

# 01 UPORABNA INFORMATIKA

# U P O R A B N A I N F O R M A T I K A

2022 ŠTEVILKA 1 JAN/FEB/MAR LETNIK XXX ISSN 1318-1882

## ► Znanstveni prispevki

Maša Kljun, Matija Teršek, Slavko Žitnik

**Pomenska analiza kategorij sovražnega govora v obstoječih označenih korpusih**

3

Jan Bajt, Marko Robnik Šikonja

**Strojna analiza tematik in sentimenta slovenskih novičarskih medijev**

19

## ► Strokovni prispevki

Alenka Baggia, Robert Leskovar, Branislav Šmitek, Saša Mlakar, Katja Pesjak, Mateja Bahun, Manuel Lillo-Crespo, Jorge Riquelme Galindo, Christine FitzGerald, Liz Kingston, Alice Coffey, Lucia Cadorin, Alvisa Palese, Barbara Narduzzi, Sara Scarsini, Uroš Rajkovič

**E-učilnica za učenje na dokazih podprtne zdravstvene nege**

37

Gregor Polančič, Mateja Kocbek Bule

**Stanje in trendi na področju rudarjenja procesov**

51

Živa Rant, Dalibor Stanimirović, Jure Janet

**Funkcionalnosti in uporaba portala za paciente zVEM in Centralnega registra podatkov o pacientu**

63

## ► Prispevki iz Konference Dnevi slovenske informatike

Matjaž Kragelj, Mirjana Kljajić Borštnar, Alenka Brezavšček

**Problematika ohranjanja zasebnosti pri podatkovnem rudarjenju dokumentov z občutljivimi podatki**

74

## ► Informacije

**Iz slovarja**

84

**Ustanovitelj in izdajatelj**

Slovensko društvo INFORMATIKA  
Litostrojska cesta 54, 1000 Ljubljana

**Predstavnik**

Niko Schlamberger

**Odgovorni urednik**

Saša Divjak

**Uredniški odbor**

Andrej Kovačič, Evelin Krmac, Ivan Rozman, Jan Mendling, Jan von Knop, John Taylor, Jurij Jaklič, Lili Nemec Zlatolas, Marko Hölbl, Mirjana Kljajič Borštnar, Mirko Vintar, Pedro Simões Coelho, Saša Divjak, Sjaak Brinkkemper, Slavko Žitnik, Tatjana Welzer Družovec, Vesna Bosilj-Vukšić, Vida Groznik, Vladislav Rajkovič

**Recenzentski odbor**

Aleksander Sadikov, Alenka Kavčič, Aljaž Košmerlj, Andrej Kovačič, Bor Plestenjak, Borut Batagelj, Borut Weber, Borut Werber, Borut Žalik, Branko Kavšek, Branko Čter, Ciril Bohak, Danijel Skočaj, David Jelenc, Dejan Georgiev, Dejan Lavbič, Denis Trček, Domen Mongus, Eva Krhač, Evelin Krmac, Inna Novalija, Irena Nančovska Šerbec, Ivan Gerlič, Jernej Vičič, Jure Žabkar, Katarina Puc, Lovro Šubelj, Luka Čehovin, Luka Pavlič, Marina Trkman, Marjan Heričko, Marjan Krisper, Marko Bajec, Marko Hölbl, Marko Robnik Šikonja, Matej Klemen, Matevž Pesek, Matjaž Divjak, Mirjana Kljajič Borštnar, Mladen Borovič, Muhamed Turkanovič, Niko Schlamberger, Nikola Ljubešić, Patricio Bulić, Peter Trkman, Polona Rus, Sandi Gec, Saša Divjak, Slavko Žitnik, Uroš Godnov, Uroš Rajkovič, Vida Groznik, Vladislav Rajkovič, Vlado Stankovski, Živa Rant

**Tehnični urednik**

Slavko Žitnik

**Lektoriranje angleških izvlečkov**

Marvelingua (angl.)

**Oblikovanje**

KOFIN DIZAJN, d. o. o.

**Prelom in tisk**

Boex DTP, d. o. o., Ljubljana

**Naklada**

200 izvodov

**Naslov uredništva**

Slovensko društvo INFORMATIKA  
Uredništvo revije Uporabna informatika  
Litostrojska cesta 54, 1000 Ljubljana  
[www.uporabna-informatika.si](http://www.uporabna-informatika.si)

Revija izhaja četrteletno. Cena posamezne številke je 20,00 EUR. Letna naročnina za podjetja 85,00 EUR, za vsak nadaljnji izvod 60,00 EUR, za posamezne 35,00 EUR, za študente in seniorje 15,00 EUR. V ceno je vključen DDV.

Revija Uporabna informatika je od številke 4/VII vključena v mednarodno bazo INSPEC.

Revija Uporabna informatika je pod zaporedno številko 666 vpisana v razvid medijev, ki ga vodi Ministrstvo za kulturo RS.

Revija Uporabna informatika je vključena v Digitalno knjižnico Slovenije (dLib.si).

© Slovensko društvo INFORMATIKA

## Vabilo avtorjem

V reviji Uporabna informatika objavljamo kakovostne izvirne članke domačih in tujih avtorjev z najširšega področja informatike v poslovanju podjetij, javni upravi in zasebnem življenju na znanstveni, strokovni in informativni ravni; še posebno spodbujamo objavo interdisciplinarnih člankov. Zato vabimo avtorje, da prispevke, ki ustrezajo omenjenim usmeritvam, pošljejo uredništvu revije po elektronski pošti na naslov [ui@drustvo-informatika.si](mailto:ui@drustvo-informatika.si).

Avtorje prosimo, da pri pripravi prispevka upoštevajo navodila, objavljena v nadaljevanju ter na naslovu <http://www.uporabna-informatika.si>.

Za kakovost prispevkov skrbi mednarodni uredniški odbor. Članki so anonimno recenzirani, o objavi pa na podlagi recenzij samostojno odloča uredniški odbor. Recenzenti lahko zahtevajo, da avtorji besedilo spremenijo v skladu s priporočili in da popravljeni članek ponovno prejmejo v pregled. Uredništvo pa lahko še pred recenzijo zavrne objavo prispevka, če njegova vsebina ne ustreza vsebinski usmeritvi revije ali če članek ne ustreza kriterijem za objavo v reviji.

Pred objavo članka mora avtor podpisati izjavo o avtorstvu, s katero potrjuje originalnost članka in dovoljuje prenos materialnih avtorskih pravic. Nenaročenih prispevkov ne vračamo in ne honoriramo. Avtorji prejmejo enoletno naročnino na revijo Uporabna informatika, ki vključuje avtorski izvod revije in še nadaljnje tri zaporedne številke.

S svojim prispevkom v reviji Uporabna informatika boste prispevali k širjenju znanja na področju informatike. Želimo si čim več prispevkov z raznoliko in zanimivo tematiko in se jih že vnaprej veselimo.

Uredništvo revije

## Navodila avtorjem člankov

Članke objavljamo praviloma v slovenščini, članek tujih avtorjev pa v angleščini. Besedilo naj bo jezikovno skrbno pripravljeno. Priporočamo zmernost pri uporabi tujk in – kjer je mogoče – njihovo zamenjavo s slovenskimi izrazi. V pomoč pri iskanju slovenskih ustreznic priporočamo uporabo spletnega terminološkega slovarja Slovenskega društva Informatika Islovar ([www.islovar.org](http://www.islovar.org)).

Znanstveni članek naj obsega največ 40.000 znakov, strokovni članki do 30.000 znakov, obvestila in poročila pa do 8.000 znakov.

Članek naj bo praviloma predložen v urejevalniku besedil Word (\*.doc ali \*.docx) v enojnem razmaku, brez posebnih znakov ali poudarjenih črk. Za ločilom na koncu stavka napravite samo en prazen prostor, pri odstavkih ne uporabljajte zamika.

Naslovu članka naj sledi za vsakega avtorja polno ime, ustanova, v kateri je zaposlen, naslov in elektronski naslov. Sledi naj povzetek v slovenščini v obsegu 8 do 10 vrstic in seznam od 5 do 8 ključnih besed, ki najbolje opredeljujejo vsebinski okvir članka. Pred povzetkom v angleščini naj bo še angleški prevod naslova, prav tako pa naj bodo doda ne ključne besede v angleščini. Obratno velja v primeru predložitve članka v angleščini. Razdelki naj bodo naslovljeni in oštrevljeni z arabskimi številkami.

Slike in tabele vključite v besedilo. Opremite jih z naslovom in oštrevlčite z arabskimi številkami. Vsako sliko in tabelo razložite tudi v besedilu članka. Če v članku uporabljate slike ali tabele drugih avtorjev, navedite vir pod sliko oz. tabelo. Revijo tiskamo v črno-beli tehniki, zato barvne slike ali fotografije kot original niso primerne. Slik zaslonsov ne objavljamo, razen če so nujno potrebne za razumevanje besedila. Slike, grafikoni, organizacijske sheme ipd. naj imajo belo podlago. Enačbe oštrevlčite v oklepajih desno od enačbe.

V besedilu se sklicujte na navedeno literaturo skladno s pravili sistema APA navajanja bibliografskih referenc, najpogosteje torej v obliki (Novak & Kovač, 2008, str. 235). Na koncu članka navedite samo v članku uporabljeno literaturo in vire v enotnem seznamu po abecednem redu avtorjev, prav tako v skladu s pravili APA. Več o sistemu APA, katerega uporabo omogoča tudi urejevalnik besedil Word 2007, najdete na strani <http://owl.english.purdue.edu/owl/resource/560/01/>.

Članku dodajte kratek živiljenjepis vsakega avtorja v obsegu do 8 vrstic, v katerem poudarite predvsem strokovne dosežke.

# ► Pomenska analiza kategorij sovražnega govora v obstoječih označenih korpusih

Maša Klijun, Matija Teršek, Slavko Žitnik

Univerza v Ljubljani, Fakulteta za računalništvo in informatiko, Večna pot 113, SI-1000 Ljubljana

mk2700@student.uni-lj.si, mt2421@student.uni-lj.si, slavko.zitnik@fri.uni-lj.si

## Izvleček

Trenutno je dostopnih mnogo angleških korpusov z označenimi različnimi kategorijami žaljivega govora, različnimi načini označevanja in poimenovanja kategorij. V tem prispevku analiziramo 21 kategorij žaljivega oz. sovražnega govora. Pri tem uporabimo metode obdelave naravnega jezika na sedem različnih korpusih, da lahko odkrivamo korelacije med posameznimi kategorijami. Analizo izvedemo s pomočjo tradicionalnih (TF-IDF) in naprednih (fastText, GloVe, Word2Vec, BERT in ostale globoke metode) tehnik, s katerimi želimo odkriti zakonitosti med posameznimi kategorijami sovražnega govora. Rezultati razkrijejo, da je večina kategorij močno povezana med seboj, vendar lahko kljub temu izdelamo dvonivojsko hierarhično predstavitev povezanosti. Analizo izdelamo tudi za slovenski jezik in primerjamo rezultate za oba izbrana jezika.

**Ključne besede:** žaljivi govor, sovražni govor, obdelava naravnega jezika, vektorske vložitve besed

## Abstract

There exists a vast amount of different offensive language corpora for English language, annotation criteria and category naming. In this paper, we explore 21 different categories of offensive language. We use natural language processing techniques to find correlations between the categories based on seven different data sets. We employ several traditional (TF-IDF) and advanced (fastText, GloVe, Word2Vec, BERT, and other deep NLP methods) techniques to uncover similarities among different offensive language categories. The findings reveal that most of the categories are densely interconnected, while a two-level hierarchical representation of them can be provided. We also transfer the analysis to the Slovenian language and compare the findings between both researched languages.

**Keywords:** Offensive language, hate speech, natural language processing, word embeddings

## 1 INTRODUCTION

In the last few years, social media grew exponentially, and with it also the ability of people to express themselves online. Enabling people to write on different online platforms without even identifying themselves lead to a new era of freedom of speech. Despite this new medium for communication bringing many positive things, it also has its downside. Social media has become a place where heated discussions happen and often result in insults and hatred. It is an important task to recognize hate speech and offensive language, and to prevent it.

Hate speech is defined as *abusive or threatening speech or writing that expresses prejudice against a particular group, especially on the basis of race, religion, or sexual orientation* [OUP, 2021]. We can see that the definition is very vague. Having said that, the goal of our paper is to help distinguish different types of hate speech and find the specific keywords of its subgroups in order to explain its structure. This could help with its identification and classification in case someone would use multiple datasets. As there exist no clear definitions of annotated categories, a researcher needs to understand them first and then decide how to

use them. In this paper we focus on 21 subgroups of offensive language – *abusive, hateful, spam, general hate speech, profane, offensive, cyberbullying, racism, sexism, vulgar, homophobic, slur, harassment, obscene, threat, discredit, insult, hostile, toxic, identity hate and benevolent sexism*. The goal of this paper is to explore offensive language subgroups and understand the similarities and connections between them.

There has been done a lot of research regarding offensive language, however, these works are usually focused on classification. One of the first works includes [Spertus, 1997] who built the decision tree based classifier Smokey for abusive message recognition and classification. Some other works that focus mainly on classification include [Waseem, 2016], who compare the classification accuracy of models trained on expert and amateur annotations, [Gambäck and Sikdar, 2017] use convolutional neural networks for classification into four predefined categories, and [Martins et al., 2018] use different natural language processing techniques for expanding data sets with emotional information for better classification. In the last years, especially deep learning models are often used for detection and classification of hate speech, such as [Rizouli et al., 2019], who propose a sophisticated method that is a combination of a deep neural network architecture with transfer learning. There is also a lot of related work that focuses on creating large data sets, such as [Chung et al., 2019], who create a large-scale, multilingual, expert-based data set of hate speech.

What is less common in the research area of offensive language is analysis of relationships between different types of the offensive language and the importance of specific keywords. Some examples include [Xu et al., 2012], who try to separate bullying from other social media posts and try to discover the topic of bullying using topic modeling with Latent Dirichlet Allocation (LDA). [Calderón et al., 2020] model hate speech against immigrants on Twitter in Spain. They try to find the underlying topic of hate speech using LDA, discovering features of different dimensions of hate speech, including foul language, humiliation, irony, etc. [Schmidt and Wiegand, 2017] conduct a survey about hate speech detection and describe key areas that have been explored, regarding the topic modeling, as well as sentiment analysis.

Recently, some research has been published, focusing on creating a new typology of offensive lan-

guage [Banko et al., 2020] or trying to unify offensive language categories across datasets [Salminen et al., 2018, Risch et al., 2021]. None of these research has focused or analyzed existing data in depth. Banko et al. [Banko et al., 2020] proposed a new typology that would require re-annotation of existing data and is therefore only a theoretical ground for further annotation campaigns. Similarly, Salminen et al. [Salminen et al., 2018] propose a new taxonomy, based on existing data sources, annotate a new corpus and perform classification analysis. Risch et al. [Risch et al., 2021] try to combine a multitude of datasets into a single schema. They also provide a unification tool. We cannot agree with the analysis as we show that annotation guidelines and data sources are too much different to directly map them into one schema and that their context should be considered when doing so. We show that different categories of offensive language (as annotated in publicly available corpora) from different datasets do not have a full intersection. In the future, there is a need for comprehensive typology development, along with linguistically-solid definitions.

We organize this paper as follows: we present the data sets and describe data preprocessing in Section 2, we perform the exploratory analysis by using many traditional and neural approaches in Section 3. Furthermore, we use non-contextual embeddings and apply them to the Slovene language in Section 4. In the end, we provide a possible offensive language ontology in Section 5.

*Note to the reader: this paper includes some explicit examples of offensive language.*

## 2 DATA

We use 7 publicly available data sets for our exploratory analysis. We combine three data sets [Waseem, 2016], [Waseem and Hovy, 2016], and [Jha and Mamidi, 2017] into one large data set (referred to as SRB) as they include the same categories of hate speech. We create labels *sexism*, *racism*, and *both* from [Waseem, 2016] and [Waseem and Hovy, 2016]. [Jha and Mamidi, 2017] is an extension of the first two. It includes label *hostile sexism*, which contains tweets from *sexism* category in the first two data sets, and label *benevolent sexism*, which we rename to *benevolent*. Thus, we obtain a data set with 6069 samples that are labeled either *sexism*, *racism*, *both*, or *benevolent*. *Benevolent* includes comments that exhibit subjective

positive sentiment, but is sexist, while *sexism* includes tweets that exhibit explicitly negative emotion. The authors do not state what was the criteria to label tweets as *racist*, but they state that it is easy to identify racist slurs.

The next data set (referred to as AHS)[Founta et al., 2018] contains 3 categories – *abusive*, *hateful*, *spam*. *Abusive* is any strongly impolite, rude, or hurtful language using profanity, that can show a debasement of someone or something, or show intense emotion. *Hateful* is language used to express hatred or is intended to be derogatory, to humiliate, or to insult the members of the group. *Spam* consists of posts related to advertising, phishing, and other kinds of unwanted information. As we use no data sets that are directly derived from this data set, contrary to the previous three data sets, we show this data set as a separate standalone data set. We obtain 13776 tweets with the above mentioned labels. Note that we exclude *None* label from both data sets, as we do not need it for the analysis. We provide an example for each label:

**Racism:** »He can't be a server at our restaurant, that beard makes him look like a terrorist.« Everyone laughs. #fuckthanksgiving

**Sexism:** #katieandnikki stop calling yourselves pretty and hot..you're not and saying it a million times doesn't make you either...STFU

**Benevolent :** It's »NEXT to every successful man, there's a woman« **Spam:** RT @OnlyLookAtMino: [!!] #WINNER trending #1 on melon search **Abusive:** You Worried About Somebody Bein Ugly... Bitch You Ugly...

**Hateful:** i hope leaders just kick retards that fake leave teams today

Additionally, we use the data set of comments extracted from the League of Legends community [Bretschneider and Peters, 2016], which we refer to as CYB. *Cyberbullying* is a process of sending offending messages several times to the same victim by the same offender. We preprocess the data set given in the SQL format to a more readable CSV form and keep only the posts that are annotated as harassment. We obtain 259 examples of cyberbullying. The sixth data set that we use was designed for the problem of hate speech identification and classification, but we use the labels from the train and test set and merge them into one big data set that we use for our analysis. It provides tags of *hatespeech*, *profane*, and

*offensive*, so we refer to the data set as HPO [Mandl et al., 2019]. It consists of 2549 tweets. *Hateful* includes messages that describe negative attributes of individuals because they are members of a group or hateful comments towards race political opinion, gender, etc. *Offensive* includes messages that are degrading, dehumanizing, or insulting to an individual, and *profane* includes messages that contain unacceptable language in the absence of hate and offensive content (for example swearwords). We provide an example for each of the labels.

**Cyberbullying:** plot twist she's a fgg

**Hatespeech:** Johnson you liar. You don't give a flying one for the Irish

**Offensive:** #FuckTrump And retired porn star Melania too.

**Profane:** Fuck Trump and anybody who voted for that Lyin POS! #FuckTrump

We also use the data set of Wikipedia comments [Wulczyn et al., 2017, Borkan et al., 2019] that are marked as either *toxic*, *severe toxic*, *obscene*, *identity hate*, *threat*, and *insult*. We merge the first two categories into *toxic*. Most labels here are derived from toxicity, which is defined as anything that is rude, disrespectful, or unreasonable that would make someone want to leave a conversation. It is important to note that each comment in this data set might have multiple labels, so the results for those tags might be similar. The original data set contains 159571 tweets, 16225 of which are labeled. We denote this data set as TOITI in the future text and show the examples for each label:

**Threat :** SHUT UP, YOU FAT POOP, OR I WILL KICK YOUR ASS!!!

**Obscene:** you are a stupid fuck and your mother's cunt stinks

**Insult :** Fuck you, block me, you faggot pussy!

**Toxic:** What a motherfucking piece of crap those fuckheads for blocking us!

**Identity :** A pair of jew-hating weiner nazi schmucks.

We show the distribution of individual categories from data sets in Figure 1. Note that the numbers of samples might not match the numbers in the original papers, due to the removed tweets by Twitter, making them unavailable for us to analyze. We see that *toxic*, *obscene*, *insult*, and *spam* are far more frequent than other labels, especially compared to *threat*, *racism*, and *cyberbullying*. This varies as the comments

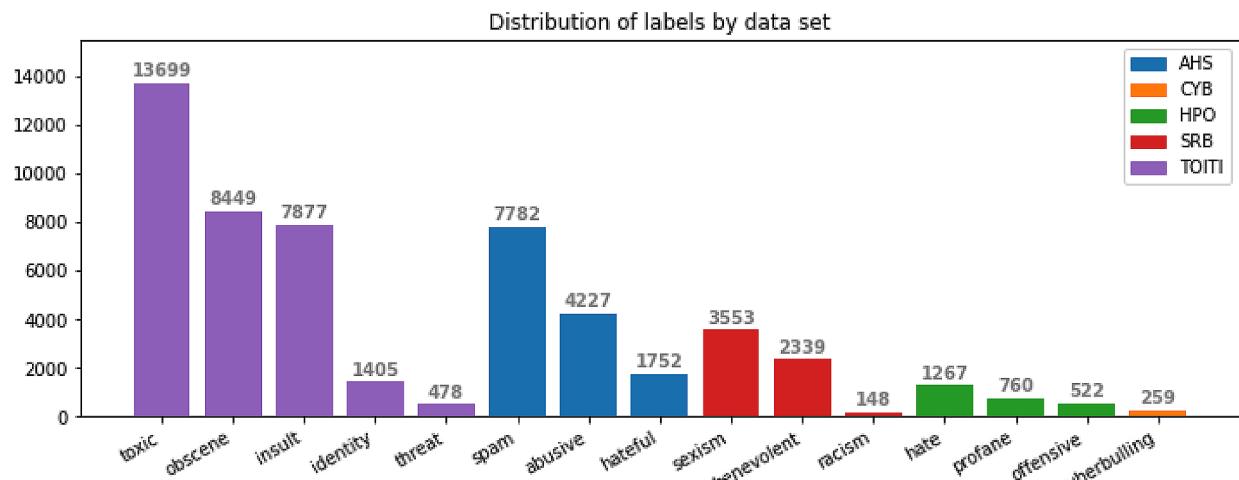


Figure 1: Distribution of labels by data sets. We analyze the following data sets: AHS [Founta et al., 2018], CYB [Bretschneider and Peters, 2016], HPO [Mandl et al., 2019], SRB [Waseem, 2016, Waseem and Hovy, 2016, Jha and Mamidi, 2017] and TOITI [Wulczyn et al., 2017].

were extracted from various social media platforms, which sometimes ban or remove inappropriate comments, making them unavailable for us to analyze. The number of comments for each label also depends on the size of the data set – for example, TOITI is much bigger than HPO. Note that two labels are similar (*hateful* and *hate*), and authors of both data sets use them to classify hate speech oriented towards certain groups because of their social status, disability, race, religion, ethnic origin, or sexual orientation. However, we do not merge those two labels as data sets are collected from Twitter or Facebook at different times, which might influence their content.

In addition to the 15 labels from the above mentioned data sets, we also consider six more offensive language subgroups *discredit*, *harassment*, *vulgar*, *homophobic*, *slur*, and *hostile*, which were not in the original five data sets that use. We included those words based on previous analysis done with experts from the linguistics field [Lewandowska-Tomaszczyk et al., 2021]. In this paper, we want to additionally support the claim that category naming in existing offensive datasets is not sound and therefore we cannot clearly distinguish them also using exploratory analysis tools.

As the goal of this report is to inspect the deeper structure and gain a new understanding of relationships between different subgroups of hate speech, we must also inspect how the data that we work with were annotated. Annotations play a big role in this analysis, as we take them as ground truth, meaning if in the data set some tweet or comment was labeled

as e.g., *sexism* we do not further question this choice and perform all our further analysis accordingly. The used data sets were sampled from different social mediums in a limited period at different times, and in some cases, for a specific topic (e.g., political topic). This influences the analysis. However, as the goal of this paper is to research the connections between various subgroups of hate speech, we do not question whether the data sets are a good representation of the subgroups, yet we are aware of this and keep this in mind during the analysis.

Data set [Waseem, 2016] uses both amateur annotators from crowdsourcing platform CrowdFlower and annotators with theoretical and applied knowledge of hate speech, and use the data set for hate speech detection and classification. [Jha and Mamidi, 2017] manually annotate their data set with the help of a 25-year-old woman studying gender studies and use the data to investigate how different is benevolent sexism from sexism, and also perform classification with SVM. [Founta et al., 2018] again use amateur annotators from CrowdFlower and want to provide large annotated data set that is available for further scientific exploration. [Bretschneider and Peters, 2016] use three human experts for the annotation and then propose an approach to precisely detect cyberbullies and also provide metrics to identify victims of severe cyberbullying cases. [Mandl et al., 2019] used junior experts for language and they engaged with an online system to judge the tweets. Their goal was text classification. [Wulczyn et al., 2017] again use platform CrowdFlower, however, they require their an-

notators to first pass a test of ten questions to ensure data quality. Their goal is to provide a methodology that will allow them to explore some of the open questions about the nature of online personal attacks.

### 3 EXPLORATORY ANALYSIS

In this section, we show the analyses of the offensive language corpora. We especially focus on known NLP techniques that would help us differentiate between existing offensive language categories that are annotated in the corpora. Our analysis is conducted as follows: (A) First we employ traditional methods such TF-IDF to gather common keywords for the existing categories. (B) We continue using pre-trained and custom-trained non-contextual word embedding techniques. These enable us to gather a number of relevant vectors and then embed them into two dimensions to investigate possible differences or clusterings. (C) Lastly, we use three different contextual word embedding techniques to check for more fine-grained similarities.

Before applying any methods we first preprocess all of our data. We remove retweet text RT, hyperlinks, hashtags, taggings, new lines, and zero-length tweets. We further filter out tokens that do not contain letters, e.g., raw punctuation.

#### 3.1 Traditional word embeddings

As the results using Latent Dirichlet Allocation in combination with Bag-of-Words (BoW) and TF-IDF do not add a contribution to the analysis, we employ TF-IDF as we want to see the most relevant words for each category of offensive language that we have in the data set. For each category, we take the corresponding tweets or comments and use them as documents. We show the results in Table 1. We can see that some of the categories have similar unigrams that achieved the highest TF-IDF score. An example of categories with the same highest scored unigrams are *insult* and *obscene*. This makes it harder to differentiate between the categories. It is important to note, that such examples might also occur due to subjective labeling in the provided data sets, as well as people not clearly differentiating between these categories. Most data sets are not labeled by experts, but with the help of platforms such as FigureEight or Amazon Mechanical Turk. From the results in Table 1, we could assume that most people perceive categories such as *insult* and *obscene* or *threat* and

*toxic* similarly. On the other hand, categories such as *spam* or *cyberbullying* are clearly differentiable from other categories. We can also see a lot of categories including Trump related words (*hatespeech*, *profane*, and *offensive*). Those categories are taken from the same data set, and we can see that such labels will contain words that are related. So the words connected to those labels might also be connected to some bigger topic since this can be influenced by the popular topics at that time, and a platform from which the creators of the data set decided to collect the data.

Table 1: Table shows the five highest scoring unigrams for each label we investigate. We choose the parameters, which we believe provide us with the most meaningful unigrams, so we consider words that appear in at least 5 % and less than 60 % of the documents.

category	unigrams with highest TF-IDF score
racism	peopl, white, terror, man, look
sexism	feminazi, women, think, sexist, notsexist
benevolent	women, classi, sassi, nasti, gonna
abusive	know, stupid, shit, like, idiot
hateful	peopl, trump, nigga, like, idiot
spam	giveaway, game, enter, work, home
cyberbullying	one, guy, good, gone, go
hatespeech	world, trumpisatrator, trump, shameonicc, peopl
identity hate	fuck, shit, littl, like, one
insult	delet, go, ass, stupid, bitch
obscene	delet, go, stupid, bitch, ass
offensive	trumpisatrator, like, douchebag, fucktrump, get
profane	trump, shit, say, resist, peopl
threat	fuck, get, die, want, find
toxic	fuck, get, bitch, want, block

#### 3.2 Non-contextual word embeddings

For each of the category labels, we try to find the 30 most similar words and use their embeddings to infer the similarities and differences between the subgroups. For this task we use pre-trained Word2Vec [Mikolov et al., 2013a, Mikolov et al., 2013b], GloVe [Pennington et al., 2014], FastText [Bojanowski et al., 2017], and ConceptNet Numberbatch [Speer et al., 2017] embeddings of dimensionality 300. We visualize the results with the help of t-SNE [Van der Maaten and Hinton, 2008] (perplexity = 15, number of iterations = 3500, and 2 components). Because of this, we cannot interpret distances between the labels from the visualization. However, we can still infer that the

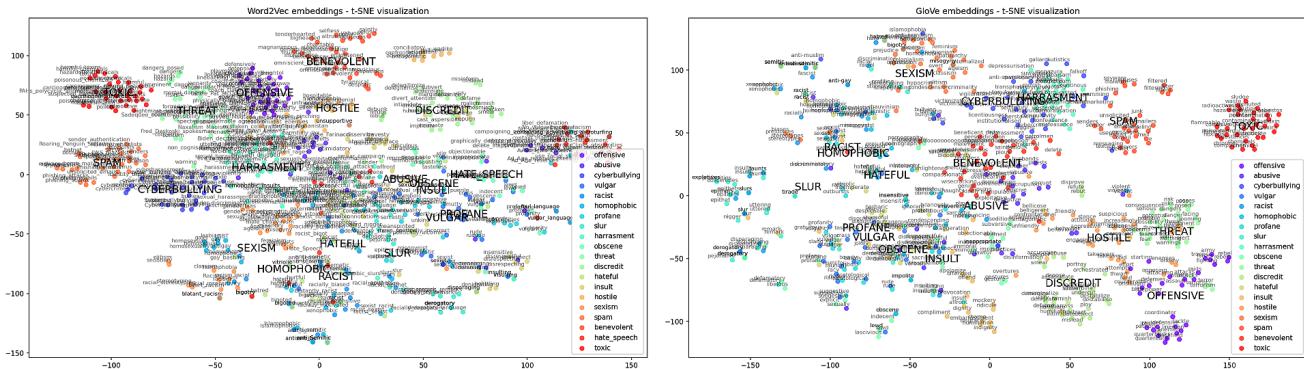


Figure 2: **Word2Vec and GloVe embeddings.** Figure shows Word2Vec (left) and GloVe (right) embeddings of 30 closest words of each label that we analyze. Note that we omit offensive language subgroups that are not in the vocabulary.

labels that are intertwined are more similar than those that are nicely separable from one another.

We show the results of Word2Vec and GloVe in Figure 2. Note that with this approach, the name of the category is favoured as the used words are derived with respect to the category name. However, the approach still uncovers various connections. We can see that *homophobic* and *racist* appear very intertwined in Word2Vec and GloVe embeddings, meaning that they cannot be separated, thus indicating a strong relation. On the other hand, in both of these embeddings *spam*, *toxic*, and *discredit* are well separated from other groups and are clearly distinguishable from others. We can also see that *abusive* is entangled with *benevolent* in GloVe representation, however, in results obtained from Word2Vec *benevolent* is nicely separable from other labels. So it is difficult to conclude that *benevolent* is a label that is different enough from other labels. FastText also nicely separates *toxic* and *benevolent* from other labels, but is unable to separate *vulgar*, *profane*, *obscene*, and *insult*. From all three models combined, we can conclude that the only label that can be always well distinguished from the others is *toxic*, and that *vulgar*, *profane*, *obscene*, and *insult* are labels that cannot be nicely separated. We also conclude that *spam* is a nicely separable category. Note that in some models we omit labels that are not in a vocabulary (*identity hate* in all models, *hate speech* in GloVe, and *threat* and *spam* in FastText).

By now we provide some relations and decide to further investigate the connections between the related labels using word analogy. We try to find hyponyms and hypernyms, which we do with the help of the following setting:

father : son = our_label : x	(hyponyms)
animal : cat = our_label : x	(hyponyms)
son : father = our_label : x	(hypernyms)
cat : animal = our_label : x	(hypernyms)

where *our\_label* is one of the analyzed labels and *x* is the word found by Word2Vec or GloVe. We look at most similar words to the vector, which we obtain by taking the difference of unit-normed vectors of the two words on the left side of the equation and adding unit-normed vector of *our\_label*. We consider cosine similarity.

Unfortunately, the relationships are not clear and uniquely defined. An example is *racism* is to *sexism* what is son to father with a cosine similarity of 0.646, but *sexism* is to *racism* what is son to father with a cosine similarity of 0.648. We can once again see that the two labels are related, but the precise relationship cannot be inferred. Using brother and sister the similarity is lower. This could indicate that it is impossible to find a specific hypernym and that we can only conclude that the labels are more closely related, as they are each in some way hypernym and hyponym of each other. Similarly, *racism* and *sexism* are connected to *homophobia* and *slur*. Another group that we find, but also cannot clearly define the inner relations contains *vulgar*, *profane*, and *obscene*.

As mentioned, the distances between the inspected labels cannot be determined from our chosen visualization. That is why we approach this problem with clustering. We use *k*-means (10 iterations for all experiments) and hierarchical clustering (with Ward linkage on distance matrix) in hopes of finding meaningful clusters that could help us understand the

relationships between the subgroups of the offensive language better. We determine the  $k$  in  $k$ -means by using the silhouette score. The silhouette score is a useful metric that can be used to validate the goodness of the clustering. It can take values from -1 (clusters assigned in the wrong way) to 1 (clusters are clearly distinguished). Silhouette score is also useful for determining the optimal number of clusters, and we use it for that purpose. Note that we choose the  $k$  of the second peak of the score, as we want to form more diverse and meaningful clusters than just 2 big subgroups as the silhouette score suggests. See the example output of the silhouette score in Figure 3.

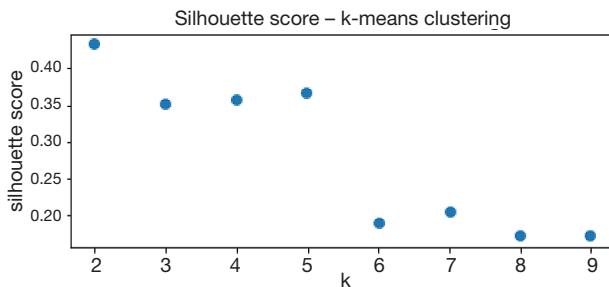


Figure 3: **Silhouette score.** Example of silhouette scores for different numbers of clusters. We use the second peak ( $k = 5$ ) instead of first ( $k = 2$ ), as we want to get more clusters.

From the top 30 similar words for each label, we compute an average vector and we obtain one such vector for each label. We compute the cosine similarity matrix between the vectors  $\text{simcos}$  and compute the distance matrix as  $d = 1 - \text{simcos}$ , which we then use for the clustering. In Table 2 we show the obtained clusters using  $k$ -means and in Figure 4 we show the results of hierarchical clustering of Word2Vec embeddings.

From these two clustering results, we can infer that *insult* and *obscene* are two similar subgroups of hate speech as they both appear in the same cluster in  $k$ -means clustering and we can see that they are in the same subcluster of nine offensive language groups in hierarchical clustering. They are also very similar according to the results from TF-IDF as seen before. We can see that *cyberbullying* and *spam* are clustered together in both clusterings and that *threat* and *toxic* are also very similar.

Comparing the hierarchical clustering results of GloVe and FastText embeddings to Word2Vec embeddings, we can see that we always get almost the same two main clusters like those in Figure 4, so we do not show figures with those results.

Looking at  $k$ -means clustering of Word2Vec and GloVe embeddings we see that labels *abusive*, *vulgar*, *racist*, *homophobic*, *profane*, *slur*, *obscene*, *hateful*, *insult*, and *discredit*, *hostile* always appear in the same two clusters, so we can conclude that they are related. We do not include the results of FastText  $k$ -means clustering, as its silhouette score is  $\leq 0.30$  for all possible  $k$ , whereas in the first two, the score is often  $> 0.30$ .

We try to apply this same approach to the words with the highest TF-IDF scores from each subgroup, however, the obtained clusters provide no useful understanding, so we omit those results.

Additionally, we use ConceptNet Numberbatch [Speer et al., 2017] embeddings. ConceptNet Numberbatch is a snapshot of word embeddings that have semi-structured, common sense knowledge from ConceptNet, a freely available semantic network. We apply a similar methodology as for Word2Vec, GloVe, and FastText embeddings, and show the results in Figure 5 using t-SNE. We can see that some subgroups are separable from the others, such as *benign*, *hostile*, *threat*, *homophobic*, and *spam*. We can also separate a cluster of *vulgar*, *obscene*, and *profane*. Other subgroups of offensive language are mainly intertwined and inseparable.

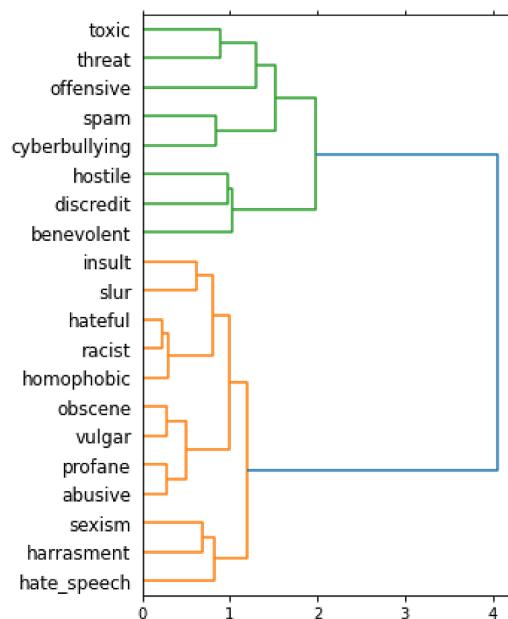


Figure 4: **Hierarchical clustering of average Word2Vec embeddings of labels' 30 nearest words.** Figure shows results of hierarchical clustering of the labels from data sets. Distance between two labels is computed as  $1 - \text{simcos}$ , where  $\text{simcos}$  is a cosine similarity between two labels. Embedding for each label is computed as an average of embeddings of the label's nearest 30 words.

Table 2: K-means clustering of average Word2Vec embeddings of labels' 30 nearest words. Table shows five clusters obtained with 5-means clustering. We determine  $k = 5$  using silhouette score.

cluster	components
1	offensive
2	abusive, vulgar, racist, homophobic, profane, slur, harassment, obscene, hateful, insult, sexism, hate speech
3	discredit, hostile, benevolent
4	cyberbullying, spam
5	threat, toxic

### 3.3 Contextual word embeddings

To perform analysis using contextual word embeddings, we need to provide whole utterances to get desired embedding vectors. We evaluate three different approaches based on BERT (Section 3.3.1), KeyBERT (Section 3.3.2) and USE (Section 3.3.3). For the plain BERT language model, we attach a category keyword to an utterance to get its representation. KeyBERT allows for automatic extraction of keywords from utterances and these represent each category. For the USE we compute average vectors from utterances and compare similarities between categories (such approach was not successful with BERT).

#### 3.3.1 BERT

We move on to contextual embeddings and we focus on BERT. We use the pretrained BERT base cased model [Devlin et al., 2019] with 768 dimensional

embeddings, and convert tweets and comments from our data set to BERT embeddings. We first append them » – This is <label>« and compute the embeddings. From the obtained last-layer embeddings of each vector, we compute an average representation from the vectors that belong to the tokens of the label. We average the obtained representation of each label and use cosine similarity to compute the similarity between those label representations. We show the obtained similarity matrix in Figure 6. We can see high similarities between most of the subgroups of hate speech. The one that differs the most from the other groups is *cyberbullying*. We can also see that *profane* is slightly less similar to *identity*, *insult*, *threat*, and *toxic*, however, the similarity score is still between 0.87 and 0.89. For all other combinations, the similarity score is  $\geq 0.90$ . We also visualize the embeddings with the help of t-SNE in Figure 7 and we show the labels on the mean points of each subgroup. We can see that all subgroups are tightly connected and it is hard to distinguish between them. However, we can see that *cyberbullying* is a little bit more compact and not as dispersed as others, which might be a reason behind slightly different similarity scores. It is also interesting that some labels, although being dispersed, have some small clusters which stand out and might indicate special subgroups within those subgroups of hate speech. An example of such a subgroup is *benevolent sexism*.

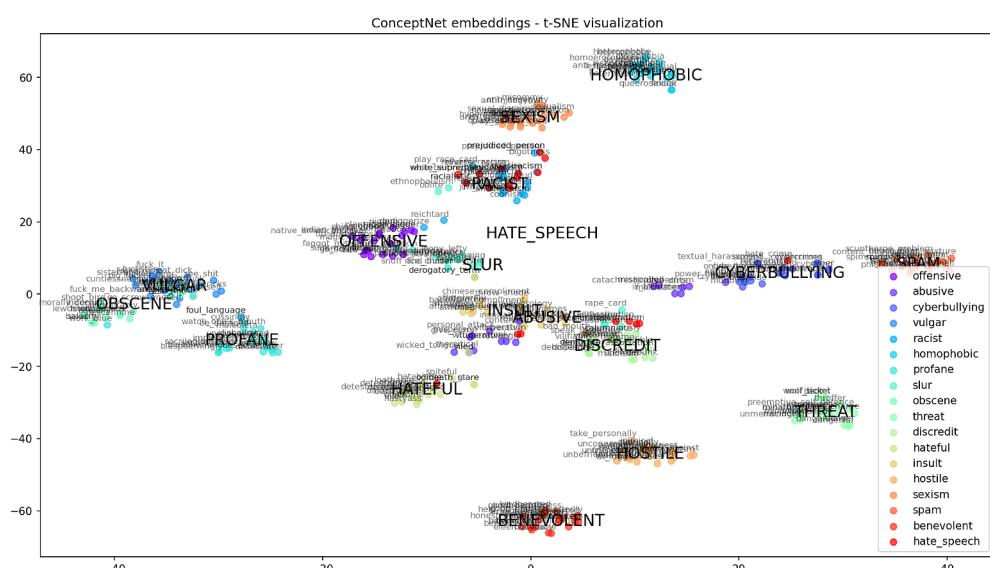


Figure 5: ConceptNet Numberbatch embeddings. Figure shows ConceptNet Numberbatch embeddings of 30 closest words of each label that we analyze. Note that we omit offensive language subgroups that are not in the vocabulary.

### 3.3.2 KeyBERT

We leverage the KeyBERT [Grootendorst, 2020], which is a minimal keywords extraction technique that uses BERT embeddings to create keywords and key phrases that are most similar to a document. For each label, we compute top three keywords for each tweet or comment using KeyBERT, and show the labels' five most common keywords in Table 3. We can see that *insult*, *obscene*, and *toxic* have the same five most common keywords. Since they come from the same data set, and since each tweet from that data set could have multiple labels, we feel that this affected the results. We can see that quite a few labels include common keywords such as fuck, bitch, fucking, and idiot, which is not surprising, as they are among the top common curses. We can see more Trump-related words in *offensive*, *profane*, and *hate speech*, which is probably again due to the background of data set generation. However, the most common keyword sets of those labels still slightly differ. Keywords are the most diverse between *benevolent*, *cyberbullying*, *racism*, *sexism*, and *spam*.

### 3.3.3 Universal Sentence Encoder (USE)

Another model that we use is Universal Sentence Encoder (USE) [Cer et al., 2018] which is a model that can be nicely used for semantic similarity. USE encodes text into high dimensional vectors that can be used for text classification, semantic similarity, clustering, and other natural language tasks. USE can be trained using Transformer encoder architecture [Vaswani et al., 2017] with Deep Averaging Network (DAN) [Iyyer et al., 2015]. Both models focus on a trade-off between accuracy and computational resource requirement. While the one with Transformer encoder has higher accuracy, it is computationally more intensive. For this analysis, we use universal-sentence-encoder-large model available from TensorFlow Hub, which was trained using Transformer encoder and has 512 dimensional embeddings.

We use USE model to further analyze the structure of offensive language in general. We average the obtained embeddings of texts for each label and use cosine similarity to compute the similarity between those label representations. We show the obtained si-

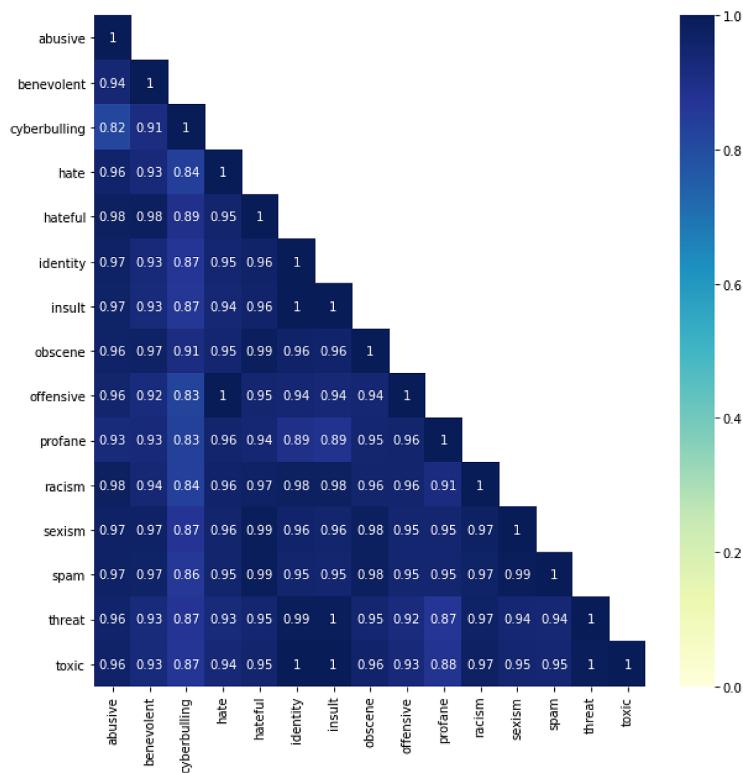


Figure 6: **Similarities between BERT embeddings.** Figure shows the similarity between labels' BERT embeddings.

For each label, we obtain an average vector representation by averaging embeddings obtained from the label's tweets or comments (same as in Fig. 7). The similarity is then computed as cosine similarity between those vector representations.

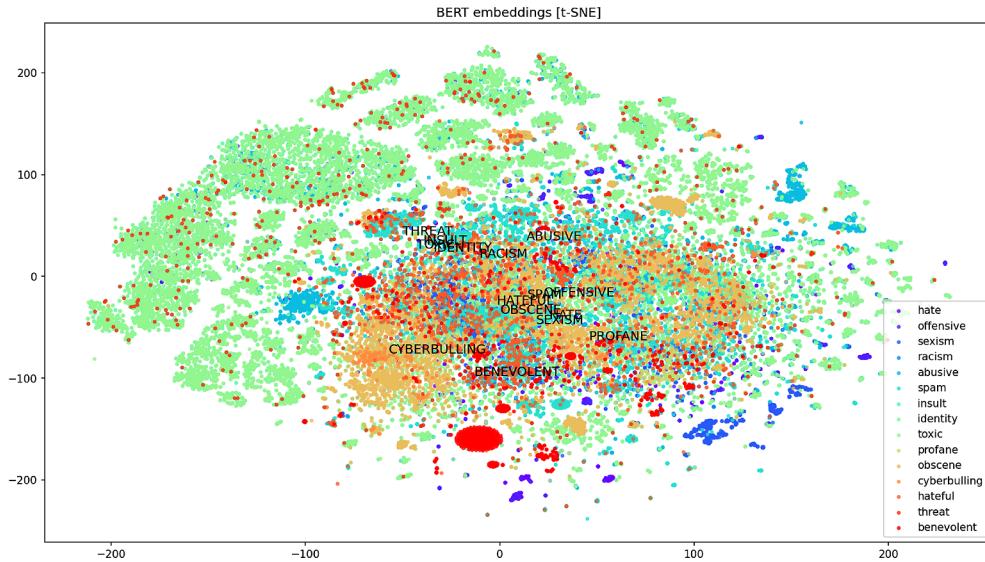


Figure 7: **BERT embeddings.** T-SNE visualization of BERT embeddings for different labels. We obtain each embedding by first appending – This is <label> to our tweets or comments and computing the embeddings for each text. An embedding of the label of text is then the average of the token embeddings that belong to the <label>.

milarity matrix in Figure 8. From the plot we can see that similarly to BERT results, the subgroups here are again very similar. We can see that *toxic*, *hateful*, and *spam* are more similar to each other than to other labels.

#### 4 OFFENSIVE LANGUAGE IN SLOVENIAN

In this section, we translate English terms to Slovene and check whether we might uncover some differences between them using pre-trained models.

We choose to use non-contextual word embeddings. We do not focus on contextual word embeddings, as no Slovene data sets that would cover most of our labels exist. We use pretrained Word2Vec [Kutuzov et al., 2017] and FastText [Grave et al., 2018] models for Slovene language and want to see whether we can separate some subgroups of hate speech or find some subgroups that are inseparable. We first translate the labels of subgroups into Slovene language and we show the translations in Table 4. We intentionally translate all labels to nouns in order to keep them all in the same part of speech, as experiments showed that otherwise the labels that shared the same part of speech were intertwined. Unfortunately, as some words are not supported in Slovenian Word2Vec and FastText, we remove labels for hate speech (*slo. sovražni govor*), spam (*slo. vsiljenost*), and cyberbullying (*slo. spletno nasilje*) for Word2Vec and hate speech (*slo. sovražni govor*), toxic (*slo. toksičen*),

and cyberbullying (*slo. spletno nadlegovanje*) for FastText. Although FastText supports word-parts, the splits did not include meaningful roots of the keywords and therefore we omit them from results. For each of the supported category labels we try to find the ten and twenty most similar words for

Table 3: **KeyBERT keywords.** Table shows five most common keywords found with KeyBERT obtained from tweets or comments for each offensive language subgroup.

category	BERT keywords
racism	coon, white, black, terror, fuck
sexism	sexist, women, feminazi, girls, kat
benevolent	women, womensday, sassy, adaywithoutwomen, woman
abusive	fucking, idiot, bitch, hate, fuck
hateful	hate, trump, idiot, nigga, fucking
spam	video, new, 2017, liked, free
cyberbullying	riot, troll, hacking, trolls, hacker
hate speech	trumpisatraitor, doctorsfightback, shameonicc, borisjohnsonshouldnotbepm, trump
identity hate	gay, fuck, nigger, bitch, fucking
insult	fuck, wikipedia, bitch, fucking, suck
obscene	fuck, wikipedia, bitch, fucking, suck
offensive	trumpisatraitor, fucktrump, trump, murderer, rapist
profane	fucktrump, fuck, dickhead, trump, douchebag
threat	kill, die, fuck, bitch, rape, death
toxic	fuck, wikipedia, bitch, fucking, suck

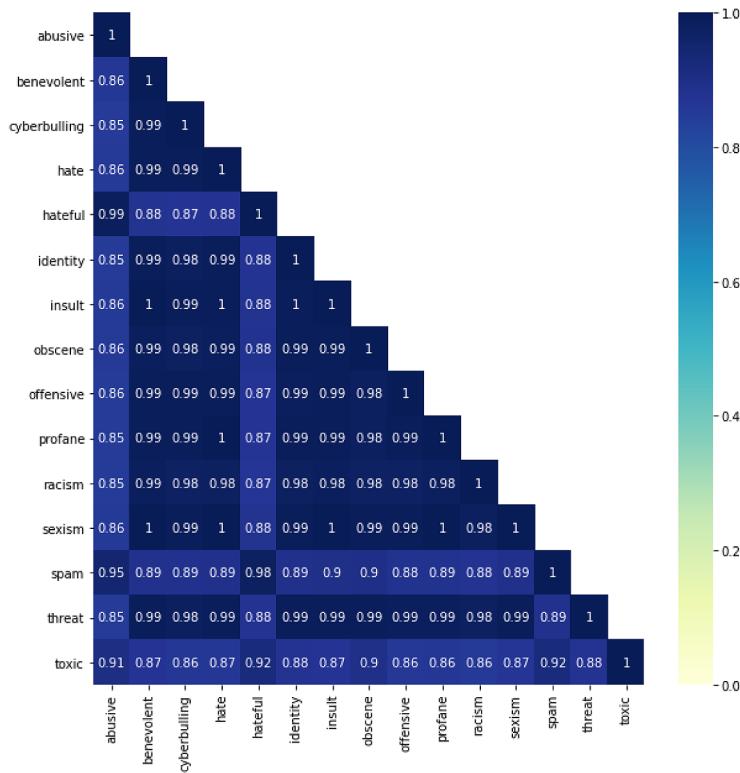


Figure 8: **Similarities between USE embeddings.** Figure shows the similarity between labels' USE embeddings. For each label, we obtain an average vector representation by averaging embeddings obtained from the label's tweets or comments. The similarity is then computed as cosine similarity between those vector representations.

Word2Vec and FastText models, respectively, and use their embeddings to infer the similarities and differences between the subgroups. We show the results of Word2Vec and FastText in Figure 9. We can see from Word2Vec visualization that toxic (*slo. toksičen*) is the only subgroup that can be well separated from others while all other subgroups are inseparable. Inspecting the FastText t-SNE visualization, we see

that the only well separable subgroup is homophobic (*slo. homofobija*). Otherwise, there exist three groups that contain two or more subgroups of offensive language that are inseparable. An example of such a group is one smaller group that contains racism (*slo. rasizem*) and sexism (*slo. seksizem*) while two other groups contain five and eight subgroups of offensive language, respectively.

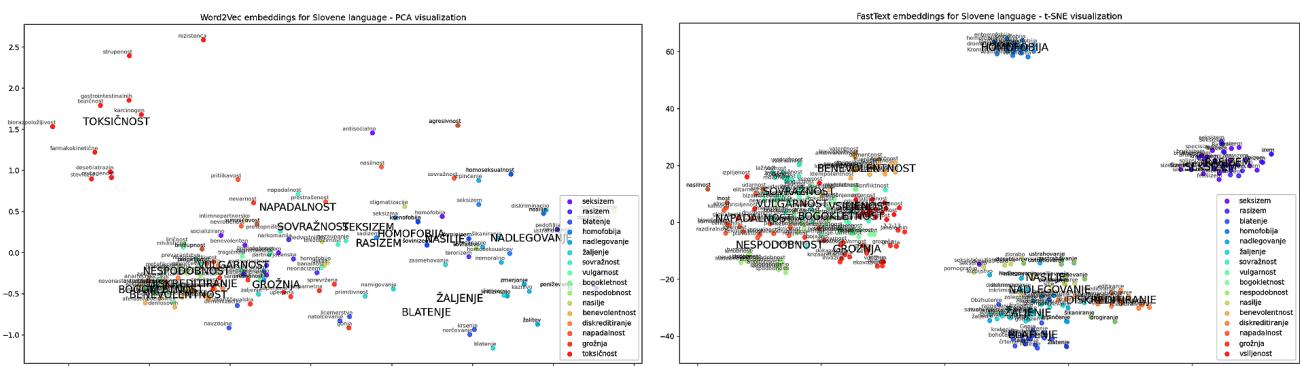


Figure 9: **Analysis of offensive language ontology for the Slovene language.** Figure shows PCA visualization of Word2Vec and t-SNE visualization of FastText embeddings.

## 5 DISCUSSION

Considering all the results and findings from above, we can now provide the following inference. Note that all categories are tightly connected in the results of contextual embeddings, which should be kept in mind. However, we want to provide some sort of separation where possible, so we consider more those results that separated our subcategories of offensive language. From all of the performed analysis, we can conclude that *spam* and *cyberbullying* can both be separated from other subcategories. We put *toxic* as a separate block as it is distinguishable from others in Word2Vec and GloVe embeddings, however, from clustering results we can see that it can also be connected to *offensive* and *threat*. We put *obscene*, *insult*, *profane*, *abusive*, and *vulgar* together as they appear in the same cluster in k-means clustering of Word2Vec and GloVe embeddings, and as they have quite similar words in KeyBERT. We define the remaining two subgroups by inspecting the Word2Vec results. Thus we obtain the following blocks:

1. *sexism, racism, homophobic, and slur* ;
2. *obscene, insult, profane, abusive, vulgar* ;
3. *discredit, offensive, hostile, threat, benevolent* ;
4. *toxic*;
5. *spam*;
6. *cyberbullying*.

In the above list, we only state 17 out of 21 subgroups that we analyze, as some categories could be tightly connected to multiple subgroups. As some subgroups cannot be separated just yet (block 1, 2, and 3), we apply further analysis with Word2Vec and GloVe. We focus on the labels and use the embeddings of their 50 most similar words. We use PCA visualization (with 2 components), so that we can also see the distance between subgroups. In the first plot of Figure 10 we see that *racism*, *slur*, and *homophobic* are more related to each other than to *sexism*. In the second plot of Figure 10 we can see that all of the inspected subgroups are tightly connected and cannot be nicely separated, *insult*, however, slightly stands out. In the last plot of Figure 10 we can see that *discredit* is not as intertwined with *insult* and *obscene*, so we conclude that although it is related to them, it is less they are to each other.

From the above findings, we show a schema of offensive language subcategories in Figure 11. Note that the schema is obtained with the described

Table 4: Slovenian translation of labels. Table shows English labels and their Slovenian translations. We only show labels for which we found a suitable translation. We use only *benevolent* as a translation for *benevolent sexism*, as it is mostly used in connection with *benevolent sexism*.

English word	Slovene translation
Sexism	Seksizem
Racism	Rasizem
Slur	Blatenje
Homophobic	Homofobija
Hate speech	Sovražni govor
Harassment	Nadlegovanje
Insult	Žaljenje
Hateful, hostile	Sovražnost
Vulgar	Vulgarnost
Profane	Bogokletnost
Obscene	Nespodobnost
Abusive	Nasilje
Benevolent sexism	Benevolentnost
Discredit	Diskreditiranje
Offensive	Napadalnost
Threat	Grožnja
Toxic	Toksičenost
Spam	Vsiljenost
Cyberbullying	Spletno nadlegovanje

analysis and it is not confirmed by any linguist professional. All of the subgroups are also tightly connected, however, as the goal of our paper is to provide some meaningful relations and ontology, we try to summarize our findings in a schema and show more connected groups together. We find 3 main groups, that are shown in bordered rectangles. The difference in colors means that the node is slightly less connected to other nodes in those groups. *Spam* and *cyberbullying* are both gray, as they are connected, but they each could be put in a separate rectangle, as they differ enough. We place them next to *toxic* as slight relations can be seen between those three. *Toxic* and *benevolent* are also connected to some of the nodes in the blue subgroup. The latter is also connected to *hateful*. We also see that *insult* has a strong relationship with the red and green subgroups, and *discredit* from the blue group. General *hate speech* is mostly connected to the red and green subgroup. Note that *identity hate* is related to all, but we could not find a stronger relation to any specific subgroup.

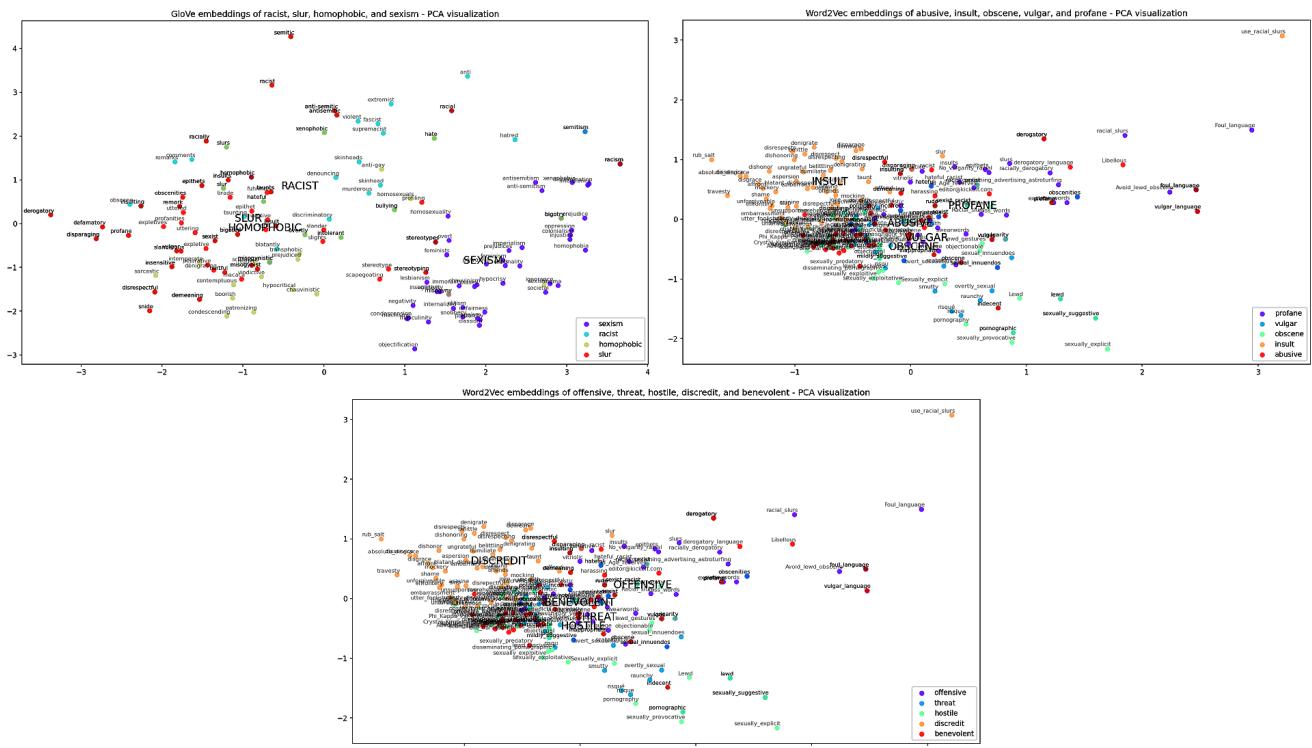


Figure 10: Further analysis of blocks that could not be separated. We use PCA visualization in all plots and 50 nearest words' embeddings of each label are used. We use GloVe embeddings in the first plot, and Word2Vec in the other two.

We compare our taxonomy to the taxonomy defined in [Banko et al., 2020]. This is a challenging task, as the proposed taxonomy in [Banko et al., 2020] is only a theoretical ground for further annotation campaigns and not derived from data, thus containing

different and missing some of the categories in our paper. The authors propose four main subcategories of online harm: Hate and harassment, self-inflicted harm, ideological harm, and exploitation. We can see that the green nodes from our taxonomy in Figure 11

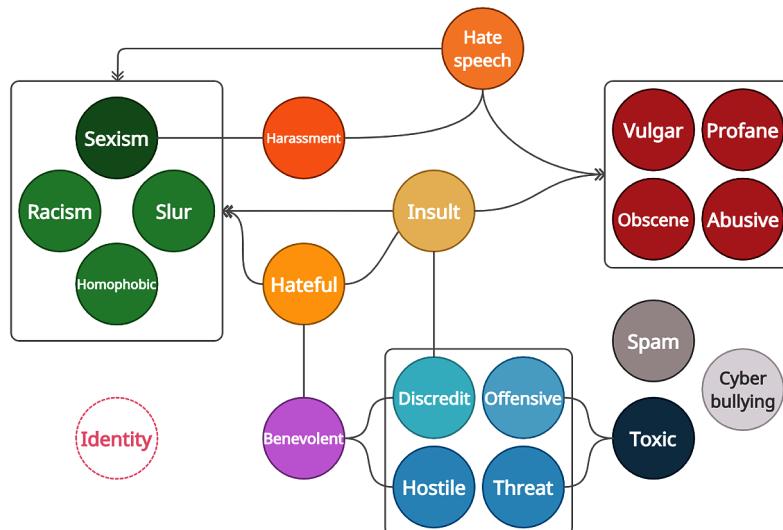


Figure 11: Inferred schema of hate speech. Figure shows the inferred schema of hate speech. Note that all of the labels are very related, however, we try to provide one possible division. Nodes in groups that are of slightly different color are more separable from other nodes in this group. We show connections to other nodes with normal lines and connections to whole groups with lines and two arrows. Identity is dotted because we do not have enough information to connect it with other nodes or groups.

can be classified into multiple subgroups of hate and harassment. *Spam* could be included in misinformation, which is a subgroup of ideological harm, as well as into some subcategories of exploitation. Some of the categories, like *threat*, *offensive*, and *profane* could be categorized into multiple subgroups of hate and harassment as well, while for some we could not find appropriate subcategories of online harm. We did not cover groups of hate speech that could be categorized into self-inflicted harm from [Banko et al., 2020], including self-harm and eating disorder promotions, or specific categories that could be categorized into subcategories of exploitation, such as child sexual abuse material or adult sexual services. Existing data is missing such annotations and relabeling could be beneficial for further exploration of subcategories of online harm proposed by [Banko et al., 2020].

## 6 CONCLUSIONS

Offensive language is known to everybody, as it is very common in social media. However, we often neglect the fact that is a conglomerate of many subgroups, such as sexism, racism, etc. In this paper, we wanted to explore offensive language and its structure and we do this by utilizing different natural language processing techniques.

We used seven different data sets that contained Twitter and online forum comments. We used traditional techniques, such as TF-IDF, and also more advanced approaches such as non-contextual (Word2Vec, GloVe, FastText) and contextual (BERT, KeyBERT, USE) embeddings. We found out that each of the approaches provides us with slightly different relations and it is difficult to draw conclusions and we would probably need some help from linguist professionals. Results also depend on how the comments were obtained and how annotators conceive the meaning of the labels.

Combining the results from several approaches, we inferred one possible ontology of offensive language. We inferred there exist three groupings that include four subgroups of offensive language each. However, even in those groupings there exist subgroups, that are less connected to others. We also found some subgroups that are more separable from others. However, it is important to note that all the subgroups are still tightly connected.

Additionally, we used pre-trained Slovenian Word2Vec and FastText models and found out that

toxic (*slo. tok- sičnost*) and homophobic (*slo. homofo- bija*) can be nicely separable by Word2Vec and FastText, respectively. Having a Slovene data set that would cover most of our labels would also be beneficial, as we could also use contextual embeddings. This would help us infer an ontology and we, therefore, delegate this to future work.

In the future, the obtained knowledge could also be upgraded with the help of a linguist professional. Only a few data sets for Slovene offensive language exist at the moment. These include Slovenian Twitter dataset 2018-2020 1.0 [Evkoski et al., 2021] and Slovenian Twitter hate speech dataset IMSyPP-sl [Kralj Novak et al., 2021], with labels acceptable, inappropriate, offensive, and violent, with the latter data set also containing some information to whom the hate speech is directed (LGBT, racism, sexism, homophobia, etc.), and Offensive language dataset of Croatian, English and Slovenian comments FRENK

1.1 [Ljubešić et al., 2021], which contains six categories – violence, offensive speech, threat, inappropriate speech, and acceptable speech. For future work, we see additional value in expanding those or creating new data sets, that would cover all categories analyzed in this paper. Note that we used only pretrained embeddings which were in our case too general and resulted in inseparable categories. Better results might be obtained by using more problem specific embeddings, such as HateBERT [Caselli et al., 2020].

## 7 ACKNOWLEDGEMENTS

We thank Žiga Trojer, Dimitar Stefanov, and Tomaž Martinčič for suggesting and help with ConceptNet Numberbatch.

## REFERENCES

- [1] [Banko et al., 2020] Banko, M., MacKeen, B., and Ray, L. (2020). A unified taxonomy of harmful content. In *Proceedings of the Fourth Workshop on Online Abuse and Harms*, pages 125–137, Online. Association for Computational Linguistics.
- [2] [Bojanowski et al., 2017] Bojanowski, P., Grave, E., Joulin, A., and Mikolov, T. (2017). Enriching word vectors with subword information. *Transactions of the Association for Computational Linguistics*, 5:135–146.
- [3] [Borkan et al., 2019] Borkan, D., Dixon, L., Sorensen, J., Thain, N., and Vasserman, L. (2019). Nuanced metrics for measuring unintended bias with real data for text classification. In *Companion proceedings of the 2019 world wide web conference*, pages 491–500.
- [4] [Bretschneider and Peters, 2016] Bretschneider, U. and Peters, R. (2016). Detecting cyberbullying in online communities.

- [5] [Calderón et al., 2020] Calderón, C. A., de la Vega, G., and Herrero, D. B. (2020). Topic Modeling and Characterization of Hate Speech against Immigrants on Twitter around the Emergence of a Far-Right Party in Spain. *Social Sciences*, 9(11):188.
- [6] [Caselli et al., 2020] Caselli, T., Basile, V., Mitrović, J., and Granitzer, M. (2020). Hatebert: Retraining bert for abusive language detection in english. *arXiv preprint arXiv:2010.12472*.
- [7] [Cer et al., 2018] Cer, D., Yang, Y., Kong, S.-y., Hua, N., Limtiaco, N., St. John, R., Constant, N., Guajardo- Cespedes, M., Yuan, S., Tar, C., Strope, B., and Kurzweil, R. (2018). Universal Sentence Encoder for English. In *Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing: System Demonstrations*, pages 169–174, Brussels, Belgium.
- [8] [Chung et al., 2019] Chung, Y.-L., Kuzmenko, E., Tekiroglu, S. S., and Guerini, M. (2019). CONAN – COunter NArratives through nichesourcing: a multilingual dataset of responses to fight online hate speech. In *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics, System Demonstrations*, pages 2819–2829, Florence, Italy. Association for Computational Linguistics.
- [9] [Devlin et al., 2019] Devlin, J., Chang, M.-W., Lee, K., and Toutanova, K. (2019). BERT: Pre-training of deep bidirectional transformers for language understanding. In *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers)*, pages 4171–4186, Minneapolis, Minnesota. Association for Computational Linguistics.
- [10] [Evkoski et al., 2021] Evkoski, B., Pelicon, A., Mozetič, I., Ljubešić, N., and Kralj Novak, P. (2021). Slovenian twitter dataset 2018–2020 1.0. Slovenian language resource repository CLARIN.SI.
- [11] [Founta et al., 2018] Founta, A., Djouvas, C., Chatzikou, D., Leontiadis, I., Blackburn, J., Stringhini, G., Vakali, A., Sirivianos, M., and Kourtellis, N. (2018). Large scale crowdsourcing and characterization of twitter abusive behavior. In *Proceedings of the International AAAI Conference on Web and Social Media*, volume 12.
- [12] [Gambäck and Sikdar, 2017] Gambäck, B. and Sikdar, U. K. (2017). Using convolutional neural networks to classify hate-speech. In *Proceedings of the first workshop on abusive language online*, pages 85–90.
- [13] [Grave et al., 2018] Grave, E., Bojanowski, P., Gupta, P., Joulin, A., and Mikolov, T. (2018). Learning Word Vectors for 157 Languages. In *Proceedings of the International Conference on Language Resources and Evaluation (LREC 2018)*.
- [14] [Grootendorst, 2020] Grootendorst, M. (2020). KeyBERT: Minimal keyword extraction with BERT.
- [15] [Iyyer et al., 2015] Iyyer, M., Manjunatha, V., Boyd-Graber, J., and Daumé III, H. (2015). Deep unordered composition rivals syntactic methods for text classification. In *Proceedings of the 53rd annual meeting of the association for computational linguistics and the 7th international joint conference on natural language processing (volume 1: Long papers)*, pages 1681–1691.
- [16] [Jha and Mamidi, 2017] Jha, A. and Mamidi, R. (2017). When does a compliment become sexist? analysis and classification of ambivalent sexism using twitter data. In *Proceedings of the second workshop on NLP and computational social science*, pages 7–16.
- [17] [Kralj Novak et al., 2021] Kralj Novak, P., Mozetič, I., and Ljubešić, N. (2021). Slovenian twitter hate speech dataset IM-SyPP-sl. Slovenian language resource repository CLARIN.SI.
- [18] [Kutuzov et al., 2017] Kutuzov, A., Fares, M., Oepen, S., and Veldal, E. (2017). Word vectors, reuse, and replicability: Towards a community repository of large-text resources. In *Proceedings of the 58th Conference on Simulation and Modelling*, pages 271–276. Linköping University Electronic Press.
- [19] [Lewandowska-Tomaszczyk et al., 2021] Lewandowska-Tomaszczyk, B., Žitnik, S., Baczkowska, A., Liebesking, C., Mitrović, J., and Oleskevišiene, G. V. (2021). Lod-connected offensive language ontology and tagset enrichment. In *Proceedings of the First Workshop on Sentiment Analysis & Linguistic Linked Data*, pages 1–16.
- [20] [Ljubešić et al., 2021] Ljubešić, N., Fišer, D., Erjavec, T., and Šulc, A. (2021). Offensive language dataset of croatian, english and slovenian comments FRENK 1.1. Slovenian language resource repository CLARIN.SI.
- [21] [Mandl et al., 2019] Mandl, T., Modha, S., Majumder, P., Patel, D., Dave, M., Mandla, C., and Patel, A. (2019). Overview of the hasoc track at fire 2019: Hate speech and offensive content identification in indo-european languages. In *Proceedings of the 11th forum for information retrieval evaluation*, pages 14–17.
- [22] [Martins et al., 2018] Martins, R., Gomes, M., Almeida, J. J., Novais, P., and Henriques, P. (2018). Hate speech classification in social media using emotional analysis. In *2018 7th Brazilian Conference on Intelligent Systems (BRACIS)*, pages 61–66. IEEE.
- [23] [Mikolov et al., 2013a] Mikolov, T., Chen, K., Corrado, G., and Dean, J. (2013a). Efficient estimation of word representations in vector space. *arXiv preprint arXiv:1301.3781*.
- [24] [Mikolov et al., 2013b] Mikolov, T., Sutskever, I., Chen, K., Corrado, G. S., and Dean, J. (2013b). Distributed Representations of Words and Phrases and their Compositionality. In Burges, C. J. C., Bottou, L., Welling, M., Ghahramani, Z., and Weinberger, K. Q., editors, *Advances in Neural Information Processing Systems*, volume 26. Curran Associates, Inc.
- [25] [OUP, 2021] OUP (2021). Lexico.com – Oxford University Press. [https://www.lexico.com/definition/hate\\_speech](https://www.lexico.com/definition/hate_speech). Accessed: 2021-09-01.
- [26] [Pennington et al., 2014] Pennington, J., Socher, R., and Manning, C. D. (2014). Glove: Global vectors for word representation. In *Empirical Methods in Natural Language Processing (EMNLP)*, pages 1532–1543.
- [27] [Risch et al., 2021] Risch, J., Schmidt, P., and Krestel, R. (2021). Data integration for toxic comment classification: Making more than 40 datasets easily accessible in one unified format. In *Proceedings of the 5th Workshop on Online Abuse and Harms (WOAH 2021)*, pages 157–163. Association for Computational Linguistics.
- [28] [Rizouli et al., 2019] Rizouli, M.-A., Wang, T., Ferraro, G., and Suominen, H. (2019). Transfer learning for hate speech detection in social media. *arXiv preprint arXiv:1906.03829*.
- [29] [Salminen et al., 2018] Salminen, J., Almerekhi, H., Milenković, M., Jung, S.-g., An, J., Kwak, H., and Jansen, B. (2018). Anatomy of Online Hate: Developing a Taxonomy and Machine Learning Models for Identifying and Classifying Hate in Online News Media. In *Proceedings of the International AAAI Conference on Web and Social Media*.
- [30] [Schmidt and Wiegand, 2017] Schmidt, A. and Wiegand, M. (2017). A survey on hate speech detection using natural language processing. In *Proceedings of the fifth international workshop on natural language processing for social media*, pages 1–10.
- [31] [Speer et al., 2017] Speer, R., Chin, J., and Havasi, C. (2017). ConceptNet 5.5: An open multilingual graph of general knowl-

- wledge. In *Thirty-first AAAI conference on artificial intelligence*, pages 4444–4451.
- [33] [Spertus, 1997] Spertus, E. (1997). Smokey: Automatic Recognition of Hostile Messages. In *Proceedings of the Fourteenth National Conference on Artificial Intelligence and Ninth Conference on Innovative Applications of Artificial Intelligence*, AAAI'97/IAAI'97, page 1058–1065. AAAI Press.
- [34] [Van der Maaten and Hinton, 2008] Van der Maaten, L. and Hinton, G. (2008). Visualizing data using t-sne. *Journal of machine learning research*, 9(11).
- [35] [Vaswani et al., 2017] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., and Polosukhin, I. (2017). Attention is all you need. *Advances in neural information processing systems*, 30.
- [36] [Waseem, 2016] Waseem, Z. (2016). Are you a racist or am i seeing things? annotator influence on hate speech detection on twitter. In *Proceedings of the first workshop on NLP and computational social science*, pages 138–142.
- [37] [Waseem and Hovy, 2016] Waseem, Z. and Hovy, D. (2016). Hateful Symbols or Hateful People? Predictive Features for Hate Speech Detection on Twitter. In *Proceedings of the NAACL Student Research Workshop*, pages 88–93, San Diego, California. Association for Computational Linguistics.
- [38] [Wulczyn et al., 2017] Wulczyn, E., Thain, N., and Dixon, L. (2017). Ex Machina: Personal Attacks Seen at Scale. In *Proceedings of the 26th International Conference on World Wide Web*, WWW '17, pages 1391–1399, Republic and Canton of Geneva, CHE. International World Wide Web Conferences Steering Committee.
- [39] [Xu et al., 2012] Xu, J.-M., Jun, K.-S., Zhu, X., and Bellmore, A. (2012). Learning from bullying traces in social media. In *Proceedings of the 2012 conference of the North American chapter of the association for computational linguistics: Human language technologies*, pages 656–666.

**Maša Kljun** is a Data Science Masters's student at the Faculty of Computer and Information Science, University of Ljubljana.

**Matija Teršek** is a Data Science Masters's student at the Faculty of Computer and Information Science, University of Ljubljana.

**Slavko Žitnik** is an assistant professor at the Faculty of Computer and Information Science, University of Ljubljana. His main research interests are information retrieval and information extraction. Specifically, he is trying to enrich the extracted data from text using parallel and iterative combination of entity extraction, relationship extraction and coreference resolution techniques. Furthermore, his research also focuses on data merging, redundancy elimination and ontologies.

# ► Strojna analiza tematik in sentimenta slovenskih novičarskih medijev

Jan Bajt, Marko Robnik Šikonja

Univerza v Ljubljani, Fakulteta za računalništvo in informatiko, Večna pot 113, 1000 Ljubljana  
janbajt@gmail.com, marko.robnik@fri.uni-lj.si

## Izvleček

V delu primerjamo slovenske novičarske medije s pomočjo analize tematik in sentimenta člankov. Analizirali smo različna stališča sedmih slovenskih medijev do specifičnih dogodkov oziroma tematik v letih 2019 in 2020. Tematike smo modelirali dvofazno z modelom LDA, s katerim smo v množici spletnih člankov poiskali nekaj posameznih tematik. Za nalogu zaznavanja sentimenta smo prilagodili velik vnaprej naučen slovenski maskirni jezikovni model SloBERTa in ga uporabili pri klasifikaciji izbranih člankov v enega izmed treh razredov (pozitivnega, nevtralnega ali negativnega). V množici izbranih tematik smo opazili precejšnje razlike med mediji v pogostosti in sentimentu poročanja.

**Ključne besede:** analiza sentimenta, latentna Dirichletova alokacija, modeliranje tematik, model BERT, obdelava naravnega jezika, slovenski novičarski mediji

## Abstract

We compare topics and sentiment in Slovenian news media. We analysed the sentiment of seven media concerning specific political events or topics in 2019 and 2020. We used two phases of LDA modelling to detect a number of specific topics. For the sentiment analysis task, we fine-tuned large pretrained Slovenian masked language model, SloBERTa, and used it to classify articles in one of three classes (positive, neutral or negative). In the set of selected topics, we observed considerable differences between media in frequency and sentiment of reporting.

**Keywords:** Sentiment analysis, latent Dirichlet allocation, topic modeling, model BERT, natural language processing, Slovenian news media

## 1 UVOD

Mediji s pisanjem o dogodkih in z mnenjskimi članki močno vplivajo na družbo in so tudi njen odraz. Ko gre za politične teme, mnogokrat pokažejo tudi ideološka prepričanja, ki jih zastopajo. V delu želimo z metodami procesiranja naravnega jezika poiskati razlike v pisanju slovenskih medijev o nekaj izbranih dogodkih oz. temah s primerjavo sentimenta člankov izbranih tematik. Podobna strojna analiza za slovenske medije še ne obstaja. Naš namen je objektivno analizirati slovenski novičarski medijski prostor in interpretirati razlike med posameznimi tematikami in mediji.

### 1.1 Obstojče raziskave na slovenščini

Področje zaznavanja sentimenta je pogosta naloga na področju obdelave naravnega jezika, vendar je bila večina raziskav narejenih za angleški jezik. V zadnjem času so najbolj uveljavljene rešitve z uporabo tehnologij, ki temeljijo na arhitekturi transformer [24]. Med tovrstne modele spada model BERT [7], iz katerega so razvili več različic (npr. RoBERTa [12], ALBERT [10] itd.), ki se uporabljajo za različne naloge predstavitev jezika. Za slovenski jezik so Bučar, Povh in Žnidarsič [4] opravili raziskavo o odkrivanju sentimenta v slovenskih člankih. V tej raziskavi so na množici slovenskih člankov [5] uporabili pet različnih klasifikatorjev (multinomski naivni Bayes, naivni

Bayes, metoda podpornih vektorjev, k-najbližjih sosedov in naključni gozdovi) in jih med seboj primerjali. Pelicon, Pranjić, Miljković, Škrlj in Pollak [18] so analizirali medjezikovne zaznave sentimenta v člankih. Razvili so klasifikacijski sistem, ki s podanim korpusom označenih člankov v slovenskem jeziku določi sentiment ne samo na slovenskih temveč tudi na drugih jezikih brez dodatnih učnih podatkov. Sistem temelji na večjezičnem modelu BERT, v raziskavi pa raziščejo tudi različne pristope za delo z dolgimi besedili. V nasprotju z naštetimi pristopi v našem delu za klasifikacijo sentimenta uporabimo trenutno najuspešnejši slovenski jezikovni model SloBERTa [22].

Za analizo tematik je razvitih kar nekaj modelov. Med najbolj poznanimi so verjetnostni modeli, med katere spadajo probabilitična latentna semantična analiza (pLSA) [9], latentna semantična analiza (LSA) [6] in latentna Dirichletova alokacija (LDA) [2].

Za slovenščino sta Logar Berginc in Ljubešić [14] opravila tematsko primerjavo podatkovnih množic Gigafida in slWaC. V množicah sta poiskala teme z metodo LDA, jih primerjala med seboj in izpostavila nekaj razlik med najdenimi temami obeh množic. Škrajnc in Pollak [21] sta analizirali in primerjali tematike med blogi moških in ženskih avtorjev. Za razliko od Logar Bohinc in Ljubešić sta razvili hierarhične ontologije, kar je omogočilo identifikacijo podtem za vsako izmed tem.

Sistematična analiza tematik v slovenskih medijih še ne obstaja. Razlike med poročanji slovenskih medijev so raziskali Martinc, Perger, Pelicon, Ulčar, Vezovnik in Pollak [17], ki so se osredotočili na temo LGBTIQ+. Raziskali so razlike v zaznanem sentimentu in uporabljenih besedah. V našem delu analiziramo široko množico tematik, vendar zaradi omejenega prostora poročamo o le nekaj ožjih tematikah (politika in epidemija COVID-19).

## 1.2 Novosti

V zbirkici člankov sedmih slovenskih večjih medijev smo najprej opravili analizo tematik in izbrali nekaj širših tem iz preteklih let. Znotraj teh tematik smo določili še podrobnejše teme. Za modeliranje tem smo uporabili statistični model latentne Dirichletove alokacije (LDA) [2], ki zaradi svoje razširjenosti ponuja tudi več vizualizacijskih orodij, ki so nam pomagala pri interpretaciji rezultatov. Za izbrane teme smo analizirali sentiment z modelom SloBERTa, ki smo ga predhodno prilagodili za zaznavanje tri ra-

zrednega sentimenta. Analiza je pokazala precejšnje razlike med posameznimi mediji, tako glede pogostosti poročanja o posameznih tematikah kot glede sentimenta pisanja o teh temah. Novosti našega prispevka so naslednje.

- Predlagamo dvonivojsko analizo tematik slovenskih medijev, ki omogoča boljšo interpretacijo in poimenovanje ožjih tem, kot če bi z enofazno analizo določili večjo število tematik, saj bi v tem primeru v veliki množici dobljenih tem težje določili specifične teme, ki jih želimo primerjati med mediji.
- Prvič na slovenskih člankih uporabimo model SloBERTa za analizo sentimenta na nivoju člankov. Model se pokaže kot uspešnejši v primerjavi z dosedanjimi poskusi z modelom SVM.
- Za razliko od dosedanjih večjih analiz sentimenta slovenskih medijev analiziramo trorazredni sentiment, za katerega menimo, da omogoča bolj objektivno analizo v primerjavi z binarnim sentimentom, saj je največ člankov v medijih sentimen-tno nevtralnih, nevtralni razred pa binarna analiza sentimenta na silo pripoji bodisi pozitivnemu bodisi negativnemu razredu.
- V naši analizi uporabimo doslej največjo podatkovno množico spletnih novic in medijev, kar daje izsledkom večjo težo.
- Opravljena analiza tematik v kombinaciji z analizo sentimenta izbranih tem pokaže precejšnje razlike med mediji tako glede pogostosti pisanja o posameznih temah kot tudi glede sentimenta.

## 1.3 Struktura prispevka

Delo smo razdelili na pet razdelkov. V drugem razdelku najprej predstavimo uporabljene tehnologije za detekcijo tematik in analizo sentimenta. V tretjem razdelku opišemo analizirano zbirko spletnih člankov in učno množico SentiNews, ki smo jo uporabili za učenje sentimentega klasifikatorja na podlagi modela SloBERTa. Naš pristop k modeliranju tem in analizi sentimenta predstavimo v četrtem razdelku. Peti razdelek vsebuje ovrednotenje razvitih modelov in rezultate modeliranja tematik in sentimenta. Zaključke in ideje za nadaljnjo delo zapišemo v šestem razdelku.

## 2 TEHNOLOGIJE ZA ANALIZO TEMATIK IN SENTIMENTA

V tem razdelku predstavimo uporabljene tehnologije. Zaradi razpoložljivosti dobrih orodij, s katerimi

lahko interpretiramo rezultate, smo za modeliranje tematik izbrali latentno Dirichletovo alokacijo, ki jo predstavimo v razdelku 4.1.3. Za interpretacijo rezultatov smo izbrali vizualizacijsko orodje LDAvis, katerega zmožnosti opišemo v razdelku 2.2. Za klasifikacijo sentimenta smo uporabili slovenski model SloBERTa, ki ga opišemo v razdelku 2.3.

## 2.1 Analiza tem z latentno Dirichletovo alokacijo

Model latentne Dirichletove alokacije (LDA) [2] je verjetno najpogosteje uporabljen pristop za modeliranje tem v besedilih. Modeliranje tem je metoda nenadzorovanega učenja, kjer v korpusu besedil poiščemo potencialno skrite ali abstraktne teme [1]. Poleg modela LDA sta za modeliranje tem pogosto uporabljeni še pristopa LSA (angl. Latent Semantic Analysis) [8] in pLSA (angl. Probabilistic Latent Semantic Analysis) [9].

Model LDA, katerega delovanje prikazuje slika 1, predpostavlja, da je v korpusu besedil določeno število tem (na sliki so štiri teme: Tema 1, Tema 2, Tema 3, Tema 4). Vsaka izmed tem vsebuje verjetnostno porazdelitev besed, ki se v temi nahajajo (npr. za Temo 1: 5% Beseda 1, 4 % Beseda 2, 2,5 % Beseda 3 itn.). Vsak dokument je zgrajen iz naključne mešanice tem v korpusu (npr. 60% Tema 1, 20 % Tema 2, 15% Tema 3 in 5 % Tema 4). Za tvorjenje novega dokumenta verjetnostni model predpostavi, da iz vseh tem naključno izberemo določeno število besed (iz Tema 1 60% vseh besed v dokumentu, iz Tema 2 20 % itd.).

V realnosti je proces ravno obraten. Na sliki 2 je grafični prikaz delovanja modela LDA. Model na vho-

du prejme število tem  $K$  in korpus besedil z  $M$  dokumenti in  $N$  besedami v posameznem besedilu. Na nivoju dokumenta (notranji okvir na sliki 2) model vsaki besedi  $w$  naključno določi temo  $z$ , s tem pa pridobimo porazdelitev tem  $\theta$  v posameznem dokumentu.

Model ima še dva hiperparametra,  $\alpha$  in  $\beta$ , ki sta parametra Dirichletove porazdelitve. LDA namreč predvideva, da sta porazdelitvi tem v besedilu in besed v temah Dirichletovi. Hiperparameter  $\alpha$  vpliva na porazdelitev tem v posameznih dokumentih,  $\beta$  pa na porazdelitev besed v posameznih temah. Večja vrednost parametra  $\alpha$  pomeni, da bodo dokumenti mešanica večjega števila tem, večja vrednost parametra  $\beta$  pa pomeni, da bodo teme mešanica večjega števila besed. Obratno velja za majhne vrednosti obeh parametrov.

Iz korpusa dokumentov in števila tem model LDA izračuna dva tipa distribucij:

- distribucije besed za vsako izmed zaznanih tem in
- distribucije tem, ki se pojavljajo v posameznem dokumentu iz korpusa dokumentov.

Izračunan model lahko uporabimo za analizo izbranega korpusa ali za klasifikacijo novih dokumentov, ki niso del izbranega korpusa. Pri analizi izbranega korpusa dobimo pregled tem, ki jih vsebuje, interpretiramo jih lahko z besedami, ki jih posamezne teme vsebujejo. Pri klasifikaciji novih dokumentov model uporabi zgolj besede iz učnega korpusa, ne upošteva pa besed iz dokumentov, ki jih ni v naučnem modelu. Za vsak nov dokument dobimo verjetnostno porazdelitev tem tega dokumenta.

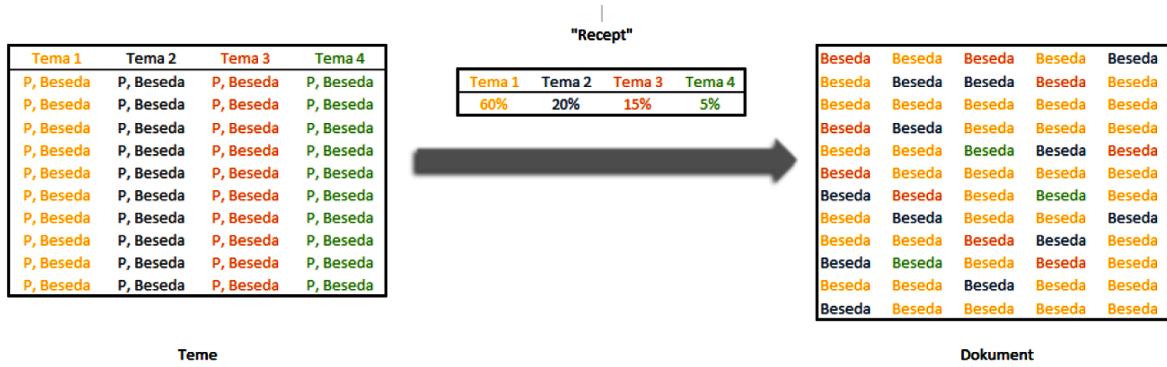


Figure 1: Primer generiranja dokumenta z verjetnostnim modelom, ki ga predpostavlja LDA.

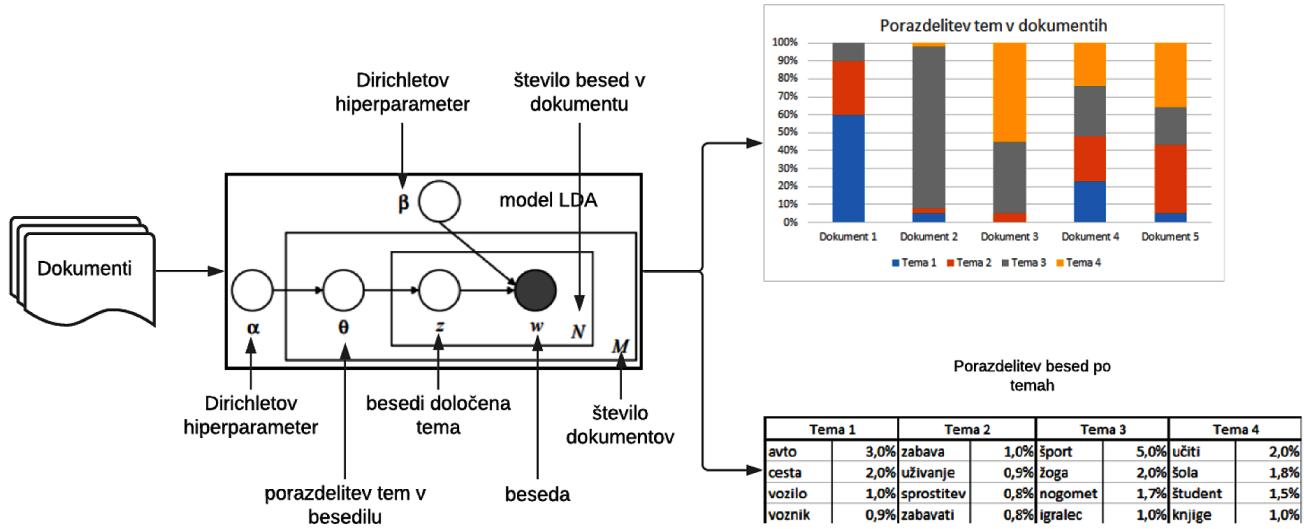


Figure 2: Shema delovanja modela LDA.

## 2.2 Vizualizacija tem z orodjem LDavis

LDavis [20] je orodje, ki omogoča interaktivno vizualizacijo tem, pridobljenih z modelom LDA. Z orodjem imamo pregled nad vsemi temami in razlikami med njimi, kot tudi pregled besed povezanih z izbrano temo, kot ilustrira slika 3. Poleg vizualizacije tem orodje vpelje še mero primernosti besed (angl. relevance) za vsako besedo znotraj teme.

Vizualizacija modela je razdeljena na dva dela:

- globalen pregled vseh tematik (leva polovica slike 3) in
- pregled najpogostejših besed znotraj izbrane teme (desna polovica slike 3).

Z analizo globalnega prikaza vseh tem lahko ugotovimo, kako pogosto se tema v besedilu nahaja in kako so teme med seboj povezane. Posamezne teme so predstavljene s krogi v dvodimensionalnem prostoru. Večji krogi pomenijo, da je tema bolj razširjena med opazovanimi besedili, razdalja med krogi pa pove, kako podobne so si teme. Dobro interpretabilen model LDA je predstavljen z velikimi krogi, ki se med sabo ne prekrivajo in so razpršeni po celotnem prostoru.

V desni polovici vizualizacije na sliki 3 so v obliki stolpčnega diagrama predstavljene najprimernejše besede za interpretacijo izbrane teme. Modri del posameznega stolpca predstavlja pogostost besede v celotnem korpusu besedil, rdeči del pa predstavlja pogostost besede v izbrani temi.

Pomemben del orodja je mera primernosti besede  $\lambda$  za določeno temo, ki lahko zavzame vrednosti med 0 in 1. Vrednost  $\lambda = 1$  pomeni, da so besede v desni polovici vizualizacije razvrščene po pogostosti besed znotraj izbrane teme (po velikosti rdečega dela stolpca). Nižja kot je vrednost  $\lambda$ , večjo pozornost dajemo besedam, ki se bolj izključno pojavljajo v izbrani temi. Sievert in Shirley [20] predlagata nastavitev  $\lambda$  na vrednost 0.6. V interaktivni vizualizaciji lahko vrednost  $\lambda$  prilagajamo in s tem sprememjamо vrstni red besed v desni polovici vizualizacije, kar nam pomaga pri interpretaciji modela.

## 2.3 Klasifikacija sentimeta s prilagajanjem modela SloBERTa

Model BERT (angl. Bidirectional Encoder Representations from Transformers) [7] je jezikovni model, ki pri učenju predstavitev besed upošteva kontekst vseh besed v stavku (tako pred kot za opazovano besedo). S prilagajanjem naučenega modela (angl. fine tuning) dobimo trenutno najuspešnejše modele za različne naloge na področju obdelave naravnega jezika, tudi za klasifikacijo sentimeta, ki jo uporabimo v našem delu. Model BERT sestavlja kodirniki nevronске arhitekture transformer [24], ki uporablja mehanizem samopozornosti (angl. self-attention). Osnovna inačica modela BERT (BERT base) vsebuje 12 slojev kodirnikov, kjer ima vsaka plast 768 skritih nevronov. Model ima 12 glavnih pozornosti (angl. attention head) in skupno 110 milijonov parametrov.

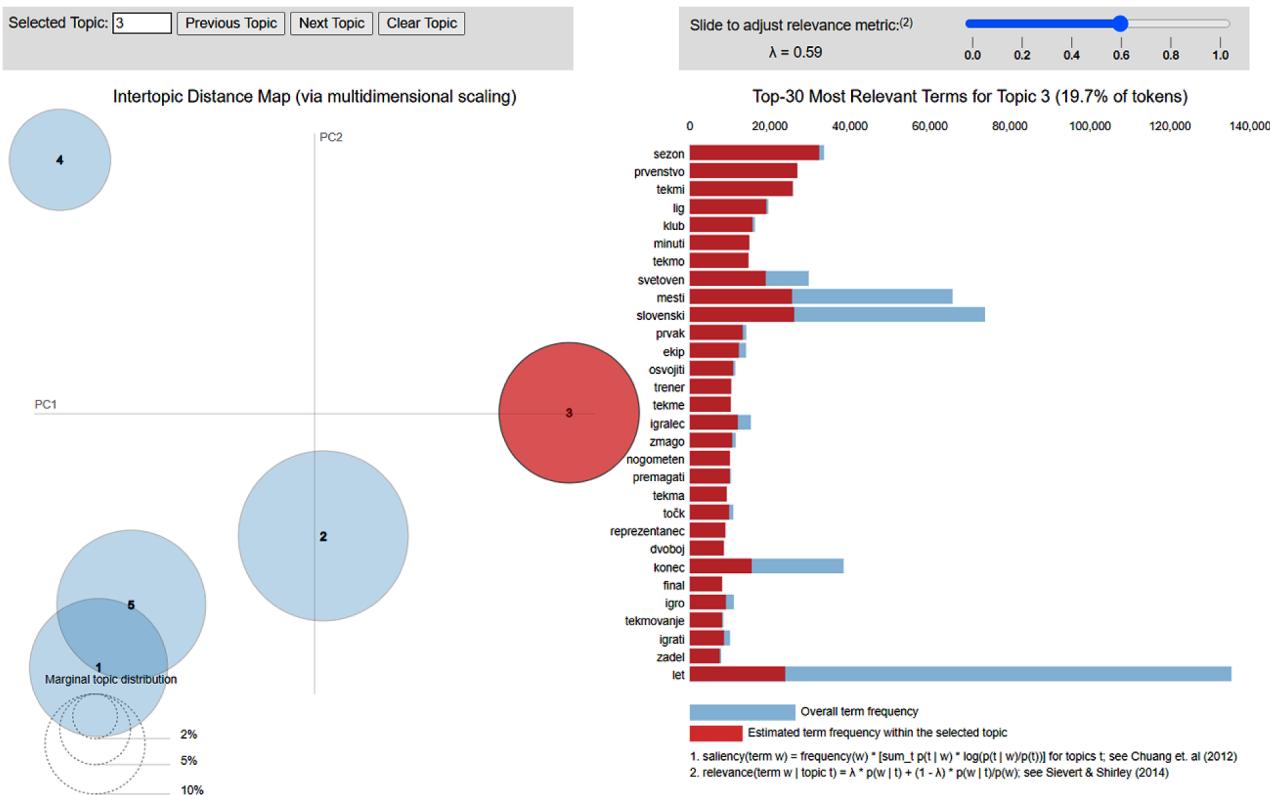


Figure 3: Vizualizacija tem z orodjem LDAvis. Na desni je prikazana interpretacija teme 3 (rdeč krog na levi strani), ki zadeva temo o nogometu.

Za učenje modela BERT se uporabita dve različni nalogi in velika množica neoznačenih podatkov. Prva naloga je maskirni jezikovni model (angl. masked language model), kjer je 'zamaskiranih' naključnih 15% besed oz. vhodnih žetonov (angl. tokens). Model napoveduje zamaskirane besede, s tem pa se nauči konteksta zamaskiranih besed. Druga naloga je predvidevanje naslednje povedi, kjer model prav tako učimo na neoznačenih podatkih. Na vhod model dobi zaporedje dveh povedi, ugotoviti pa mora ali druga poved sledi prvi ali ne. S tem se model uči smiselnih povezav na nivoju povedi. Naučen model lahko prilagodimo za uporabo na specifičnih nalogah obdelave naravnega jezika, kot so odkrivjanje sentimenta, povzemanje besedil, odgovarjanje na vprašanja ipd. Pri prilaganju modela za določeno nalogo uporabimo označene podatke, primerne za nalogo, ki jo izvajamo, modelu pa dodamo nov izhodni sloj.

Model RoBERTa [12] (angl. A Robustly Optimized BERT Pretraining Approach) je izboljšava modela BERT, ki je uporabila veliko večjo podatkovno množico in daljši čas učenja. RoBERTa uporablja večje velikosti učnih paketov (angl. batch size), v fazi učenja

pa ne uporablja naloge predvidevanja naslednjih povedi. Spremenjen je tudi način maskiranja besed. Pri modelu BERT so besede maskirane statično (samo enkrat, na začetku učenja), model RoBERTa pa besede maskira dinamično, kar pomeni, da se maskiranje izvede posebej za vsako iteracijo učenja.

Model SloBERTa [23] je enojezičen slovenski model RoBERTa, ki sledi arhitekturi in učenju franco-skega modela CamemBERT [16]. Naučili so ga na korpusu besedil, ki vsebuje 3.47 milijard besed, njegov slovar pa vsebuje 32.000 žetonov.

### 3 UČNI PODATKI

Za opravljenou analizo smo potrebovali dve zbirkli podatkov. Zbirko spletnih novic, ki smo jo analizirali glede tem in sentimenta, opišemo v razdelku 3.1, učno množico, s katero smo naučili klasifikator sentimenta, pa v razdelku 3.2.

#### 3.1 Zbirka spletnih člankov iz storitve Event Registry

Dostop do velike množice člankov s slovenskih novičarskih medijev nam je omogočil spletni servis Event Registry [11]. Pridobljena množica vsebuje 2.2 milij-

jona člankov v formatu JSON, objavljenih med 1. 1. 2014 in 31. 12. 2020. Posamezen članek poleg besedila vsebuje še meta podatke, kot so naslov, datum, čas objave, spletni naslov in informacije o viru članka.

Za potrebe naše analize smo za vsak članek izluščili njegovo vsebino, naslov in medij. Zaradi omejenega prostora smo uporabili članke iz let 2019 in 2020 za nekaj največjih slovenskih medijev (Dnevnik, 24ur.com, RTV Slovenija in Siol.net) in nekaj medijev iz desnega političnega pola, za katere smo pričakovali večje razlike v poročanju (Nova24TV, Tednik Demokracija in Portal Politikis).

V tabeli 1 so prikazane povprečne dolžine člankov posameznih medijev v posameznem letu. Iz člankov izbranih medijev smo odstranili tiste z manj kot 25 besedami in duplike, ostale članke pa smo uporabili pri zaznavanju tematik. Končno število uporabljenih člankov izbranih medijev v posameznem letu je prikazano v tabeli 2.

Table 1: Povprečna dolžina člankov v številu besed za posamezne medije v analiziranih letih 2019 in 2020.

Medij	2019	2020
RTV Slovenija	403	452
Siol.net	410	405
24ur.com	202	214
Svet24	340	346
Tednik Demokracija	424	463
Nova24TV	523	546
Portal Politikis	353	356
Dnevnik	253	253
Povprečje	351	373

Table 2: Število uporabljenih člankov izbranih medijev v letih 2019 in 2020.

Medij	2019	2020
RTV Slovenija	28.948	33.466
Siol.net	25.871	23.863
24ur.com	18.831	21.281
Tednik Demokracija	8.869	8.213
Nova24TV	6.524	7.170
Portal Politikis	6.142	5.321
Dnevnik	20.990	15.304
Skupaj	116.175	114.618

### 3.2 Učna množica za analizo sentimenta SentiNews

Za učenje sentimenta smo uporabili podatkovno množico slovenskih člankov SentiNews [3, 5]. Ce-

lotna podatkovna zbirka je sestavljena iz več kot 250.000 člankov s politično, poslovno, ekonomsko in finančno vsebino petih slovenskih spletnih medijskih virov (24ur, Dnevnik, Finance, RTV Slovenija in Žurnal24). V tej zbirki je bilo 10.427 dokumentov ročno označenih s sentimentom, merjenim s petstopenjsko Likertovo lestvico (1 – zelo negativno, 2 – negativno, 3 – nevtralno 4 – pozitivno in 5 – zalo pozitivno). Dokumente je anotiralo od 2 do 6 anotatorjev, povprečne vrednosti ocen pa so pretvorjene v eno izmed končnih oznak po naslednjih merilih [5]:

- razred »negative«, če je povprečje ocen manjše ali enako 2.4,
- razred »neutral«, če je povprečje ocen med 2.4 in 3.6,
- razred »positive«, če je povprečje ocen večje ali enako 3.6.

Članki so označeni s sentimentom na treh nivojih: nivo stavka, odstavka in dokumenta. V naši raziskavi smo uporabili članke, ki so s sentimentom označeni na nivoju celotnega dokumenta. Izmed skupno 10.427 anotiranih člankov je 5.425 člankov označenih s nevtralnim sentimentom, 3.337 z negativnim in 1.665 z pozitivnim sentimentom. Povprečno število besed v teh člankih je 309.

## 4 METODOLOGIJA ANALIZE TEMATIK IN SENTIMENTA

V tem razdelku opisemo uporabo tehnologij, opisanih v razdelku 2, za namen analize tem (razdelek 4.1) in določitve sentimenta novic posameznih medijev v izbranih temah (razdelek 4.2). Shema celotnega postopka je ilustrirana na sliki 4.

### 4.1 Modeliranje tem

S postopki modeliranjem tem želimo v množici slovenskih člankov odkriti različne teme, o katerih pišejo slovenski mediji. Za te teme želimo, da so dovolj podrobne, da bomo lahko na njih odkrivali razlike v sentimentu in opravili primerjavo različnih medijev. Primer tem, ki bi jih lahko odkrili in analizirali je npr. cepljenje proti COVID-19 ali menjava vlade v letu 2020. Za pridobivanje tako podrobnih tem bi lahko zgradili model LDA za veliko število tem (100 in več), vendar bi si s tem otežili interpretacijo pridobljenih tem. Namesto tega smo se modeliranja tem lotili dvofazno. Najprej smo zgradili model LDA na celotnem korpusu besedil za majhno število širših tem (okrog 10), ki jih je hitreje in lažje interpretirati.

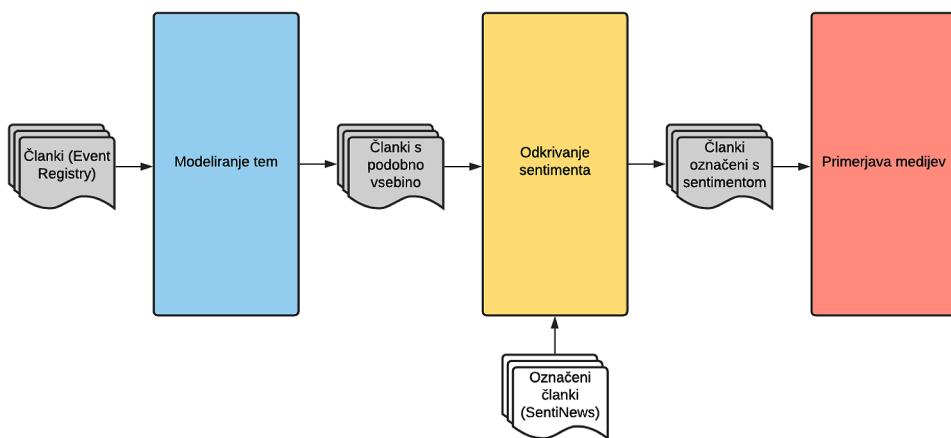


Figure 4: **Shema uporabljene metodologije za analizo člankov.**

Po opravljeni interpretaciji prvostopenjskega modela smo za nadaljnjo obravnavo izbrali le dve širši temi o politiki in epidemiji COVID-19. Iz množice dokumentov smo tako izbrali le tiste, ki imajo verjetnost, da pripadajo širši temi višjo od določene meje (vsaj 0.55). Na tako pridobljeni novi množici člankov smo zgradili nov podrobnejši model LDA. Na koncu smo iz nekaj drugostopenjskih tem znotraj širših tem o politiki in epidemiji COVID-19 izluščili najbolj tipične članke in jih uporabili za analizo sentimenta in primerjavo medijev. Celoten postopek modeliranje tem sestavljajo naslednji koraki, ki so prikazani tudi na sliki 5:

1. Predobdelava člankov (razdelek 4.1.1).
2. Priprava podatkov za računanje prvostopenjskega modela LDA (razdelek 4.1.2).
3. Konstrukcija modela LDA (razdelek 4.1.3).

4. Interpretacija prvostopenjskega modela LDA (razdelek 4.1.4).
5. Izbor teme in člankov za računanje podrobnejšega drugostopenjskega modela.
6. Ponovimo 2., 3. in 4. korak za modeliranje podtem izbranih širših tem.
7. Izbor podtem in člankov za nadaljnjo analizo sentimenta (razdelek 4.1.5).

### 3.0.1 Predobdelava člankov

V predobdelavi podatkov za odkrivanju tematik iz besedil izluščimo za nas pomembne dele. Postopek na besedilih člankov izvede naslednje korake, ki jih shematsko prikazuje slika 6.

1. Filtriranje člankov.
2. Tokenizacija.
3. Pretvorba besed v male črke.

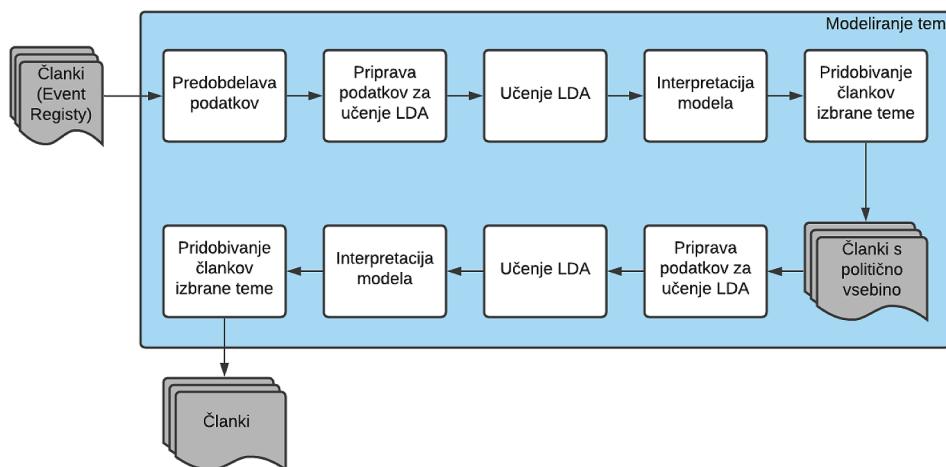


Figure 5: **Dvostopenjski postopek modeliranja tem za pridobivanje člankov določene ožje teme, ki jo analiziramo glede sentimenta.**

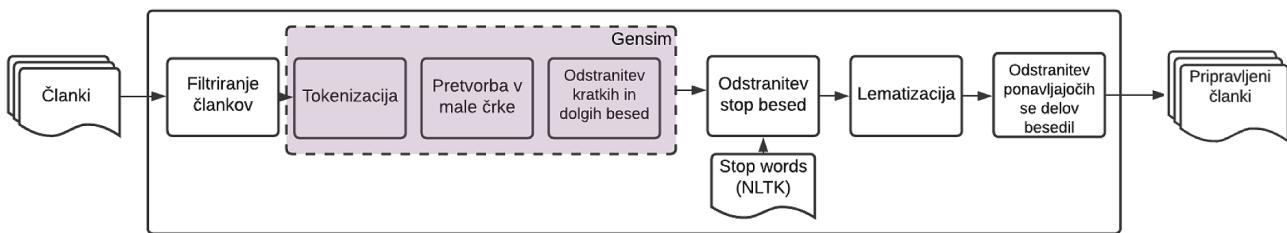


Figure 6: Proses predobdelave podatkov za analizo tematik.

4. Odstranitev besed krajsih oz. daljših od določene dolžine.
5. Odstranitev nepomembnih besed (angl. stop-words).
6. Lematizacija.
7. Odstranitev ponavljajočih se delov besedil.

V prvem koraku smo članke filtrirali, kar pomeni, da smo odstranili vse članke, ki so krajsi od določene števila besed, in vse podvojene članke, t.j. članke z identičnimi naslovi. Pri odstranjevanju duplikatov smo v tem koraku odstranili zgolj članke s popolnoma identičnimi naslovi, ne pa tudi člankov, kjer je v naslovu spremenjena zgolj posamezna beseda, je pa očitno, da gre za enako vsebino članka.

Naslednje tri korake predobdelave smo opravili s pomočjo metode *simple\_preprocess* iz knjižnice *Gensim* [19]. Metoda besedilo razdeli na posamezne besede (tokenizacija), jih pretvorji v male črke in odstrani vse besede, ki so kraje oz. dalje od določene dolžine.

Iz preostalih besed odstranimo še t.i. *stop besede* (angl. stop words), ki nimajo posebnega pomena v povedih (npr. vezniki, zaimki, imena mesecev itn.). Seznam stop besed za slovenski jezik smo pridobili iz knjižnice *NLTK* [15]. Vse preostale besede smo pretvorili v njihove leme (osnovne oblike). Za lematizacijo slovenskih besed smo uporabili orodje *Classla* [13].

V zadnjem koraku smo pregledali dobljene članke posameznih medijev in pri določenih medijih opazili ponavljajoče se dele besedil, ki smo jih odstranili. Pri več medijih se je v člankih velikokrat pojavljala beseda »foto«, ki je bila v spletni obliki članka del naslova priloženih fotografij. Odstranili smo tudi oznake virov, npr. 'reuters', 'getty images', 'urbanec' in 'sportid', ki predstavljajo vir fotografij. Pri mediju 24ur.com smo odstranili ponavljajoč se začetni del besedila, ki od uporabnika zahteva omogočenje

piškotkov spletnih strani. Iz člankov Siol.net Novice smo odstranili ponavljajoč se začetni del besedila, ki se je nanašal na t.i. *termometer*, ki bralcu članka razloži vlogo le-tega pri poročanju o popularnosti članka. Pri ostalih medijih večjih ponavljajočih se delov na začetku člankov nismo opazili.

### 3.0.2 Priprava n-gramov za model LDA

S postopkom predobdelave podatkov smo iz člankov izluščili posamezne besede, ki nam lahko nekaj povedo o temah člankov. V člankih se določene besede večkrat pojavljajo skupaj (npr. Marjan Šarec, Janez Janša, državni zbor itd.), kar lahko pomaga pri interpretaciji tem. V naslednjem koraku smo zato v člankih zaznali pogoste dvojice besed (bigrame) in pogoste trojice besed (trigrame). Knjižnica *Gensim* [19] ponuja model za avtomatsko zaznavanje pogostih besednih zvez imenovan *Phrases*. Zaznane bigrame in trigrame smo pretvorili v en sam niz besed ločenih s podčrtajem (npr. državni\_zbor) in jih dodali v seznam besed predprocesiranih člankov. Pri tem nismo upoštevali tistih bigramov in trigramov, ki se pojavijo v manj kot 15 člankih in tistih, ki imajo vrednost *threshold*<sup>1</sup> nižjo od 100.

Iz predobledanih člankov smo pridobili podatke, ki jih potrebujemo za učenje modela LDA s knjižnico *Gensim* [19]. Ta na vhodu sprejme za vsak članek t.i. vrečo besed (angl. bag of words) in slovar besed (angl. dictionary) za celoten korpus besedil. Slovar besed vsebuje vse unikatne besede iz korpusa predobdelanih besedil, za vsako od besed pa določi unikatno identifikacijsko število (id). S pomočjo slovarja knjižnice *Gensim* tvorimo vrečo besed za vsak članek v korpusu z uporabo metode *doc2bow*.

S tem imamo pripravljen slovar besed in korpus člankov predstavljenih z vrečami besed in lahko začnemo z učenjem modela LDA.

<sup>1</sup> Podrobnosti o parametru *threshold* so predstavljene v dokumentaciji orodja *Gensim* na <https://radimrehurek.com/gensim/models/phrases.html#gensim.models.phrases.Phrases>.

### 3.0.3 Izgradnja modela LDA

Delovanje modela LDA smo razložili v razdelku 2.1. Implementacija modela LDA v knjižnici *Gensim* na vhodu sprejme število tem, ki jih želimo odkriti v besedilu, slovar besed in korpus člankov v formatu vrečje besed, katerih pripravo smo opisali v razdelkih 4.1.1 in 4.1.2. Glavno merilo evalvacije modela LDA je smiselnost in interpretabilnost tem, zato smo izračunali več modelov z različnim številom tematik. Izračunane modele smo poizkusili interpretirati in za nadaljevanje postopka izbrali subjektivno najbolj interpretabilen in smiseln model.

### 3.0.4 Interpretacija tem modela LDA

Pri interpretacijah modelov LDA smo si pomagali z več pripomočki. Uporabili smo najpogosteješ besede posameznih tem, poleg tega pa še vizualizacijo modela LDA z orodjem pyLDAvis [20]. Pri interpretaciji je pomembna mera primernosti besed, katere večje vrednosti dajejo prednost besedam, ki pripadajo opazovani temi v večji meri kot drugim temam. Na ta način tematik ne interpretiramo le na podlagi najpogostejših besed ampak uporabimo tudi besede, ki so najbolj primerne za opazovano temo.

Za razumevanje širšega konteksta smo si pri interpretaciji modela LDA pomagali tudi z naslovi člankov. Vsakemu članku smo najprej določili temo, ki ji pripada v največji meri (največja verjetnost). Članke smo nato združili po temah in za vsako temo izbrali 20-30 člankov, ki najbolje predstavljajo posamezno temo (imajo najvišjo verjetnost, da pripadajo temi). Iz teh člankov smo izluščili naslove in jih uporabili pri interpretaciji.

V postopku interpretacije teme poimenujemo s pomočjo treh elementov, ki jih prikazuje slika 7:

- najpogosteje oz. najprimernejše besede določene teme,

- vizualizacija z orodjem pyLDAvis,
- naslovi člankov.

### 3.0.5 Izbor člankov za nadaljnjo analizo

Ko smo v analizi drugostopenjskega modela LDA določili in izbrali podrobnejše teme, moramo iz njih izbrati članke, ki jih bomo uporabili pri nadaljnji analizi sentimenta. Pri tem želimo izbor tematsko homogene množice člankov, ki bo omogočala smiselno primerjavo med mediji. To dosežemo tako, da iz vsake izbrane teme, izberemo članke z dovolj visoko verjetnostjo pripadnosti temi. Prag verjetnosti je lahko med posameznimi temami različen, zato smo preizkusili različne vrednosti verjetnosti in pri vsaki primerjali še naslove člankov, ki dosegajo prag.

## 4.2 Analiza sentimenta

Analiza sentimenta je sestavljena iz dveh faz. Najprej na označenih podatkih naučimo napovedni model za sentiment dokumentov, čemur sledi klasifikacija člankov, ki smo jih izbrali v razdelku 4.1.5.

Kot napovedni model smo uporabili vnaprej naučen maskirni jezikovni model SloBERTa [22], ki smo ga podrobnejše opisali v razdelku 2.3. Model smo prilagodili za napovedovanje sentimenta z uporabo učne množice SentiNews [5], ki smo jo opisali v razdelku 3.2. Model SloBERTa smo prilagajali s pomočjo knjižnice *transformers* [25]. Osnovni model je bil naučen za nalogu napovedovanja maskiranih besed, zato smo iz modela odstranili zadnji sloj, ki je namenjen tej nalogi, in mu dodali dva nova sloja. Prvi dodani sloj je linearen s 768 nevroni, ki smo mu dodali še opuščanje nevronov (angl. dropout). Kot zadnji sloj smo dodali tri nevrone, vsakega za eno izmed oznak sentimenta (pozitivno, negativno in neutralno).

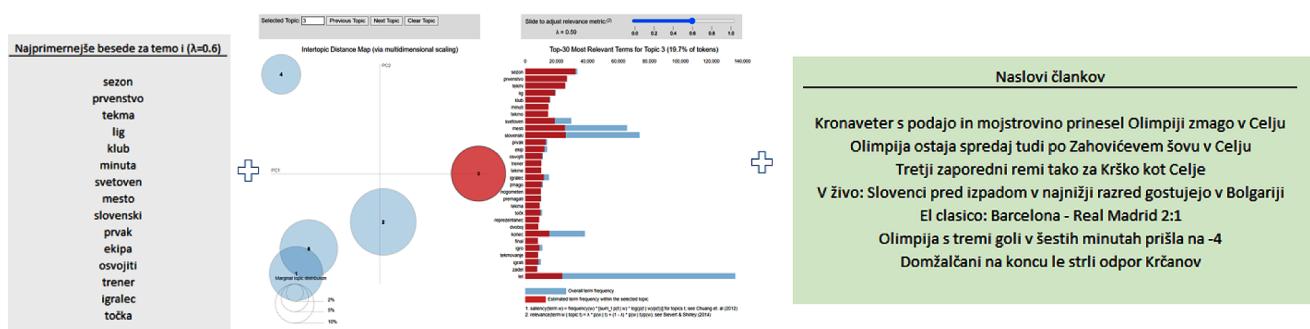


Figure 7: Informacije, ki jih uporabimo pri interpretacije in poimenovanju posamezne teme: najprimernejše besede (levo), vizualizacija z orodjem LDAvis (sredina) in naslovi člankov (desno).

Pred prilagajanjem modela smo pripravili vhodne podatke. Model lahko na vhodu sprejme največ 512 žetonov, zato smo predolge članke skrajšali, krajše pa podaljšali s posebnimi žetoni *pad\_token*. S tem smo dobili enako dolge predstavitve vseh člankov. Postopek smo izvedli s tokenizatorjem modela SloBERTa, ki pripravi podatke v primerinem formatu za učenje:

1. 'input\_ids': seznam unikatnih id-jev za vsako izmed besed v članku
2. 'attention\_mask': seznam ničel in enic, kjer mesta z ničlami predstavljajo *pad\_token*.

Za učenje modela smo uporabili okolje Google Colaboratory, ki ponuja brezplačno uporabo GPU z omejeno rabi spomina. Ta nam je dovoljevala velikosti paketov podatkov (angl. batch size) največ 8 za zaporedja žetonov dolžine 512. Podatke smo razdelili na učno, validacijsko in testno množico, kjer 80% podatkov predstavljajo učni podatki, po 10% pa validacijski in testni podatki. Izpopolnjevanje modela je potekalo 6 epoch; takrat se klasifikacijska točnost na validacijski množici ni več izboljševala in je dosegla najvišjo vrednost 70%.

Za zanesljivo interpretacijo rezultatov naše analize je nujno uporabiti kakovosten napovedni model za analizo sentimenta, zato smo prilagojen model SloBERTa pred dejansko uporabo ovrednotili. Poleg klasifikacijske točnosti, ki je dosegla 70% na testni množici, smo za ocenjevanje modela uporabili še mere točnost, priklic in  $F_1$ . Klasifikacijska točnost predstavlja delež pravilno napovedanih vseh primerov. Točnost, priklic in  $F_1$  so namenjene za ocenjevanje klasifikatorjev v dvorazrednih problemih. V večrazrednih problemih enega od razredov izberemo kot pozitivnega, ostali razredi skupaj pa predstavljajo negativni razred. Točnost predstavlja delež pravilno klasificiranih primerov med napovedanimi pozitivnimi primeri, priklic pa nam pove delež pravilno klasificiranih primerov dejanskega pozitivnega razreda. Meri točnost in priklic uporabimo za izračun mere  $F_1$ :

$$F_1 = \frac{2 \cdot \text{točnost} \cdot \text{priklic}}{\text{točnost} + \text{priklic}}$$

Podrobnejši rezultati napovednega modela so prikazani v tabeli 3.

Table 3: Rezultati napovednega modela za zaznavanje sentimeta SloBERTa na testni množici SentiNews.

razred	točnost	priklic	$F_1$	št. primerov
negativni	0,67	0,72	0,70	331
nevtralni	0,75	0,69	0,72	558
pozitivni	0,64	0,72	0,68	154
povprečje	0,69	0,71	0,70	1043
uteženo povprečje	0,71	0,70	0,70	1043

Model ima v primerjavi s podobnimi modeli BERT, učenimi na binarnem sentimentu angleških člankov [7, 10], nižjo točnost, kar je posledica več razlogov. Ker smo bili omejeni z delovnim spominom v okolju Google Colaboratory, smo model učili z dokaj majhnimi velikostmi paketov. Slabost modela SloBERTa pri napovedovanju sentimeta celotnih člankov je tudi v omejeni dolžini vhoda v model (512 žetonov), s krajšanjem članka pa izgubljamo informacije. Tretji razlog za nižjo uspešnost modela v primerjavi z angleškimi je tudi v trirazredni klasifikaciji sentimeta, ki je težji problem kot binarna klasifikacija. Menimo, da je uporaba trorazrednega sentimeta zaradi objektivnosti analize bolj smiselna od binarne, saj večina člankov spada prav v tretji, nevtralni razred.

Tako kot Bučar, Povh in Žnidaršič [4] smo tudi mi preizkusili klasifikator SVM (angl. support vector machine), ki se je pri zaznavanju binarnega sentimeta izkazal za dokaj uspešnega (85%). Za učenje sentimeta s tremi možnimi oznakami smo z modelom SVM dobili klasifikacijsko točnost le okrog 60%.

Naučeni napovedni model smo uporabili na člankih iz razdelka 4.1.5, ki smo jih pridobili s procesom modeliranja tematik, in jim določili sentiment. Rezultati modeliranja tem in napovedan sentiment predstavljajo podatke, s pomočjo katerih smo ovrednotili celoten postopek in interpretirali rezultate, kar opisemo v 5. poglavju.

## 5 INTERPRETACIJA REZULTATOV

V tem razdelku predstavimo rezultate analize tematik, njihovo interpretacijo in primerjamo različne medije. Analizo smo izvedli za leti 2019 in 2020, kjer smo za vsako leto posebej odkrili teme, o katerih pišejo članki, in primerjali odnos medijev do zaznanih tem.

Ker smo želeli ugotoviti, kakšne razlike je zmožna zaznati predstavljena metodologija, smo izbrali štiri osrednje medije (MMC RTV Slovenija, 24ur.com, Siol.

net Novice in Dnevnik) in tri desno usmerjene medije (Nova24TV, Tednik Demokracija in Portal Politikis). Z metodami opisanimi v 4. poglavju želimo poiskati razlike v opredelitvah posameznih medijev do nekaterih tem med tema dvema skupinama medijev.

V razdelku 5.1 predstavimo primerjavo pokritosti posameznih širših tem med različnimi mediji, v razdelku 5.2 pa ožjih podtem. V razdelku 5.3 predstavimo še primerjavo med mediji glede uporabljenega sentimenta pri pisanju o posameznih ožjih temah.

## 5.1 Rezultati modeliranja splošnih tem

Nekaj statistik o podatkih uporabljenih pri modeliranju splošnih tem z modelom LDA smo za obe analizirani leti zbrali v tabeli 4.

Table 4: Podatki o učni množici za pripravo modela LDA za splošne teme.

	2019	2020
število splošnih tem	8	10
št. člankov za učenje modela	94.640	93.914
št. besed v slovarju	66.653	64.051

Razlike med mediji smo opazili že pri modeliranju splošnih tem. Za vsako leto smo naučili model LDA na člankih vseh vključenih medijev in opazili, da model LDA odkrije eno ali več tem, ki jo sesta-

vljajo večinoma članki iz desnih medijev. Na sliki 8 je prikazana porazdelitev tematik, ki jih pokrivajo različni mediji. Opazimo, da je večina člankov desnih medijev dodeljenih ločeni temi o politiki, medtem ko članki s politično vsebino ostalih medijev uporabljajo toliko drugačen jezik, da so dodeljeni drugi temi. Dokaj presenetljiva je tudi nizka frekvenca poročanja treh desnih medijev o športu in svetu slavnih.

Ker želimo v naši analizi preveriti opredelitve medijev do enakih tem, smo iz množice člankov izločili članke desnih medijev in ponovno izračunali model LDA, kot to prikazuje slika 9. Pri novo izračunanem modelu smo dobili bolj enakomerno zastopane teme. Članke desnih medijev smo nato klasificirali z dobljenim modelom LDA. Problem precej drugačnega pisanja desnih medijev in prevlada pisanja o politiki pri njih se je pojavil tako pri splošnem modelu LDA (za pridobitev splošnih tem) kot tudi pri podrobnejših modelih. V obeh primerih smo postopali na zgoraj opisan način.

Za članke iz leta 2020 smo naučili model za 10 tem (slika 9). Večino tem smo lahko poimenovali že samo s pregledom besed z najvišjimi vrednostmi mere primernosti besed (tabela 5), pri nekaterih temah pa smo si pomagali še s preverjanjem naslovov člankov (tabela 5). Temo epidemije virusa COVID-19 smo

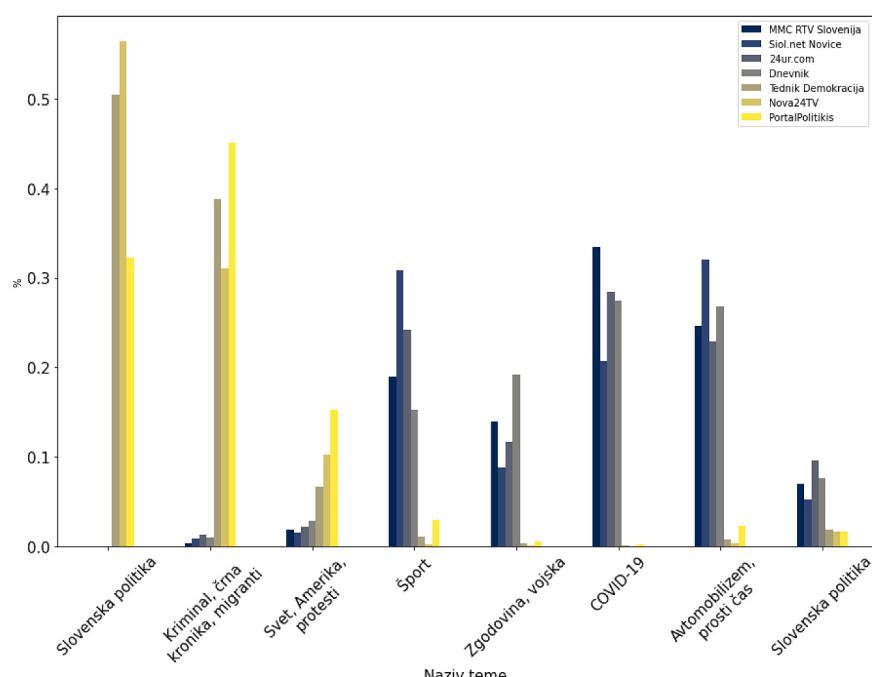


Figure 8: Distribucija člankov izbranih medijev po temah pridobljenih z modelom LDA, ki je bil naučen na celotni množici podatkov za leto 2020.

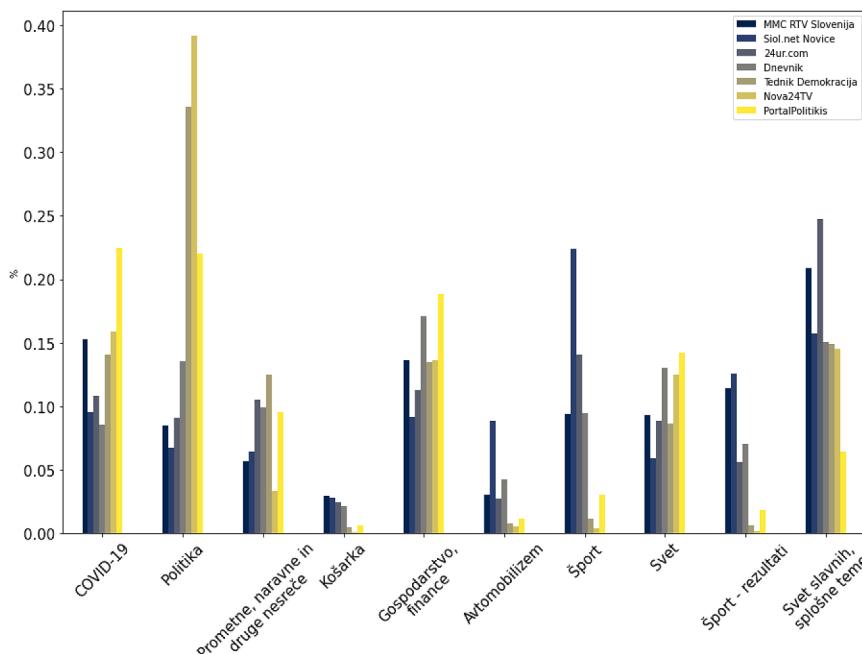


Figure 9: Distribucija tem člankov po medijih za leto 2020 z modelom LDA, izračunanim na osrednjih medijih.

lahko prepoznali s pomočjo besed *korona virus*, *okužb*, *covid*, *okužen* itd. Pri športnih tematikah samo s pregledom besed ne moremo dovolj dobro interpretirati

tematik. Temi poimenovani Šport in Šport – rezultati sta si po najprimernejših besedah zelo podobni, saj obe v večji meri predstavljata temo nogometa. Po

Table 5: Pregled 20 tem, pridobljenih z orodjem Classla [13], z največjo vrednostjo mere primernosti za posamezne splošne teme za leto 2020.

	COVID-19	Politika	Prometne, naravne in ostale nesreče	Košarka	Gospodarstvo, finance	Avtomobilizem	Šport (splošno)	Svet	Šport (rezultati)	Film, glasba svet slavnih
1	koronavirus	stranki	dom	košarkar	podjetji	lahek	sezon	ameriški	minuti	let
2	nov	predsednik	policist	lig	evrov	avtomobili	klub	trump	tekmi	film
3	okužb	policij	ljubljjan	dallas	odstotkov	motor	prvenstvo	let	zmago	življenje
4	covid	vlade	otrok	točk	odstotek	model	nogometen	britanski	mesti	lahek
5	ljud	političen	občin	košarkarski	lahek	električen	lig	kitajski	dvoboј	knjig
6	okužen	minister	območji	končnic	javen	voziti	tekmovanje	dejati	dirko	čas
7	števiti	poslanec	voziti	dončić	let	hitrost	športen	volitev	premagati	imet
8	potrditi	zakon	center	luk_dončić	zaposlen	avtomobilov	evropski	biden	polčas	svet
9	ukrep	vlad	bolnišnic	igre	ministrstvo	kilometrov	šport	predsednik	zadetek	glasben
10	zdravstven	desus	zdravnik	miami	dejavnost	kolo	let	sporočiti	gol	fotografij
11	držav	sodišče	voznik	parket	deloven	meter	nogomet	držav	kolesar	otrok
12	virus	javen	gasilec	četrtnin	gospodarski	let	prvak	poroč	zadel	videti
13	umrl	predlog	občine	tekmi	gospodarstvo	avto	igralec	vojen	zmagovalec	družin
14	okužbe	politik	župan	dosegel	vrednost	zrak	trener	zvezen	priložnost	ljudje
15	karanten	dejati	šolski	boston	pomoč	vozil	slovenski	ruski	prednost	slovenski
16	hrvaški	odločitev	zaposlen	dragić	sredstev	polet	svetoven	trumpov	točki	nagrad
17	bolezen	odstop	pomoč	točka	epidemij	zato	lig_prvakov	napad	niz	zato
18	teden	slovenski	oddelek	miamij	deti	znamki	reprezentanec	dolarjev	tour	filmski
19	bolnikov	opozicij	policij	zvezdnik	družbe	avtomobilski	lahek	vojaški	etap	ljubezen
20	zdravje	postopek	star	tekmo	finančen	hitro	tek	oblast	izgubiti	misel

pregledu naslovov člankov obeh tem smo ugotovili, da ena tema predstavlja predvsem športne rezultate oz. izide tekem, druga pa govorji o športnikih in športnih tekmovanjih. Za interpretacijo nekaterih tem je bilo potrebno pregledati več besed in naslovov.

Za članke iz leta 2019 smo določili 8 različnih tem. Postopek interpretacije tem je bil enak prej opisaniemu za leto 2020. V obeh letih smo zaznali podobne teme, nekaj pa je tudi razlik. Tako smo v letu 2020

zaznali temo, ki je v celoti pripadala politiki, v letu 2019 pa smo politično tematiko zaznali skupaj z gospodarsko in finančno tematiko. Prav tako smo opazili nekaj razlik pri zaznanih športnih tematikah.

V obeh letih je opaziti razliko v distribuciji tematik med posameznimi mediji. Desni mediji imajo visok delež člankov s temo politike, nizko pa pri tematikah športa. Osrednji mediji imajo bolj enakomerno porazdelitev tem, vseeno pa so tudi med njimi opa-

Table 6: Primeri naslovov člankov, ki pripadajo posameznim splošnim temam za leto 2020.

COVID 19	Rekordne številke okužb v Italiji, Nemčiji in Avstriji, v Franciji je umrlo že več kot 40.000 ljudi Rekordno število novoookuženih v Avstriji in Nemčiji, na Hrvaškem največ smrti v enem dnevu doslej Na Poljskem število potrjenih okužb preseglo milijon, na Švedskem dnevni rekord okuženih Na Hrvaškem 2399 novih okužb in največ smrti v enem dnevu, 35 V Grčiji ustavlajo javno življenje, v Belgiji prvi znaki izboljšanja
Politika	Polnar: Iz poslanske skupine DeSUS lahko izstopim le sam Pivčeva: Pred sejo sveta stranke ne bom odstopila Direktor Ukoma za opozarjanje na manipulativne novinarske prispevke Predčasne volitve ostajajo prva izbira SD-ja Urbanija za opozarjanje na »manipulativne prispevke«; oster odziv v Levici in SD-ju
Prometne, naravne in druge nesreče	Ceste na Dolenjskem v le nekaj urah vzele dve življenji V Piranu zagorela hiša, sedem oseb prepeljali v bolnišnico Še bo vetrovno, občasno bo rahlo snežilo Voznik pri Kranju zapeljal s ceste in po prevračanju vozila umrl č rni petek: V čelnem trčenju štirje mrtvi
Košarka	LeBronu Jamesu v Houstonu vzklikali »MVP« Naveza Jokić-Porter novo udarno orožje Denverja Dragić in Butler poskrbela za Miamijev zmagovalni 'ogenj' Zmagi za vodilno moštvo obeh konferenc Dallas zmagal brez poškodovanega Dončića
Gospodarstvo, finance	Prispevki delavcev državo doslej stali več kot 90 milijonov evrov Delodajalci v treh dneh oddali 1154 vlog za čakanje zaposlenih Finančni minister: Leta 2021 ne bo novih davkov, nekateri se bodo znižali 2021 ne bo prineslo višjih davkov, tudi davka na nepremičnine (še) ne bo Za 6,6 odstotka BDP-ja primanjkljaja in 16 odstotkov manj proračunskih prihodkov
Avtomobilizem	Clio E-tech Uradno: prenova in novost enega najbolj priljubljenih križancev Električni leaf z večjo baterijo na preizkusu uporabnosti Volkswagenov ofenziva ob koncu leta Kako je voziti male SUV? Ti se izkažejo najbolje.
Šport	Final four v ligi prvakov? Presednika NZS Mijatovića čaka nujni sestanek s Kekom As: V ligi prvakov možen tudi final four Kevin Kampl izvedel, kdaj bo začel sezono Prvi seznam po letu 2005, pod katerim ni podpisa Dobovičnika
Svet	Novi predsednik ZDA je Joe Biden Florida in Teksas Trumpu, ki napoveduje »veliko zmago«; Biden nagovoril javnost: Bodite potrpežljivi Lukašenko na skrivaj prisegel za šesti mandat Macron na skeptičnem vzhodu brani svoj strateški dialog z Moskvo Iran grozi Združenim arabskim emiratom s posledicami zaradi dogovora z Izraelom
Šport – rezultati	Celje – Triglav 1:1 Tekma zapravljenih priložnosti v Kidričevem #video Prva zmaga Celjanov, nocoj na TV SLO 2/MMC Olimpija – Domžale Razigrani Vekić paral živce Domžalam #video Nov poraz Maribora, Aluminij slavil v Domžalah
Film, glasba, svet slavnih	Sestra Miley Cyrus se je večkrat počutila pozabljeni: Živila sem v njeni senci Poslovila se je plesalka Lojzka Žerdin Ko izza znamenitega oranžnega kavča skoči kar sama Rachel Bowrain – 2020 sekund v živo Lana Del Rey svojo glamurozno obleko kupila v nakupovalnem središču

zne razlike v pokrivanju tematik. Tako izstopa večje pokrivanje športa in avtomobilizma portala Siol.net in večje pokrivanje sveta slavnih portalov 24ur.com in MMC RTV.

## 5.2 Analiza rezultatov modeliranja podrobnejših tem

Naslednji korak analize posameznega leta je interpretacija rezultatov pridobljenih z modeliranjem podrobnejših podtem izbrane splošne teme. V tem koraku pridobimo končne teme in njihove članke, ki jih nato uporabimo za primerjavo sentimenta medijev. Postopek določanja podtem je bil enak kot pri modeliranju splošnih tem.

Za nadaljnjo analizo smo iz leta 2020 vzeli članke s splošnimi temami o epidemiji koronavirusa in slovenski ter svetovni politiki. Za leto 2019 smo poiskali podobne tematike in sicer: politika, gospodarstvo, finance in svetovna politika. Za izbrane teme obeh let smo ponovno izračunali model LDA in s tem pridobili podrobnejše podteme. Za analizo sentimenta smo na koncu izbrali tiste podteme, ki so vsebovale najbolj podobne članke.

Za leto 2020 smo v člankih o slovenski politiki z nadaljnjam modeliranjem našli 12 podtem (slika 10).

Naslovi posameznih tem povzemajo dogajanje na slovenski politični sceni v letu 2020. Zaznali smo temo menjave vlade, ki zajema odstop premiera Marjana Šarca, kot tudi sestavo nove vlade. Poleg tega smo zaznali tudi dogajanje znotraj stranke DeSUS in afero Aleksandre Pivec, afero o nabavi zaščitne medicinske opreme, proteste, ukinitve financiranja STA itd. Opaziti je, da imajo desni mediji največji del svojih člankov s temo, ki smo jo označili kot temo razmišljaj o slovenski politiki in njeni zgodovini. Znotraj te teme članki omenjajo predvsem 30 letnico plebiscita o samostojnosti Slovenije, kar je verjetno vzrok, da imajo desni mediji tako visok delež člankov s to temo.

Za leto 2019 med splošnimi temami nismo dobili teme z zgolj politično vsebino, ampak smo dobili politično tematiko skupaj s financami in gospodarstvom. Ker se te tri teme pogosto prepletajo, se to zdi upravičeno. Za temo s političnimi, finančnimi in gospodarskimi članki smo izračunali nov model LDA za 10 podtem. Ena izmed podtem predstavlja celotno politično dogajanje, ostale pa govorijo o podrobnejših gospodarskih in finančnih temah. Primeri takih tem so stečaj letalske družbe Adrie Airways, prevzemi in prodaje podjetij (npr. Mercator), različne sodne obravnave itd.

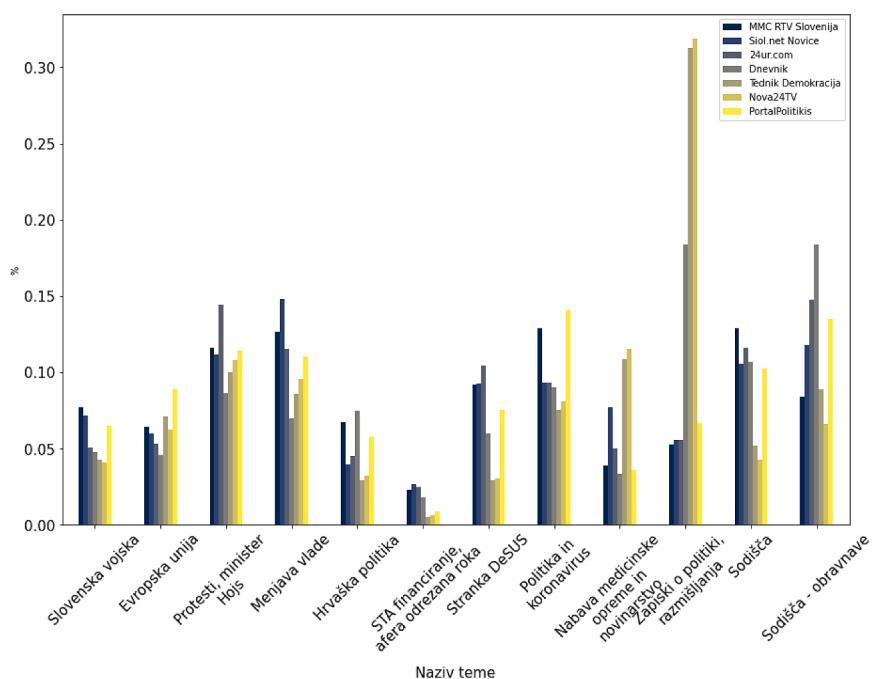


Figure 10: Distribucija podtem slovenske politike po medijih za leto 2020.

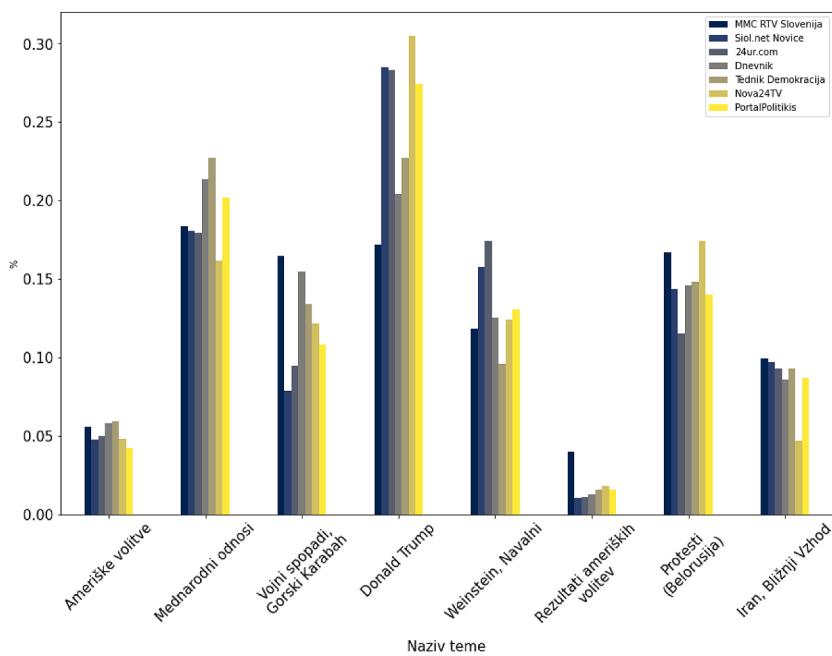


Figure 11: Distribucija podtem svetovne politike po medijih za leto 2020.

Pri člankih, ki smo jih določili temi poimenovani 'svet', smo za leto 2020 zaznali 8 različnih podtem, za leto 2019 pa 10. V obeh letih smo zaznali teme o ameriški politiki in predsedniku Donaldu Trumu, vojnih spopadih na Bližnjem vzhodu in protestih. V letu 2020 je posebna podtema ameriške volitve, v letu 2019 pa evropska politika. Zaradi ameriških volitev v

letu 2020 je bilo več govora o predsedovanju Donalda Truma, ki je najbolj zastopana svetovna politična tema v letu 2020. V letu 2019 je veliko člankov na temo evropske politike, saj so to leto potekale evropske parlamentarne volitve. Deleži tem se v letu 2020 med posameznimi mediji ne razlikujejo prav veliko, za leto 2019 pa smo opazili, da desni mediji v večji

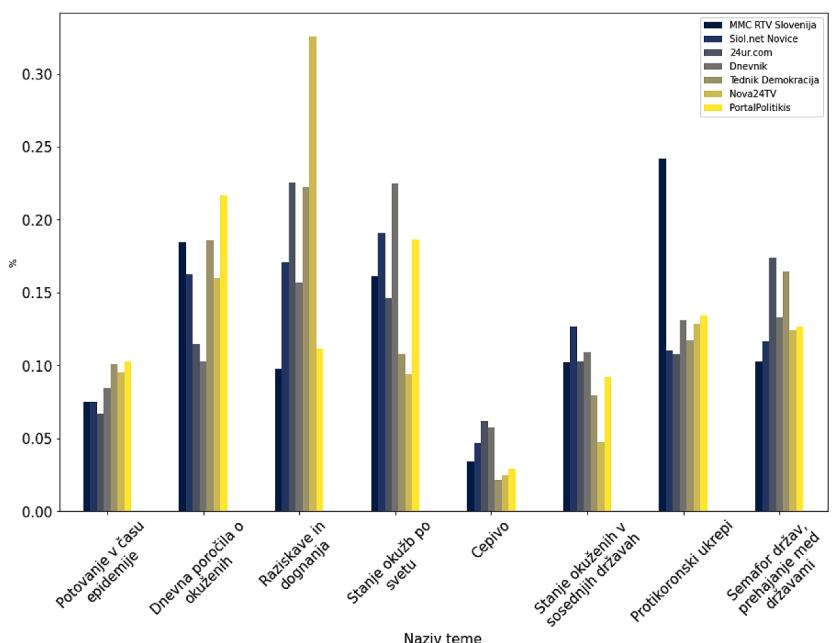


Figure 12: Distribucija podtem epidemije virusa COVID-19 po medijih za leto 2020.

meri pišejo o migrantski krizi in terorističnih napadih ter o evropski politiki.

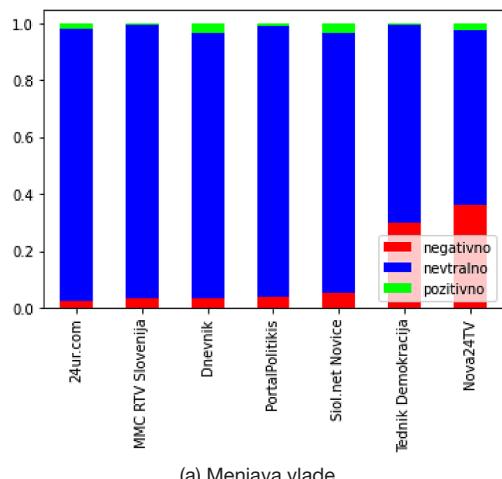
V letu 2020 je posebna tema epidemije virusa COVID-19, ki je pri nas izbruhnila v začetku meseca marca. Znotraj te tematike smo zaznali podteme, kot so poročanje o številu okuženih, o cepivu, evakuacijah in potovanjih v času epidemije ter o protikoronskih ukrepih (slika 12).

### 5.3 Analiza sentimenta

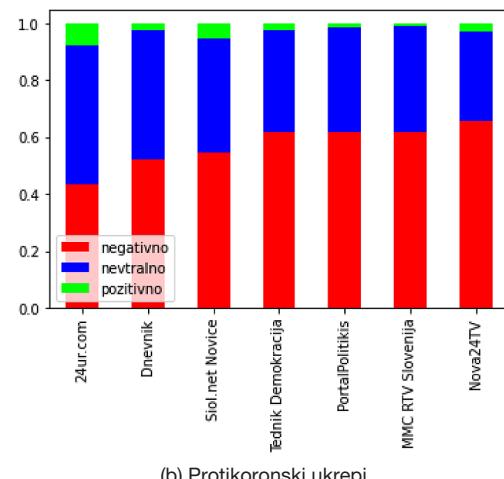
V prejšnjem razdelku smo analizirali zaznane podteme, v tem razdelku pa izluščimo članke izbranih podtem in primerjamo razlike sentimenta med mediji. Ker nekaj tem govori o enem samem dogodku oz. temi (menjava vlade, stranka DeSUS), nekaj pa jih pokriva več dogodkov (npr. financiranje STA in afera odreza roka sta del iste teme), smo za analizo sentimenta izbrali tiste, ki predstavljajo en sam dogodek oz. temo.

Za leto 2020 smo izbrali teme menjave vlade, ameriške politike (predsednik Donald Trump), cipivu proti COVID-19 in protikoronskih ukrepov. Porazdelitve sentimentov po posameznih temah so prikazane na sliki 13.

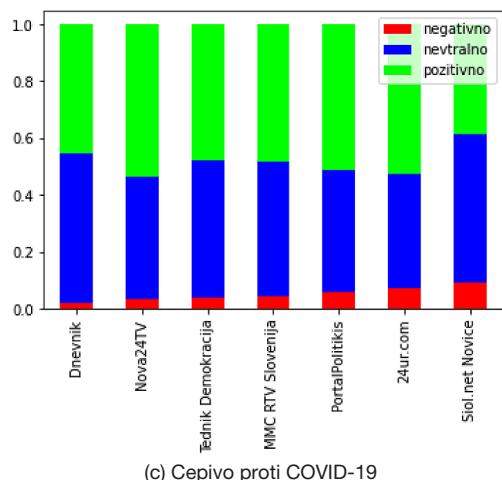
Pri temi menjave slovenske vlade opazimo, da pri vseh medijih prevladuje neutralen sentiment. Nova24TV in Tednik Demokracija imata nekoliko višji delež člankov z negativnim sentimentom, ostali mediji pa so si zelo podobni po porazdelitvi sentimenta. Pri temah o protikoronskih ukrepih in o ameriški politiki opazimo, da v člankih prevladuje negativni sentiment. Opaziti je nekoliko višji delež pozitivnega sentimenta medijev Nova24TV in Portal Politikis pri temi o ameriškem predsedniku Donaldu Trumpu. Pri vseh treh omenjenih temah je delež negativnega sentimenta najvišji pri desnih medijih, predvsem pri Nova24TV. Pri temi o cepivih je porazdelitev senti-



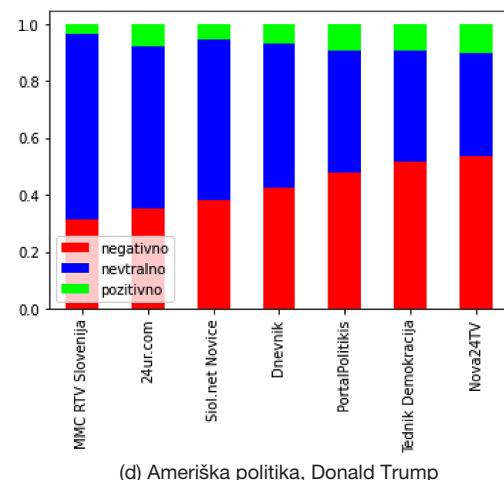
(a) Menjava vlade



(b) Protikoronski ukrepi



(c) Cepivo proti COVID-19



(d) Ameriška politika, Donald Trump

Figure 13: Distribucije sentimenta po medijih za izbrane podteme v letu 2020.

menta precej drugačna. Večina člankov o temi piše s pozitivnim sentimentom, saj večinoma pišejo o razvoju in dobavi cepiv.

Za analizo leta 2019 smo izbrali podobne teme kot za leto 2020: slovensko politiko, stečaj Adrie Airways in ameriško politiko. Temi slovenske in ameriške politike sta dokaj široki, a razbitje na še več podtem bi razdelilo članke na premajhne skupine za zanesljivo analizo sentimenta. Pri temi slovenske politike smo opazili podoben delež sentimenta kot v letu 2020 pri menjavi vlade. Obe temi namreč veliko omenjata koalicijo, opozicijo, politične stranke itd. Pri temi ameriške politike v letu 2019 smo opazili, da imajo mediji zelo podobne porazdelitve sentimenta, pri temah menjave vlade in protikoronskih ukrepov pa imata Tednik Demokracija in Nova24TV opazno višji delež negativnega sentimenta. Zanimivo je, da v letu 2019 Portal Politikis nekoliko odstopal od ostalih dveh desnih medijev.

Z analizo sentimenta v obeh letih smo opazili, da imajo članki desnih medijev pogosto višji delež negativnega sentimenta kot uveljavljeni mediji. Večina negativnih desnih člankov opisuje teme, ljudi, stranke in medije z nasprotnega političnega pola, kar je razlog za višji delež negativnega sentimenta. Prav tako smo v obeh letih opazili nizek delež pozitivnih člankov. Razlogov za to je lahko več. Eden glavnih je zagotovo ta, da v večini obravnavanih tematik težko pričakujemo članke s pozitivnim sentimento. Drug razlog bi lahko bil v našem modelu za napovedovanje sentimenta. Model smo naučili na relativno majhni količini podatkov označenih s pozitivnim sentimento, ki večinoma izhaja iz finančne oz. gospodarske tematike (zaslužki, delnice, prodaja itd.).

Rezultate moramo torej jemati z nekaj rezerve, ki izhajajo iz omejitev strojne analize. Omeniti je potrebno tudi, da model zaznava sentiment zgolj za prvi 512 žetonov vsakega članka, kar pomeni izgubo dela informacij. Ločiti je potrebno tudi med zaznavo sentimenta (naklonjenosti) in izraženimi stališči. Sentiment namreč detektiramo v člankih s podobnimi temami, kar pa ne pomeni, da mediji o istih temah govorijo iz istih stališč. V politični temi se velkokrat pokaže, da desni mediji z negativnim sentimento pišejo o levo opredeljenih strankah ali osebah, med tem ko levo opredeljeni mediji počnejo obratno. Tako članki medijev obeh opredelitev pišejo o isti politični temi, a oboji izpostavljajo negativne aspekte.

## 6 ZAKLJUČEK

V delu smo s pristopi obdelave naravnega jezika poskusili objektivno analizirati dosedaj največjo zbirko člankov izbranih slovenskih medijev. Z analizo smo žeeli primerjati razlike med uveljavljenimi in manj uveljavljenimi desno opredeljenimi mediji, do katerih smo imeli dostop preko servisa Event Registry. Predstavili smo postopek predobdelave besedil in tehniko modeliranja tematik, kjer smo z dvonivojskim modelom LDA iz člankov zaznali podrobne tematike in z naučenim modelom SloBERTa analizirali sentiment.

Z modeliranjem tematik smo pridobili nekaj smiselnih in interpretabilnih tem, ki opisujejo posamezne dogodke oz. teme. Ugotovili smo, da desni mediji v veliki večini pišejo le o političnih temah. Nekaj tem smo izbrali in njihove članke klasificirali glede sentimenta z naučenim modelom SloBERTa. Ugotovili smo, da je večina člankov političnih tem z negativnim in nevtralnim sentimento, zelo malo pa s pozitivnim. Opazili smo razliko med desnimi mediji in uveljavljenimi mediji, kjer so za več tem desni mediji imeli višji delež negativnega sentimenta.

Rezultati so pokazali nekaj razlik med mediji tako na nivoju zaznanih tematik kot na nivoju sentimenta. Rezultati bi bili lahko natančnejši, če bi se uspeli izogniti omejitvam našega pristopa. Pri modeliranju tem bi lahko namesto iskanja podobnih člankov glede na najvišjo verjetnost pojavljanja v dani temi uporabili metodo gručenja. Članke bi predstavili s porazdelitvami verjetnosti vektorskih vložitev za posamezne teme in poskusili poiskati smiselne skupine člankov, ki bi vsebovale podobne članke. Rezultate zaznavanja sentimenta bi lahko izboljšali z uporabo natančnejšega modela, ki bi ga naučili z več raznovrstnimi učnimi množicami. Namesto krajevanja člankov na začetnih 512 žetonov bi lahko uporabili kakšen drug pristop, kot na primer kombiniranje začetka in konca članka.

## ZAHVALE

Avtorja se zahvaljujeva Gregorju Lebanu iz podjetja Event Registry, ki je omogočil dostop do slovenskih člankov. Raziskavo je sofinancirala Javna agencija za raziskovalno dejavnost Republike Slovenije skozi projekt J6-2581 (Računalniško podprtta večjezična analiza novičarskega diskurza s kontekstualnimi besednimi vložitvami) in raziskovalni program P6-0411 (Jezikovni viri in tehnologije za slovenski jezik).

## LITERATURA

- [1] David Blei, Lawrence Carin, and David Dunson. Probabilistic topic models: A focus on graphical model design and applications to document and image analysis. *IEEE signal processing magazine*, 27:55–65, 11 2010.
- [2] David M Blei, Andrew Y Ng, and Michael I Jordan. Latent Dirichlet allocation. *Journal of machine learning research*, 3:993–1022, 2003.
- [3] Jože Bučar. Manually sentiment annotated Slovenian news corpus SentiNews 1.0, 2017. Slovenian language resource repository CLARIN.SI.
- [4] Jože Bučar, Janez Povh, and Martin Žnidaršič. Sentiment classification of the Slovenian news texts. In *Proceedings of the 9th International Conference on Computer Recognition Systems CORES 2015*, pages 777–787, 2016.
- [5] Jože Bučar, Martin Žnidaršič, and Janez Povh. Annotated news corpora and a lexicon for sentiment analysis in Slovene. *Language Resources and Evaluation*, 52(3):895–919, 2018.
- [6] Scott Deerwester, Susan T Dumais, George W Furnas, Thomas K Landauer, and Richard Harshman. Indexing by latent semantic analysis. *Journal of the American society for information science*, 41(6):391–407, 1990.
- [7] Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. BERT: Pre-training of deep bidirectional transformers for language understanding. In *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers)*, pages 4171–4186. Association for Computational Linguistics, 2019.
- [8] Susan T. Dumais. Latent semantic analysis. *Annual Review of Information Science and Technology*, 38(1):188–230, 2004.
- [9] Thomas Hofmann. Probabilistic latent semantic indexing. In *Proceedings of the 22nd annual international ACM SIGIR conference on Research and development in information retrieval*, pages 50–57, 1999.
- [10] Zhenzhong Lan, Mingda Chen, Sebastian Goodman, Kevin Gimpel, Piyush Sharma, and Radu Soricut. ALBERT: A lite BERT for self-supervised learning of language representations. *CoRR*, abs/1909.11942, 2019.
- [11] Gregor Leban, Blaz Fortuna, Janez Brank, and Marko Grobelnik. Event Registry: Learning about world events from news. In *Proceedings of the 23rd International Conference on World Wide Web*, page 107–110, 2014.
- [12] Yinhan Liu, Myle Ott, Naman Goyal, Jingfei Du, Mandar Joshi, Danqi Chen, Omer Levy, M. Lewis, Luke Zettlemoyer, and Veselin Stoyanov. RoBERTa: A robustly optimized BERT pre-training approach. *ArXiv*, abs/1907.11692, 2019.
- [13] Nikola Ljubešić and Kaja Dobrovoljc. What does neural bring? Analysing improvements in morpho-syntactic annotation and lemmatisation of Slovenian, Croatian and Serbian. In *Proceedings of the 7th Workshop on Balto-Slavic Natural Language Processing*, pages 29–34, 2019.
- [14] Nataša Logar and Nikola Ljubešić. Gigafida in slWaC: tematska primerjava. *Slovenščina 2.0*, 1(1):78–110, 2013.
- [15] Edward Loper and Steven Bird. NLTK: The natural language toolkit. In *In Proceedings of the ACL Workshop on Effective Tools and Methodologies for Teaching Natural Language Processing and Computational Linguistics.*, 2002.
- [16] Louis Martin, Benjamin Muller, Pedro Javier Ortiz Suárez, Yolann Dupont, Laurent Romary, Éric Villemonte de la Clergerie, Djamé Seddah, and Benoit Sagot. CamemBERT: A tasty French language model. In *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics*, 2020.
- [17] Matej Martinc, Nina Perger, Andraž Pelicon, Matej Ulčar, Andreja Vezovnik, and Senja Pollak. EM-BEDDIA hackathon report: Automatic sentiment and viewpoint analysis of Slovenian news corpus on the topic of LGBTIQ+. In *Proceedings of the EACL Hackathon on News Media Content Analysis and Automated Report Generation*, pages 121–126, 2021.
- [18] Andraž Pelicon, Marko Pranjić, Dragana Miljković, Blaž Škrlić, and Senja Pollak. Zero-shot learning for cross-lingual news sentiment classification. *Applied Sciences*, 10(17):5993, 2020.
- [19] Radim Řehůřek and Petr Sojka. Software framework for topic modelling with large corpora. In *Proceedings of the LREC 2010 Workshop on New Challenges for NLP Frameworks*, pages 45–50, 2010.
- [20] Carson Sievert and Kenneth Shirley. LDavis: A method for visualizing and interpreting topics. In *Proceedings of the workshop on interactive language learning, visualization, and interfaces*, pages 63–70, 2014.
- [21] Iza Skrjanec and Senja Pollak. Topic ontologies of the Slovene blogosphere: A gender perspective. 2016.
- [22] Matej Ulčar and Marko Robnik-Šikonja. Slovenian RoBERTa contextual embeddings model: SloBERTa 1.0, 2020. Slovenian language resource repository CLARIN.SI.
- [23] Matej Ulčar and Marko Robnik-Šikonja. SloBERTa: Slovene monolingual large pretrained masked language model. In *Proceedings of Data Mining and Data Warehousing, SiKDD*, 2021.
- [24] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Łukasz Kaiser, and Illia Polosukhin. Attention is all you need. In *Proceedings of the 31st International Conference on Neural Information Processing Systems*, page 6000–6010, 2017.
- [25] Thomas Wolf, Lysandre Debut, Victor Sanh, Julien Chaumond, Clement Delangue, Anthony Moi, Pierric Cistac, Tim Rault, Rémi Louf, Morgan Funtowicz, Joe Davison, Sam Shleifer, Patrick von Platen, Clara Ma, Yacine Jernite, Julien Plu, Canwen Xu, Teven Le Scao, Sylvain Gugger, Mariama Drame, Quentin Lhoest, and Alexander M. Rush. Transformers: State-of-the-art natural language processing. In *Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing: System Demonstrations*, pages 38–45, 2020.

# ► E-učilnica za učenje na dokazih podprte zdravstvene nege

Alenka Baggia<sup>1</sup>, Robert Leskovar<sup>1</sup>, Branislav Šmitek<sup>1</sup>, Saša Mlakar<sup>2</sup>, Katja Pesjak<sup>2</sup>, Mateja Bahun<sup>2</sup>, Manuel Lillo-Crespo<sup>3</sup>, Jorge Riquelme Galindo<sup>3</sup>, Christine FitzGerald<sup>4</sup>, Liz Kingston<sup>4</sup>, Alice Coffey<sup>4</sup>, Lucia Cadorin<sup>5</sup>, Alvisa Palese<sup>5</sup>, Barbara Narduzzi<sup>6</sup>, Sara Scarsini<sup>6</sup>, Uroš Rajkovič<sup>1</sup>

<sup>1</sup> Fakulteta za organizacijske vede, Univerza v Mariboru, Kidričeva cesta 55a, SI-4000 Kranj

<sup>2</sup> Fakulteta za zdravstvo Angele Boškin, Spodnji plavž 3, SI-4270 Jesenice

<sup>3</sup> Faculty of Health Sciences, University of Alicante, Carretera San Vicente del Raspeig s/n, ES-03690 San Vicente del Raspeig, Alicante

<sup>4</sup> Department of Nursing & Midwifery, Faculty of Education & Health Sciences, Health Sciences Building, North Bank Campus, University of Limerick, IE-Limerick

<sup>5</sup> Udine University, Viale Ungheria 20, IT-33100 Udine

<sup>6</sup> Azienda Sanitaria Universitaria Friuli Centrale, Via Pozzuolo n. 330, IT-33100 Udine

alenka.baggio@um.si, robert.leskovar@um.si, branislav.smitek@um.si, smlakar@fzab.si kpesjak@fzab.si, mbahun@fzab.si, manuel.lillo@grupohla.com, jorge.riquelme@grupohla.com, Christine.Fitzgerald@ul.ie, Liz.Kingston@ul.ie Alice.Coffey@ul.ie, lucia.cadorin@uniud.it, alvisa.palese@uniud.it, barbara.narduzzi@asufc.sanita.fvg.it, sara.scarsini@asufc.sanita.fvg.it, uros.rajkovic@um.si

## Izvleček

Podobno kot na ostalih izobraževalnih področjih se je tudi podiplomski študij zdravstvene nege v zadnjem času delno preselil v spletno okolje. Že pred tem pa se je pojavila ideja o razvoju skupne platforme za učenje na dokazih podprte zdravstvene nege. E-učilnica za učenje na dokazih podprte zdravstvene nege bo omogočala lažji dostop do gradiv, ki ni časovno omejen. Z uporabo interaktivnih elementov v e-učilnici pa bomo udeležence izobraževanja še dodatno motivirali. Zaradi razširjenosti in dostopnosti sistema za upravljanje z učnimi vsebinami je bil za razvoj e-učilnice izbran sistem Moodle. Izbrani sistem s svojimi raznolikimi aktivnostmi že v osnovi ponuja širok nabor interaktivnih elementov, z razširitvama BigBlueButton in H5P pa se ta nabor še razširi. Da bi omogočili izvajalcem izobraževanja s področja zdravstvene nege lažje odločanje o primernosti posameznih načinov prikaza učnih vsebin, smo razvili prototip spletne učilnice. Na osnovi informacij o potrebah po izobraževanju smo identificirali ključne teme, za katere bomo v nadaljevanju razvili interaktivno e-učilnico za učenje na dokazih podprte zdravstvena nega.

**Ključne besede:** e-učenje, e-učilnica, interaktivne vsebine, zdravstvena nega, na dokazih podprta zdravstvena nega

## Abstract

Similar to other educational sectors, postgraduate nursing studies have also shifted to the online environment to some extent in recent times. The idea of developing a common platform for learning on evidence-based nursing emerged even before this change in education. E-learning on evidence-based nursing will provide easier access to the available material. The integration of interactive elements in the e-classrooms will further motivate students to actively participate in education. Due to its widespread use in education and accessibility, the Moodle learning management system was selected as the development platform. Moodle, with its wide range of activities, offers a variety of interactive elements that can be integrated into the e-Classroom, and the number of elements is even greater with the use of BigBlueButton and H5P plugins. To help healthcare education providers decide how to present content, we developed a prototype e-Classroom. Based on information on educational needs gathered during the project, we identified the main topics for which we will develop an interactive e-Classroom for evidence-based nursing.

**Keywords:** E-learning, e-classroom, interactive content, gamification, nursing, evidence-based nursing

## 1 UVOD

V zadnjem obdobju se je celoten izobraževalni proces po sili razmer preselil v spletno okolje. Ne glede na to pa so že pred situacijo s COVID-19 nekatere izobraževalne ustanove, predvsem visokošolske, svoje aktivnosti delno izvajale preko spletja. V svojih spletnih učilnicah so ponujali in še ponujajo različne oblike predstavitev, aktivnosti in možnosti medsebojnega sodelovanja študentov ali sodelovanja študentov z izvajalci študijskega procesa. Prehod v situacijo izrednih razmer v izobraževanju tako za marsikatero visokošolsko ustanovo ni predstavljal tako velikega problema kot ustanovam na nižjih stopnjah izobraževanja. Poleg internih spletnih učilnic posameznih ustanov lahko na spletu najdemo veliko prosto dostopnih spletnih platform, ki ponujajo tečaje (angl. Massive Open Online Course – MOOC) in ostale izobraževalne vsebine. Tovrstne vsebine so mnoge izobraževalne ustanove v času izrednih razmer tudi koristno uporabile v svojem študijskem procesu.

Podobno kot ostala področja se razvija tudi izobraževanje v zdravstveni negi. Veliko priložnosti za izobraževanje v spletnem okolju se nam na tem področju ponuja predvsem na podiplomskem študiju zdravstvene nege, ki nadgrajuje dodiplomske študije z novimi znanji, raziskovalnimi pristopi ter celostnim pristopom k obravnavi pacienta. Študenti na podiplomskem študiju so bolj notranje motivirani za študij, dodatno pa jih lahko motiviramo še z metodami aktivnega poučevanja. Pri tem lahko v študijski proces smiselno vključimo številna spletna orodja in storitve ter tako poučevanje osredotočimo na študenta [1].

Kot v poročilu s srečanja Sekcije za informatiko v zdravstveni negi navaja Dornik [2], naj bi se e-izobraževanje na področju zdravstvene nege uveljavilo kot oblika formalnega, vseživljenskega in samozobraževanja medicinskih sester. [3] ugotavljajo, da se e-izobraževanje v primerjavi s tradicionalnim načinom izobraževanja ne izkaže kot bistveno boljše glede obravnave pacienta, obnašanja, veščin in znanja zdravstvenih delavcev, kljub temu pa študenti e-izobraževalne portale uporabljajo in jih nameravajo uporabljati tudi v prihodnosti, saj so časovno prilagodljivi, pomagajo pri razvoju kariere in naredijo študente bolj zaposljive [4]. Information quality and service quality. E-learning effectiveness dimension included user satisfaction and net benefits. The items in this section were measured on a five-point Likert

scale ranging from strongly disagrees to strongly agree. The data collected have been analyzed using the SPSS version 17.0 and AMOS version 21.0. Findings: Results show that system quality and service quality contribute more in e-learning system compared to information quality. Students perception may be that information available on the website may not be very useful as it's a one-way mode of communication. The researcher also found that the three dimensions (system quality, service quality and information quality).

V prispevku predstavljamo prototipno rešitev e-učilnice za učenje na dokazih podprte zdravstvene nege, posebnega koncepta dela medicinskih sester, ki je ključnega pomena za njihovo uspešno delo. E-učilnica bo namenjena podiplomskim študentom zdravstvene nege ne glede na lokacijo in bo razvita v okviru Erasmus+ projekta ProCare (Hospitals and Faculties together for propoerous and scientific based healthcare).

## 2 E-IZOBRAŽEVANJE

Čeprav smo bili v zadnjem obdobju primorani uporabljati e-izobraževanje kot način izobraževanja na vseh stopnjah, pa se je koncept e-izobraževanja že pred situacijo s COVID-19 izkazal kot učinkovit. Kot navajajo [5] ima še posebej pozitiven vpliv pri uporabi platforme za e-izobraževanje možnost komuniciranja, interaktivnost, možnost ocenjevanja in vrednotenja ter raznolikost učnih stilov.

### 2.1 Interaktivnost v e-izobraževanju

Da bi e-izobraževanje v čim večji meri približali študentom, je pomembno, da študenta ne samo z vsebinami, pač pa tudi z načinom dela v procesu e-izobraževanja čim bolj pritegnemo k sodelovanju. Pri tem lahko uporabimo različne inovativne pristope, ki jih predstavljamo v nadaljevanju. Pri predstavljivosti posameznih pristopov izhajamo iz predpostavke, da želimo opisane pristope uporabiti na primeru izobraževanja s področja zdravstvene nege, zato navajamo tudi primere uspešne uporabe v izobraževanju s področja zdravstva.

#### Skupnost praks

Skupnost praks (angl. Community of Practice) je ena od oblik skupinskega učenja, pri kateri si skupina ljudi izmenjuje mnenja o neki skupni temi ter sodeluje z izmenjavo informacij in izkušenj, da doprinese

k boljšemu znanju [6]. Pri CoP je ključnega pomena, da imajo študenti dostop do skupnosti in pa osnovne računalniške spretnosti, da se lahko vključijo v skupnost. Vsekakor pa moramo poskrbeti tudi za to, da so ključne komponente CoP zagotovljene tudi če se le-ta izvede v spletnem okolju [7] Kot navajata [6], lahko za podporo delovanja skupnosti praks uporabimo različne spletne tehnologije, družbena omrežja ali pa forme.

### Bralni klub

Bralni klubi (angl. Journal Club), ki so se v preteklosti v večji meri odvijali znotraj akademskih ali zdravstvenih ustanov, so bili namenjeni spodbujanju kritičnega mišljenja in širjenju informacij o novih odkritijih [8]. Pozitivne učinke in mnjenja o izvedbi bralnih klubov so zaznali tudi pri bralnih klubih, ki se s pomočjo različnih orodij izvajajo preko spletja [9] its effectiveness as an educational resource is undetermined. Objective To evaluate the effectiveness of the international Twitter-based urology journal club (#urojc). Spletni bralni klubi poleg spodbujanja kritičnega mišljenja študentov, ter veščin za delo po zaključku študija [10], omogočajo dostop do vsebin in diskusij širšemu krogu študentov kot klasični bralni klubi.

### Odprti spletni tečaji

Množični odprti spletni tečaji (angl. Massive Open Online Course, MOOC) so prosto dostopni na spletu. Večina jih sicer zahteva registracijo, na osnovi česar je mogoče slediti napredku posameznika v primeru izdaje potrdila o opravljenem tečaju po zaključku tečaja. Razširjenost MOOC-ov spodbuja visokošolske ustanove, da tudi same raziščejo nove vrste učnih modelov [11], marsikatera od njih pa študente spodbuja k sodelovanju v MOOC-ih da bi razširili svoje znanje. Tak način uporabe v zdravstvu prikazuje prispevek [12], ki opisuje primere izvedbe uvajalnih seminarjev za novo zaposlene s pomočjo MOOC.

### Interaktivne vsebine

Ena od glavnih prednosti e-izobraževanja je tudi priložnost uporabe interaktivnih vsebin. Medtem ko vključevanje interaktivnih vsebin v nekaterih izobraževalnih okoljih zahteva napredno znanje orodij in programskih jezikov, pa sistemi za upravljanje učnih vsebin omogočajo uporabo vtičnikov za urejanje interaktivnih vsebin. Moodle tako vključuje vtičnike

kot so lekcija, e-knjiga ali vtičnih H5P s širokim izborom možnosti za vključevanje interaktivnih vsebin [13]. Nekaj primerov uspešne uporabe interaktivnih vsebin v spletnem izobraževanju najdemo tudi na področju zdravstva. [14] opisujejo razvoj interaktivnih spletnih učnih modulov za učenje tematik povezanih z varnostjo pacientov ter ugotovijo, da lahko tovrstno tehnologijo uspešno uporabijo za učenje teoretičnih osnov. Še bolj napreden pristop, 360° videoposnetek pri vključevanju interaktivne vsebine na področju izobraževanja v zdravstvu prikazujejo [15], ki prav tako naleti na pozitiven odziv udeležencev izobraževanja.

### Igrifikacija

Igrifikacija, koncept uporabe elementov iger v neigranih kontekstih [16] se v izobraževanju uveljavlja kot učinkovito motivacijsko orodje za vključevanje študentov. [17] ugotavljajo, da je k uvedbi igrifikacije v učno okolje potrebno pristopiti premišljeno in hkrati inovativno, da bi dosegli najboljši možni učinek – poleg znanja tudi boljše tehnične in vedenjske veščine študentov. Koncept igrifikacije je še posebej uporaben na področju zdravstva, saj omogoča simulacijo dela s pacientom. [18]many medical schools now incorporate technology-enhanced active learning and multimedia education applications. Education games, medical mobile applications, and virtual patient simulations are together termed gamified training platforms. Objective: To review available literature for the benefits of using gamified training platforms for medical education (both preclinical and clinical) in their research represent them visually in the field of medical education. This study analyzed state-trait anxiety levels of nursing students because of e-Learning during two periods of the COVID-19

## 2.2 E-izobraževanje v zdravstveni negi

V preteklih letih je bilo pri študentih zdravstvene nege zaznati določen strah pred e-učenjem [19], še posebej ob hitrem prehodu na e-izobraževanje ob izbruhu pandemije COVID-19 [20]confinement measures and an urgent change in the education of nursing students from traditional education to distance learning throughout the country affect the mental health of university students. This study analyzed state-trait anxiety levels of nursing students because of e-Learning during two periods of the COVID-19

confinement. A mixed follow-up study was used, which evaluates the same cohort cross-sectionally but with a longitudinal component. A sample of 460 nursing students of the Nursing Degree at the University of Lorca (Murcia, vendar pa se je odnos do e-izobraževanja v času pandemije COVID-19 korenito spremenil. Kot navajajo Singh in sodelavci [21] we aim to evaluate if online teaching methods are as feasible, acceptable, and effective as in-class teaching for medical/nursing students.\nObjectives\\nThe questionnaire captured: (1, si študenti medicine in zdravstvene nege želijo še več inovativnih učnih metod, ki jih ponuja tehnologija. Po drugi strani pa razvoj materialov za e-izobraževanje na področju zdravstvene nege prinaša tudi različne izzive za izvajalce pedagoškega procesa tako pri pripravi materialov, kot tudi pri zagotavljanju povratnih informacij in nadzora nad delom študenta [19].

Poseben izziv pri oblikovanju okolja za e-izobraževanje pa predstavlja učenje na dokazih podprt zdravstvene nege. Na dokazih podprta zdravstvena nega predstavlja vestno in premišljeno uporabo trenutno najboljših dokazov pri odločanju glede oskrbe posameznega pacienta. Pri tem medicinska sestra sledim 5 korakom [22]:

1. Oblikovanje vprašanja o zdravstvenem problemu
2. Iskanje najboljšega možnega dokaza, ki ustreza vprašanju
3. Kritično ocenjevanje ali je dokaz primeren, klinično relevanten in ga je mogoče uporabiti
4. Uporaba rezultata dokaza na obravnavanem primeru
5. Evalvacija učinkovitosti uporabe

Za učinkovito uporabo na dokazih podprt zdravstvene nege mora imeti medicinska sestra določene kompetence, kot so metodološka znanja, poznavanje epidemiologije, iskanja po elektronskih bazah podatkov ter sposobnost kritičnega presojanja [22]. V preteklih raziskavah se je e-učenje za poučevanje na dokazih podprte zdravstvene prakse že izkazalo kot učinkovito, saj prinaša boljše rezultate pri preverjanju znanja in omogoča večjo fleksibilnost za udeležence [23].

### 3 ORODJA ZA PRIPRAVO E-UČILNICE

Na izbiro orodij pri pripravi e-učilnice vplivajo različni dejavniki. Poleg tega, da je platforma prosto dostopna, smo pri razvoju e-učilnice za učenje na dokazih podprte zdravstvene nege upoštevali tudi kriterij

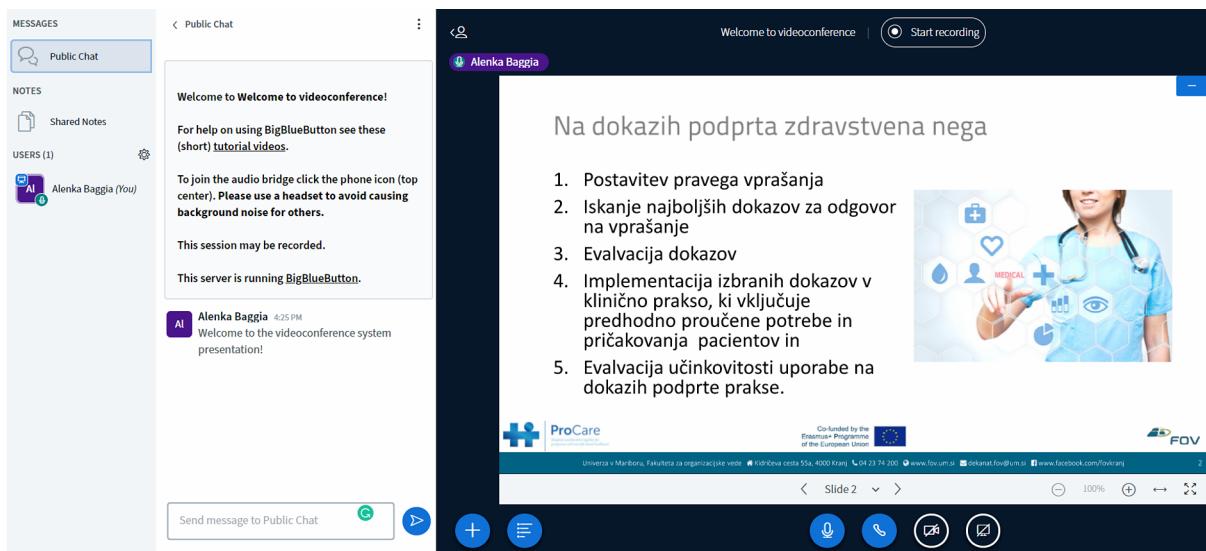
poznavanja tehnologije ter druge pomembne dejavnike [24]. Glede na izbrane kriterije, se je spletna platforma Moodle [25] izkazala kot najbolj primerna za pripravo e-učilnice, saj jo podpira mednarodna skupnost, je odprto kodna in prosto dostopna, zelo fleksibilna, ponuja veliko razširitev ter omogoča tudi integracijo z videokonferenčnim sistemom BigBlue-Button. Kot navajajo Lambda Solutions [26] je Moodle tudi v izobraževanju zdravstvenih delavcev zelo razširjen in na ta način lahko omogoči konsistenten način izobraževanja za zaposlene v zdravstvu. Moodle se tako uporablja pri kombiniranem učenju (angl. Blended learning), vseživljenjskem učenju ali kot točka srečanja za določene zdravstvene strokovne skupnosti.

Med razširitvami, ki jih lahko vključimo v Moodle, smo izbrali H5P, ki omogoča uporabo širokega nabora interaktivnih vsebin v različnih oblikah [27], [28], hkrati pa je mogoče aktivnostim študenta in njegovemu napredku slediti. H5P je zelo intuitivno zasnovan, zato priprava interaktivnih vsebin za izvajalca izobraževanja ni težka in ne zahteva posebnih znanj. Druga razširitev, ki jo bomo v e-učilnici uporabili, LevelUp!, omogoča vključevanje konceptov igrifikacije v učno okolje. Podobno kot razširitev H5P tudi LevelUp! ne zahteva posebnih znanj, vendar pa moramo pri uporabi dosledno definirati logiko dodajanja točk in prehajanja stopenj. S uporabo razširitve LevelUp! študentom omogočimo zbiranje tako imenovanih izkustvenih točk (angl. Experience Points, XP), ki predstavljajo napredek študenta in so osnova za premik študenta po nivojih znanja [29].

S pomočjo predstavljenih orodij smo razvili prototip e-učilnice za poučevanje na dokazih podprt zdravstvene nege. Vsebina in učne oblike izhajajo iz raziskave o potrebnih znanjih s področja na dokazih podprte zdravstvene nege, upoštevali in vključili pa smo tudi dobre prakse predhodnega izobraževanja na partnerskih ustanovah.

### 4 PROTOTIP E-UČILNICE ZA POUČEVANJE NA DOKAZIH PODPRTE ZDRAVSTVENE NEGE

V projektu ProCare sodelujejo izobraževalne ustanove in bolnišnice. Bolnišnice z namenom identificirati potrebe po znanjih s področja zdravstvene nege, ter evalvirati pripravljene izobraževalne vsebine. Izobraževalne ustanove v večji meri prispevajo s svojim strokovnim in znanstvenih poznavanjem področja zdravstvene nege, bolj specifično na dokazih



Slika 1: Videokonferenčni sistem BigBlueButton.

podprtne zdravstvene nege. Da bi zapolnili vrzel pri poznavanju področja e-izobraževanja ter tehnologije, ki e-izobraževanje podpira, so v projektno ekipo vključeni tudi sodelavci Fakultete za organizacijske vede Univerze v Mariboru, ki s svojim strokovnjem znanjem s področja informacijskih sistemov ostalim partnerjem svetujejo pri razvoju e-učilnice. Da bi partnerje seznanili z možnimi načini predstavitve vse-

bin v okviru e-učilnice, so sodelavci pripravili nekaj prototipnih rešitev, ki jim bodo v pomoč pri odločjanju o najprimernejših načinih podajanja vsebine za posamezno tematiko.

#### 4.1 Videokonferenčni sistem

Videokonferenčni sistem je postal nepogrešljiv del e-izobraževanja. V spletnem okolju Moodle lahko

Slika 1: Forum za skupnost praks.

## Teaching evidence-based nursing practice: A systematic review and convergent qualitative synthesis

Subscribed Settings ▾

◀ Selecting a Grounded Theory Approach for Nursing Research

Display replies in nested form

Move this discussion to ...

MOVE



### Teaching evidence-based nursing practice: A systematic review and convergent qualitative synthesis

by Alenka Baggia - Monday, 14 September 2020, 8:37 AM

**Authors:** Samson Wakibia, Linda Ferguson, Lois Berryb, Don Leidib, Sara Beltonb

**Title:** Teaching evidence-based nursing practice: A systematic review and convergent qualitative synthesis

**Date of publication:** 10 June 2020

**Please consider the following when assessing the proposed research:**

1. Was the aim clear?
2. Did they state the research question(s) clearly (if any)?
3. Was the study design quantitative, qualitative, or a combination?
4. Study design appropriate and well explained?
5. Was the sample description clearly explained?
6. Was the size of the sample appropriate for this type of study?
7. Was the research method appropriate?
8. Was the analysis objective?
9. Did the results truly reflect the data provided in the article?
10. Are the conclusions valid?

Overall score of the paper: Good=4; Fair=3; Poor=2; Very Poor=1; Lower Scores=Poor quality

**Copy the assessment questions and write your feedback as a reply to this post. Use CTRL+C and CTRL+V to copy and paste.**

[Wakibi2020.pdf](#)

Slika 3: Ena od tem v forumu bralnega kluba.

uporabimo videokonferenčni sistem BigBlueButton [30], ki ima podobne funkcionalnosti kot ostala podobna orodja, za delovanje pa potrebuje samo HTML5. Videokonferenčni sistem lahko uporabimo kot orodje za predstavitev vsebin, za razprave, medsebojno pomoč študentov in podobno. Izgled vmesnika videokonferenčnega sistema BigBlueButton je predstavljen na sliki 1.

## 4.2 Forum

V e-učilnici lahko aktivnost Forum, ki podpira skupinsko delo, uporabimo za različne namene. Forum lahko poljubno oblikujemo in prilagodimo. Na sliki 2 je predstavljen forum za podporo delovanja skupnosti praks. Kot predlog smo pripravili dve osnovni temi. Prva tema je namenjena predstavitvi novih študentov, ki predstavlja dobro izhodišče za kvalitetno komunikacijo v spletnem okolju. Glede na izvajalce izobraževanj ostale teme v skupnost praks dodaja moderator e-učilnice.

Forum je primerna oblika tudi za spletno izvajanje aktivnosti bralnega kluba. Bralni klubi v obliki rednih, običajno mesečnih druženj medicinskih sester so v sodelujočih ustanovah stalna praksa. S spremembami dela v obdobju med in po COVID-19 pan-

demiji, kot tudi s spremenjeno obliko učenja preko e-učilnice, bralnega kluba v klasični obliki ni mogoče več izvajati. Na sliki 3 je predstavljena ena od tem v forumu Bralnega kluba.

Seveda forum ni edina možna oblika izvedbe bralnega kluba v e-učilnici. Možne so različne kombinacije z videokonferenčnim sistemom. Manj verjetna je uporaba spletne klepetalnice za izmenjavo mnenj o aktualnih vsebinah in prispevkih. Vse možne oblike smo vključili v prototip ter tako uporabnikom omogočili testiranje možnih izvedb, ki so predstavljene na sliki 4.

## 4.3 Zunanji viri

V e-učilnico lahko vključimo tudi zunanje vsebine, pri čemer poskrbimo za ustrezno navajanje avtorjev gradiva. V prototip sta vključena dva različna primer: MOOC tečaj iz spletnega portala Coursera [31] in e-knjiga povzeta po Dugganu [32].

## 4.4 Interaktivne vsebine

Da bi udeležence izobraževanja čim bolj motivirali ter obogatili njihovo izkušnjo učenja na dokazih podprtih zdravstvene nege v e-učilnici, smo v prototipu e-učilnice predlagali tudi vključevanje interaktivnih

### Journal Club

A Journal club is an example of the flipped classroom concept. Journal clubs provide an open forum for discussing nursing issues in a friendly environment. Nurses read articles and then come together with a facilitator to discuss the content and its application.



#### Synchronous virtual Journal Club

##### Option 1: Journal Club live chat

Join the real-time written discussion each Tuesday at 14:00 or view the past discussion.

##### Option 2: Journal Club online discussions

Live online weekly meetings for the discussion of research papers in nursing.

#### Asynchronous virtual Journal Club

##### Option 3: Journal Club forum

Discuss journal articles with your colleagues, provide feedback, and view other opinions.

##### Journal Club Evaluation Form (Christine)

##### ASSESSMENT FORM JOURNAL CLUB NURSING UHL

Modified from HAWKER, S., PAYNE, S., KERR, C., HARDEY, M. AND POWELL, J., 2002. Appraising the evidence: reviewing disparate data systematically. Qualitative health research, 12(9), pp.1284-1299. Prepared by NPDU UHL 2018

Slika 4: Različne možnosti izvedbe bralnega kluba.

### MOOC Courses

A MOOC is an online course with the option of free and open registration, a publicly-shared curriculum, and open-ended outcomes. MOOCs integrate social networking, accessible online resources, and are facilitated by leading practitioners in the field of study. Most significantly, MOOCs build on the engagement of learners who self-organize their participation according to learning goals, prior knowledge and skills, and common interests.



##### HI-FIVE: Health Informatics For Innovation, Value & Enrichment (Social/Peer Perspective)



HI-FIVE (Health Informatics For Innovation, Value & Enrichment) Training is an approximately 10-hour online course designed by Columbia University in 2016, with sponsorship from the Office of the National Coordinator for Health Information Technology (ONC). The training is role-based and uses case scenarios. No additional hardware or software are required for this course.



##### Quiz on Selected Topics



### Research in nursing - SIR model

#### Research in nursing - SIR model



##### How to apply system dynamics in nursing



##### Quiz on system dynamics



Slika 5: Zunanji viri v e-učilnici.

## Introduction to Research Databases

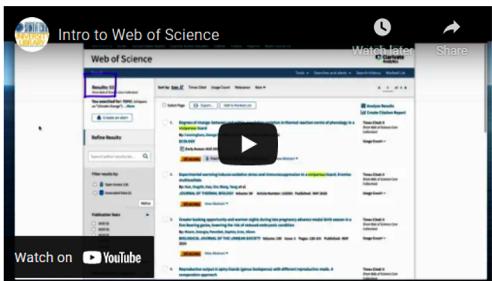
[Preview](#) [Edit](#) [Reports](#) [Grade essays](#)

### Web of Science

**Web of Science** (previously known as **Web of Knowledge**) is a website which provides subscription-based access to multiple databases that provide comprehensive citation data for many different academic disciplines, including Nursing Research. The platform is currently maintained by Clarivate Analytics.

Visit Web of Science [here](#).

A short introduction to the Web of Science and Science Citation Index is available in the following presentation:



[Watch on YouTube](#)

[RESEARCHGATE](#) [GOOGLE SCHOLAR](#)

Slika 6: Lekcija za učenje uporabe raziskovalnih baz podatkov.

vsebin. Sistem za upravljanje učnih vsebin Moodle v osnovi ponuja nekaj interaktivnih modulov. Tako smo v prototip vključili lekcijo, ki omogoča pripravo razvijane vsebine z različnimi dodatki in možnostjo prehajanja med posameznimi vsebinami (slika 6).

E-knjiga podobno kot lekcija omogoča uporabniku premikanje po poglavjih, vključevanje različ-

nih vsebin, povezav in zunanjih virov. Medtem ko je glavna prednost lekcije v razvejanosti, pa e-knjiga uporabniku predлага določeno zaporedje. Primer e-knjige o učenju na dokazih podprte zdravstvene nege prikazuje slika 7.

Poleg osnovnih komponent smo v prototipu uporabili tudi vtičnik H5P, ki so svojim širokim naborom

## Five stages of EBN - eBook

[◀ Previous: The Seven Steps of Evidence-Based Practice](#) [Next: In detail ▶](#)

### Step 1 – ASK question

Developing a good research question is one of the first critical steps in the research process. The research question, when appropriately written, will guide the research project and assist in the construction of a logical argument. The research question should be a clear, focused question that summarizes the issue that the researcher will investigate.

- Researchers should begin by identifying a broader subject of interest that lends itself to the investigation. For example, a researcher may be interested in childhood obesity.
- The next step is to do preliminary research on the general topic to find out what research has already been done and what literature already exists.
- How much research has been done on childhood obesity? What types of studies? Is there a unique area that yet to be investigated or is there a particular question that may be worth replicating?

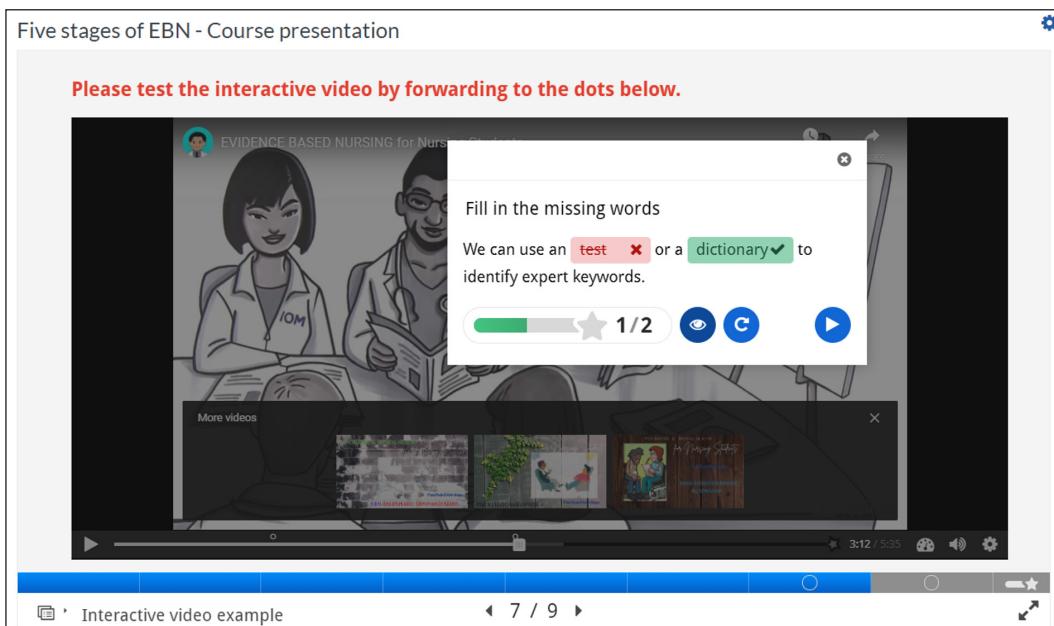
How to choose appropriate keywords and search online databases?



[GoAnimate FOR SCHOOLS](#)

[◀ Previous: The Seven Steps of Evidence-Based Practice](#) [Next: In detail ▶](#)

Slika 7: Lekcija za učenje uporabe raziskovalnih baz podatkov.

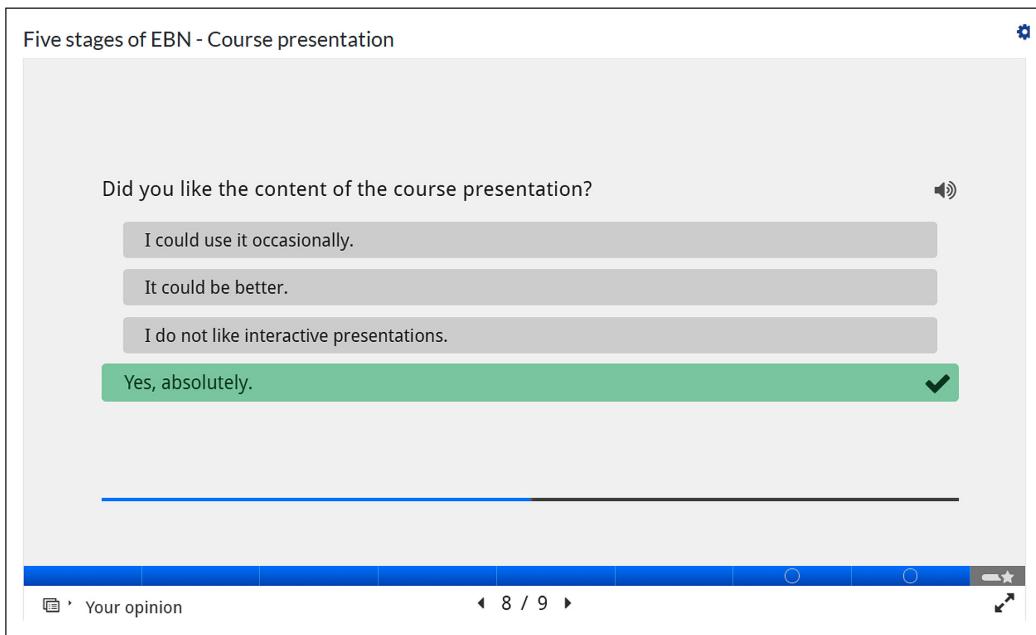


Slika 8: Dodatno vprašanje za sprotno preverjanje znanja ob ogledu videoposnetka.

različnih oblik interaktivnih vsebin omogoča razvoj atraktivnih prikazov učnega gradiva. Za razliko od interaktivne lekcije in e-knjige modul *Course presentation* omogoča vključevanje še ostalih interaktivnih elementov. Kot prikazuje slika 8, je mogoče v vgrajenemu videoposnetku dodati vprašanja za sprotno preverjanje znanja.

Na sliki 9 je prikazana uporaba vprašanja, ki omogoča sprotno preverjanje znanja udeležencev izobraževanja. Rezultati sprotnega preverjanja znanja so zbrani in prikazani ob zaključku dela s posameznim modulom.

Modul *Course presentation* ponuja še vrsto drugih možnosti, med katerimi smo v prototip vključili



Slika 9: H5P modul Course presentation za vključevanje interaktivnih elementov.



Slika 10: H5P modul za prikaz časovnice.

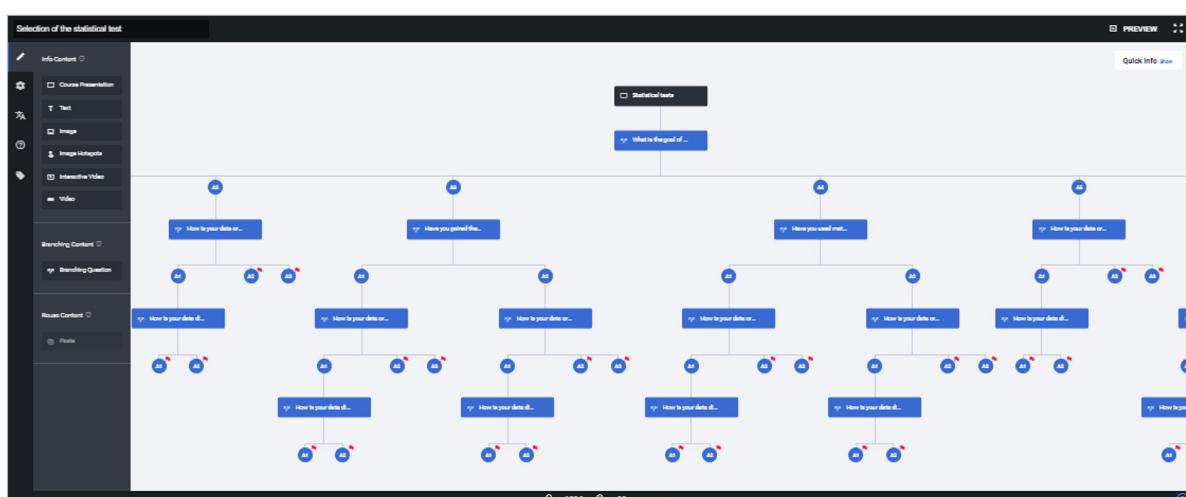
še kartice za preverjanje znanja. Kartice lahko uporabimo za primer vprašanja in odgovora, ali pa za primer trditev, ki jim na drugi kartici sledijo primeri.

Razširitev H5P omogoča tudi enostavno dodajanje elementov, ki jih prikažemo na časovnem traku. Na sliki 10 je prikazan časovni trak razvoja raziskovanja v zdravstveni negi. V časovni trak lahko vključimo opise, fotografije in povezave do dodatnih razlag posameznih mejnikov.

Na dokazih podprta zdravstvena nega vključuje tudi različne metode raziskovanja, na primer stati-

stične metode. Pri raziskavi moramo torej za analizo podatkov uporabiti pravi statistični test. Modul odločitveni scenarij (angl. branching scenario), ki ga ponuja razširitev H5P omogoča definicijo odločitvenega drevesa. V odločitvenem drevesu so definirana vprašanja, ter možni odgovori, na osnovi katerih se določi logika izbire posameznega statističnega testa (slika 11).

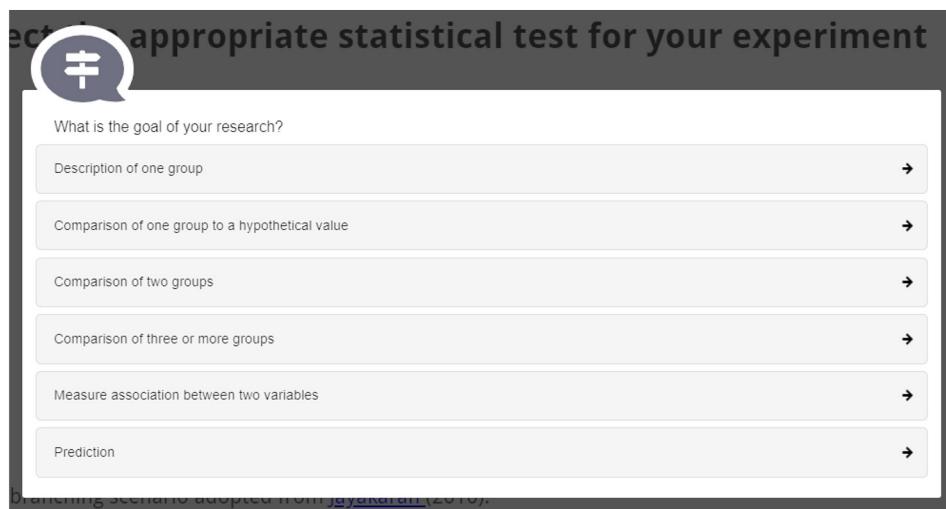
Na osnovi definicije odločitvenega drevesa, se po uvodnem diapositivu predstavitev (slika 12), na zaslonu prikazujejo vprašanja z možnimi odgovori



Slika 11: Definicija odločitvenega drevesa iz izbiro statističnega testa.



Slika 12: Začetni zaslon v procesu izbire pravega statističnega testa.



Slika 13: Primer vprašanja za izbiro statističnega testa.

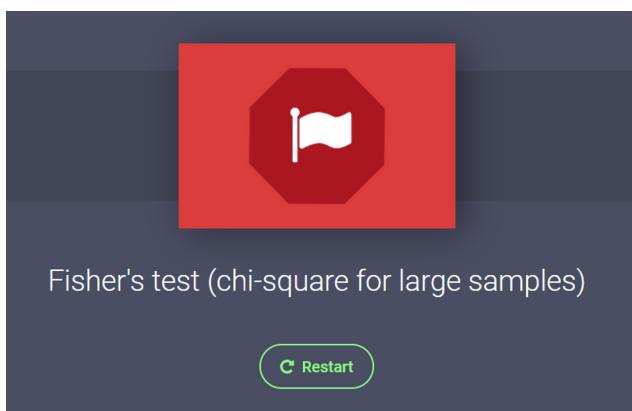
(slika 13), ki vodijo do končnega rezultata, pravega statističnega testa za izbrani problem.

Ko udeleženec izobraževanja izbere vse odgovore definirane v odločitvenem drevesu, se izpiše rezultat, ki prikazuje ime najprimernejšega statističnega testa za obravnavani primer (slika 14).

Poleg predstavljenih interaktivnih elementov v e-učilnico lahko vključimo tudi druge. Ena od zanimivih možnosti je slovar izrazov. Med osnovnimi

aktivnostmi v okolju Moodle lahko uporabimo tudi povratno informacijo, kviz, vprašalnik ali anketo. Še večji nabor možnosti pa najdemo v razširitvi H5P, od možnosti dopolnjevanja manjkajočih izrazov, grafičnih prikazov, prekrivanja slik, iskanja parov, virtualnih ogledov in podobno.

Ena od možnosti, ki v prototip še niso vključenje, je tudi dodajanje elementa igrifikacije. V e-učilnici Moodle lahko igrifikacijo omogočimo z uporabo raz-



Slika 14: Rezultat procesa odločanja o statističnem testu.

širitve LevelUp! [33]. Z definicijo obveznosti in pravil za zbiranje točk udeleženec izobraževanja dobri povratno informacijo, kako dobro napreduje in kakšen je njegov napredek v primerjavi z ostalimi udeleženci izobraževanja.

## 5 ZAKLJUČEK IN RAZPRAVA

V prispevku smo predstavili prototip e-učilnice za učenje na dokazih podprte zdravstvene nege. Prototip je nastal v okviru Erasmus+ projekta Procare in predstavlja izhodišče za razvoj učnega modula s področja zdravstvene nege. V prototipu je uporabljen sistem za upravljanje izobraževalnih vsebin Moodle, z razširtvama BigBlueButton in H5P, ki pomagata pri vzpostaviti interaktivnih vsebin v spletni učilnici. V prispevku prikazujemo različne možnosti rešitev, ki bi študentom zdravstvene nege še bolj približale določene tematike. Kot je prikazano več raziskavah namreč tudi izobraževanja s področja zdravstvene nege, lahko obogatimo z uporabo interaktivnih vsebin. Interaktivne vsebine omogočajo boljšo uporabniško izkušnjo in udeleženca izobraževanja dodatno motivirajo. V prototip je v manjši meri vključen tudi element igrifikacije, preko zbiranja točk v različnih interaktivnih aktivnostih. Večji meri pa je mogoče igrifikacijo vključiti v e-učilnico z uporabo razširitve LevelUp!.

V nadaljevanju bomo v okviru projekta ProCare razvili delujočo e-učilnico, ki jo bodo uporabljali študenti zdravstvene nege v angleškem jeziku. Raziskaava med zaposlenimi v zdravstveni negi je pokazala, da se zdravstveni delavci želijo izpopolniti v tematikah kot so osnovne raziskovalnih metod, uporaba znanstvenih baz podatkov, najnovejše raziskave na področju zdravstvene nege. Pri tem želijo, da so vse

informacije zbrane na enem mestu, da imajo dostop do videoposnetkov z navodili kako dostopati do informacij, ter da lahko s svojimi vrstniki delijo izkušnje. V nekaterih primerih so zdravstveni delavci izrazili tudi željo, da bi bilo gradivo na voljo v njihovem jeziku in ne samo v angleškem.

## ZAHVALA

Prispevek je nastal ob podpori Evropske komisije z nepovratnimi sredstvi 2018 – 2726 / 001 – 001 za projekt Hospitals and faculties together for prosperous and scientific based healthcare (ProCare). Vsebina tega prispevka ne odraža nujno stališča ali mnenja Evropske komisije. Za izražena mnenja odgovarjajo samo avtorji in se zato ta ne morejo štetiti za uradno stališče Evropske komisije.

## LITERATURA

- [1] Ž. Fišer and A. B. Arbeiter, »Možnosti za uporabo na študenta osrednjih metod poučevanja in učenja bioloških predmetov na UP FAMNIT,« *Andragoška spoznanja*, vol. 26, no. 2, pp. 47–57, 2020.
- [2] E. Dornik, »Digitalizacija v zdravstvu: poročilo s srečanja Sekcije za informatiko v zdravstveni negi – SIZN 2019,« *Inform. Medica Slov.*, vol. 24, no. 1–2, pp. 55–60, 2019.
- [3] A. Vaona *et al.*, »E-learning for health professionals,« *Cochrane Database Syst. Rev.*, no. 1, 2018.
- [4] G. Chopra, P. Madan, P. Jaisingh, and P. Bhaskar, »Effectiveness of e-learning portal from students' perspective: A structural equation model (SEM) approach,« *Interact. Technol. Smart Educ.*, vol. 16, no. 2, pp. 94–116, 2019.
- [5] D. Al-Fraiha, M. Joy, R. Masa'deh, and J. Sinclair, »Evaluating E-learning systems success: An empirical study,« *Comput. Human Behav.*, vol. 102, pp. 67–86, 2020.
- [6] M. Chou and J. Frank, »Designing of Online Communities of Practice to Facilitate Collaborative Learning,« in *2018 5th International Symposium on Emerging Trends and Technologies in Libraries and Information Services (ETTLIS)*, 2018, pp. 100–104.
- [7] P. Moule, »E-learning for healthcare students: developing the communities of practice framework,« *J. Adv. Nurs.*, vol. 54, no. 3, pp. 370–380, May 2006.
- [8] J. M. Topf *et al.*, »The Evolution of the Journal Club: From Osler to Twitter,« *Am. J. Kidney Dis.*, vol. 69, no. 6, pp. 827–836, 2017.
- [9] I. A. Thangasamy *et al.*, »Evaluating the Effectiveness of an Online Journal Club: Experience from the International Urology Journal Club,« *Eur. Urol. Focus*, 2019.
- [10] V. C. Lucia and S. M. Swanberg, »Utilizing journal club to facilitate critical thinking in pre-clinical medical students,« *Int. J. Med. Educ.*, vol. 9, pp. 7–8, Jan. 2018.
- [11] W. D. Maxwell *et al.*, »Massive open online courses in U.S. healthcare education: Practical considerations and lessons learned from implementation,« *Curr. Pharm. Teach. Learn.*, vol. 10, no. 6, pp. 736–743, 2018.
- [12] M. Pučko, B. Jurca, and M. Jermol, »Odprto izobraževanje v zdravstvu – tehnologija in metoda,« *Andragoška spoznanja*, vol. 22, no. 4, pp. 57–71, 2016.

- [13] Joubel, »H5P,« 2020. [Online]. Available: <https://h5p.org/>. [Accessed: 24-Aug-2020].
- [14] R. Gaupp, M. Körner, and G. Fabry, »Effects of a case-based interactive e-learning course on knowledge and attitudes about patient safety: a quasi-experimental study with third-year medical students,« *BMC Med. Educ.*, vol. 16, no. 1, p. 172, 2016.
- [15] F. Ulrich, N. H. Helms, U. P. Frandsen, and A. V. Rafn, »Learning effectiveness of 360° video: experiences from a controlled experiment in healthcare education,« *Interact. Learn. Environ.*, pp. 1–14, Feb. 2019.
- [16] M. Urh and E. Jereb, »Model uvedbe igrifikacije v sisteme za upravljanje učenja glede na osebnostne lastnosti,« in 38. Mednarodna konferenca o razvoju organizacijskih znanosti: Ekosistem organizacij v dobi digitalizacije, 2019, pp. 1155–1168.
- [17] M. J. Ferreira, C. Algoritmi, F. Moreira, D. F. Escudero, and L. S. Gretel, »Gamification in higher education: The learning perspective,« in *Experiences and perceptions of pedagogical practices with Game-Based Learning & Gamification*, B. D. da Silva, J. A. Lencastre, M. Bento, and J. Osorio, Eds. Braga, Portugal: Institute of Education, University of Minho, 2019, pp. 195–218.
- [18] L. McCoy, J. H. Lewis, and D. Dalton, »Gamification and Multimedia for Medical Education: A Landscape Review,« *J. Am. Osteopath. Assoc.*, vol. 116, no. 1, pp. 22–34, Jan. 2016.
- [19] M. Telford and E. Senior, »Healthcare students' experiences when integrating e-learning and flipped classroom instructional approaches,« *Br. J. Nurs.*, vol. 26, no. 11, pp. 617–622, Jun. 2017.
- [20] J. García-González, W. Ruqiong, R. Alarcon-Rodriguez, M. Requena-Mullor, C. Ding, and M. I. Ventura-Miranda, »Analysis of Anxiety Levels of Nursing Students Because of e-Learning during the COVID-19 Pandemic,« *Healthcare*, vol. 9, no. 3, 2021.
- [21] H. K. Singh et al., »A survey of E-learning methods in nursing and medical education during COVID-19 pandemic in India,« *Nurse Educ. Today*, vol. 99, p. 104796, 2021.
- [22] A. Rohwer, N. V. Motaze, E. Rehfuss, and T. Young, »E-learning of evidence-based healthcare (EBHC) to increase EBHC competencies in healthcare professionals,« *Campbell Syst. Rev.*, vol. 13, Mar. 2017.
- [23] A. Green, D. A. Jeffs, B. A. Boateng, G. R. Lowe, and M. Walden, »Evaluating evidence-based practice knowledge and beliefs through the e-learning EBP academy,« *J. Contin. Educ. Nurs.*, vol. 48, no. 7, pp. 304–311, 2017.
- [24] A. Baggio et al., »Selecting the e-Learning Platform for Nursing Education,« in 38. mednarodna konferenca o razvoju ograničajskih znanosti: Ekosistem organizacij v dobi digitalizacije, 2019, pp. 49–62.
- [25] Moodle, »Moodle.« 2019.
- [26] Lambda Solutions, *The complete user guide to Moodle*. 2017.
- [27] J. Hudson, »Flipping Lessons with Moodle: Using the H5P Moodle Plugin to Deliver Online Sessions,« in 12th Annual University of Glasgow Learning and Teaching Conference, 2019.
- [28] R. Singleton and A. Charlton, »Creating H5P content for active learning,« *Pacific J. Technol. Enhanc. Learn.*, vol. 2, no. 1, pp. 13–14, 2019.
- [29] H. F. Hasan, M. Nat, and V. Z. Vanduhe, »Gamified Collaborative Environment in Moodle,« *IEEE Access*, vol. 7, pp. 89833–89844, 2019.
- [30] Big Blue Button, »Big Blue Button.« 2019.
- [31] R. Kukafka, »HI-FIVE: Health Informatics For Innovation, Value & Enrichment (Social/Peer Perspective).« Columbia University, 2021.
- [32] J. Duggan, »Diffusion Models,« in *System Dynamics Modeling with R, Lecture Notes in Social Networks*, Springer International Publishing, 2016, pp. 97–122.
- [33] branchup, »LevelUp!,« 2020. [Online]. Available: <https://levelup.plus/>. [Accessed: 27-Aug-2020].

**Alenka Baggia** je docentka na Univerzi v Mariboru, Fakulteti za organizacijske vede kot docentka za področje informacijski sistemov. Njeno raziskovalno delo je osredotočeno na sprejetje novih tehnologij in vlogo informacijskih sistemov v trajnostnem razvoju. Je članica Laboratorija za kakovost in testiranje programske opreme in certificirana inštruktorica Oracle Academy.

**Robert Leskovar** je redni profesor na Univerzi v Mariboru, Fakulteti za organizacijske vede. Raziskovalno področje obsega večkriterijsko odločanje, simulacijo in modeliranje ter razvoj in testiranje programskih rešitev. Je vodja Laboratorija za kakovost in testiranje programske opreme, predstojnik Katedre za informatiko in certificiran inštruktor Oracle Academy.

**Branislav Šmitek** je docent na Univerzi v Mariboru, Fakulteti za organizacijske vede. Njegovo pedagoško in raziskovalno delo je usmerjeno v reševanje problemov uporabe multimedije v izobraževalnem procesu, razvoja elektronskih učnih gradiv in njihove uporabe pri e-izobraževanju in načrtovanja ter izvedbe preverjanja znanja s pomočjo elektronskih sistemov za preverjanje znanja.

**Saša Mlakar** je Predstojnica Centra za vseživiljenjsko izobraževanje, karierno svetovanje, tutorstvo in mentorstvo na Fakulteti za zdravstvene vede Angele Boškin. V sklopu Centra vodi karierno središče, ki je namenjeno povezovanju zaposlovalcev in diplomantom fakultete. Sodeluje na več mednarodnih in nacionalnih projektih s področja zdravstvenih ved.

**Katja Pesjak** je docentka za področje Sociologije zdravja in bolezni na Fakulteti za zdravstvo Angele Boškin. Je članica razvojno-raziskovalne skupine fakultete in raziskovalno deluje na področju javnega zdravja, promocije zdravja in razvoja zdravstvene nege kot znanstvene discipline. Aktivno sodeluje pri pridobivanju in izvajanju tujih in domačih aplikativnih in temeljnih projektov.

**Mateja Bahun** je višja predavateljica in predstavnica vodstva za kakovost na Fakulteti za zdravstvo Angele Boškin. Po izobrazbi je profesorica zdravstvene vzgoje in magistra zdravstvene nege. Njeno pedagoško delo na 1. stopnji visokošolskega študijskega programa zdravstvene nege obsega različne vsebine, med drugim tudi e-zdravstveno nego.

**Manuel Lillo-Crespo** je izredni profesor na Oddelku za zdravstveno nego Univerze v Alicanteju. Je vodja več nacionalnih in mednarodnih raziskovalnih projektov s področja zdravstvene nege, inovacij v izobraževanju zdravstvene nege ter kakovosti zdravstvene nege. Je član Royal College of Surgeons na Irskem in sodelavec Akademije za zdravstveno nego v regiji.

**Jorge Riquelme Galindo** je doktorski kandidat na področju zdravstvenih ved. Zaposlen je kot koordinator zdravstvene nega na oddelku za intenzivno terapijo in intervencijsko kardiologijo v bolnišnici HLA Vistahermosa. Hkrati je profesor na CEU Univerzi in mentor mendarodnim študentom na HLA Vistahermosa. Je član več mednarodnih združenj s področja zdravstvenih ved in sodeluje na več mednarodnih projektih.

**Christine Fitzgerald** je podoktorska raziskovalka na Univerzi v Limericku. Z bogatimi izkušnjami s področja zdravstvene nege in promocije zdravja, se njen raziskovalno delo osredotoča na raziskovanje zdravstvenih storitev, uporabniške izkušnje in sodelovanja na področju zdravstvene nege.

**Liz Kingston** je predavateljica in koordinatorka laboratorijskih na Oddelku za zdravstveno nego Univerze v Limericku. Njena raziskovalna področja vključujejo higieno rok, preprečevanje in nadzor okužb, poučevanje kliničnih veščin ter uporaba tehnologije v pedagoškem procesu.

**Alice Coffey** je redna profesorica ter predstojnica oddelka zdravstvene nege, vodja doktorskega študija, vodja inštituta za zdravstvene raziskave in grozda Health Implementation Science and Technology na Univerzi v Limericku. Njena raziskovalna področja so prehodna in celostna oskrba, gerontologija, paliativna oskrba demence in razvoj raziskovalnih kompetenc na področju zdravstvene nege.

**Lucia Cadorin** je raziskovalka na Univerzi v Udinah in izredna profesorica bioetike. Kot oblikovalka stalnega izobraževanja je zaposlena pri nacionalnem inštitutu za boj proti raku. Sodeluje pri več projektih vezanih na izobraževanje v zdravstveni negi. Njeno raziskovalno področje pa vključuje samostojno in smiselnoučenje na področju zdravstvene nege.

**Alvisa Palese** je izredna profesorica za področje zdravstvene nege na Oddelku za medicinske vede ter koordinatorica študijskega programa zdravstvenih ved Univerze v Udinah. Kot koordinatorka ali raziskovalka sodeluje pri več nacionalnih in mednarodnih projektih. Njeno področje raziskovanja vključuje zaposlovanje in izobraževanje medicinskih sester, klinične študije ter raziskave s področja nevroznanosti v zdravstvenih vedah.

**Barbara Narduzzi** je magistrka zdravstvenih ved. Zaposlena je kot medicinska sestra v Univerzitetnem javnem zdravstvenem podjetju za Osrednjo Furlanijo. Vključena je v raziskave s področja profesionalnega razvoja medicinskih sester in babic.

**Sara Scarsini** je diplomirana medicinska sestra, zaposlena kot raziskovalka na mednarodnih projektih na Univerzitetnem javnem zdravstvenem podjetju za Osrednjo Furlanijo. Poleg bogatih izkušenj na delovnem mestu medicinske sestre je zaključila tudi doktorski študij.

**Uroš Rajković** je zaposlen na Univerzi v Mariboru, Fakulteti za organizacijske vede. Raziskuje na področju sistemov za podporo odločjanju in zdravstvene informatike. Je vodja programskega odbora konference Vzgoja in izobraževanje v informacijski družbi.

# ► Stanje in trendi na področju rudarjenja procesov

Gregor Polančič<sup>1</sup> in Mateja Kocbek Bule<sup>1</sup>

<sup>1</sup> Univerza v Mariboru, Fakulteta za elektrotehniko, računalništvo in informatiko,  
Koroška cesta 46, 2000 Maribor  
gregor.polancic@um.si, mateja.kocbek@um.si

## Izvleček

Upravljanje poslovnih procesov je uveljavljena metodologija, katere poglaviti namen je učinkovito izboljšanje organizacijskih procesov z uporabo različnih tehnik in tehnologij, ki v veliki meri temelji na modelih procesov. Predpogoj za uspešno upravljanje je zagotavljanje veljavnih modelov, kar pa je v praksi pogosto težko doseči, saj so le ti, pogosto zaradi človeških dejavnikov, nepopolni, nepravilni oziroma neažurni.

Alternativni oziroma komplementarni pristop, ki se v zadnjih letih uveljavlja na področju upravljanja poslovnih procesov, je zato na realnih podatkih temelječe upravljanje procesov, ki jih, predvsem v obliki dnevnikov dogodkov, generirajo poslovne informacijske rešitve. Rudarjenje procesov je sinonim za množico tehnik in tehnologij, ki omogočajo avtomatsko generiranje in vizualizacijo modelov procesov na osnovi dnevnikov dogodkov, z njihovo pomočjo pa je možno procese odkrivati, analizirati, preverjati skladnost izvajanih procesov in odkrivati morebitna odstopanja.

V prispevku bomo predstavili in umestili rudarjenje procesov v življenjski cikel upravljanja poslovnih procesov, na osnovi korakov algoritma Alfa pa bo pojasnjen postopek avtomatskega oblikovanja modela procesa iz podatkov sistemskega dnevnika. Osrednji del prispevka je namenjen predstavitvi zmožnosti sodobnih rešitev za rudarjenje procesov, ki postajajo v sodobnih poslovnih okoljih ne-pogrešljiv člen poslovne analitike, z njihovo pomočjo pa je možno sprejemati natančne procesne oziroma poslovne odločitve, ki temeljijo na realnih operativnih podatkih.

**Ključne besede:** poslovni procesi, upravljanje poslovnih procesov, rudarjenje procesov

## Abstract

Business process management is an established methodology the main purpose of which is to effectively improve organizational processes by applying a variety of techniques and technologies that are largely based on process models. A prerequisite for the successful management is the provisioning of valid models, which is often difficult to achieve in practice as commonly, due to human factors, process models tend to be incomplete, inaccurate, or outdated.

An alternative or complementary approach, which has been established in recent years in the field of business process management, considers empirical process-related data, which especially in the form of event logs, are generated by business applications. Process mining is a synonym for a multitude of techniques and technologies that enable automatic event log-based generation and visualization of process models that make possible the detection and analysis of processes, checking the compliance of implemented processes and detection of potential deviations.

In this paper, we will present and position process mining in the business process management lifecycle. Process mining will be demonstrated with the steps of a common process mining algorithm – Alpha. The central part of the paper is aimed at presenting the capabilities of modern tools for process mining, which are becoming an indispensable part of business analytics in modern business environments. With their help, it is possible to make precise process or business decisions based on real operational data.

**Keywords:** Business process, business process management, process mining

## 1 UVOD

Upravljanje poslovnih procesov (angl. business process management, BPM) je uveljavljena metodologija, katere poglavitni namen je povečanje uspešnosti, učinkovitosti in prilagodljivosti organizacijskih procesov in posledično poslovanja podjetja. Predstavlja skupek praks, tehnik in tehnologij, ki so običajno urejene v obliki (teoretičnega) življenjskega cikla, sestavljenega iz naslednjih, medsebojno odvisnih, faz [1]: identificiranje procesa (angl. process identification), odkrivanje procesa (angl. process discovery), analiza procesa (angl. process analysis), prenova procesa (angl. process redesign), implementacija procesa (angl. process implementation) in spremljanje oz. nadzorovanje procesa (angl. process monitoring and control).

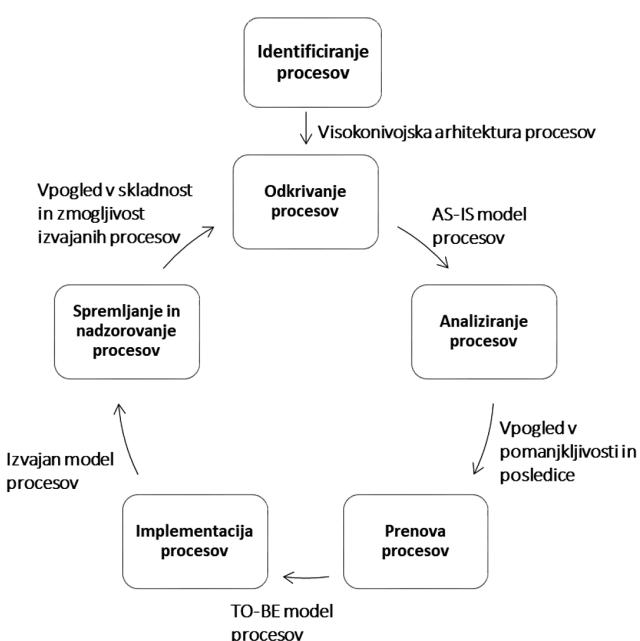
Ker so (poslovni) procesi neotipljiva sredstva (angl. intangible assets), jih običajno upravljamo preko modelov procesov (angl. process model), le ti pa so običajno predstavljeni v grafični obliki oziroma v obliki diagrama (angl. process diagram) [2]. Jedro tradicionalnega upravljanja poslovnih procesov tako predstavlja modeli procesov, ki služijo različnim namenom kot so: analiziranje procesov, komuniciranje o procesih, implementacija procesov in spremembe oz. izboljšave procesov. Ker odločitve upravljanja poslovnih procesov v veliki meri temeljijo na modelih procesov, je poglavitični izviv zagotavljanje veljav-

nih modelov procesov (angl. validity), kar pomeni, da modeli predstavljajo dejanske procese oziroma operativno izvajanje in da le te opisujejo v celoti (angl. completeness) [1].

V praksi se je izkazalo, da je ravno zagotavljanje veljavnih in pravilnih modelov procesov šibek člen njihovega upravljanja. Zaradi nenehnih sprememb v poslovnom okolju se poslovni procesi kontinuirano spreminja in prilagajajo. Modeli poslovnih procesov tako hitro postanejo neskladni z dejansko izvajanimi procesi kakor tudi s tehničnim okoljem v katerem se izvajajo. Modeliranje poslovnih procesov je prav tako podvrženo človeškim dejavnikom, saj je pretežno odvisno od sprememb, znanj in razpoložljivosti analitika, kar vpliva na izdelane modele procesov. Tradicionalno odkrivanje in modeliranje procesov je drago in časovno potratno tudi zaradi vrzeli v poslovnu znanju deležnikov in pomanjkanja objektivnih validacij modelov [3]. Modeli so zato pogosto nepopolni (ne opisujejo celotnega procesa), neskladni (ne predstavljajo dejanskega procesa) ali nepravilni (ne upoštevajo pravil diagramskega jezika, na primer BPMN, in so zato nerazumljivi tako za ljudi kakor tudi za izvajalna okolja). Poslovne odločitve, ki se sprejemajo na neustreznih modelih procesov, so tako lahko napačne.

Z višanjem stopnje avtomatizacije (procesov) so se pojavile priložnosti za reševanje omenjenih izzivov, ki omogočajo bolj neposredno povezovanje aktivnosti upravljanja procesov z dejansko izvajanimi procesi in sicer preko podatkov, ki jih poslovne informacijske rešitve generirajo v fazi operativne izvedbe procesov, predvsem v obliki dnevnikov dogodkov (angl. event log). Te podatke je možno z usmerjenimi tehnikami rudarjenja podatkov (angl. data mining) pretvoriti v obliko, ki je uporabna za sprejemanje odločitev upravljanja procesov in se imenuje rudarjenje procesov (angl. process mining). Rudarjenje procesov predstavlja uspešen primer prehoda akademskih zamisli in rešitev v poslovna okolja [3].

V prispevku bomo predstavili in umestili rudarjenje procesov v življenjski cikel upravljanja poslovnih procesov, na osnovi korakov algoritma Alfa pa bo pojasnjen postopek avtomatskega oblikovanja modela procesa iz podatkov sistemskoga dnevnika. Osrednji del prispevka je namenjen predstavitvi zmožnosti sodobnih rešitev za rudarjenje procesov, ki v postajajo v razvitih državah nepogrešljiv člen poslovne analitike, z njihovo pomočjo pa je možno



Slika 1: Življenjski cikel upravljanja poslovnih procesov [1]

sprejemati natančnejše procesne odločitve, ki temeljijo na operativnih podatkih.

## 2 OSNOVE RUDARJENJA PROCESOV

Kot že besedna zveza pove, je osnovni namen ruderjenja procesov »pridobivanje« procesov oziroma njihovih modelov iz osnovnih sestavin, to je (empiričnih) podatkov o procesih. Pri tem je pomembno izpostaviti, da lahko ruderjenje poteka popolnoma samodejno, s pomočjo algoritmov, ki na osnovi podatkov operativnega izvajanja procesov, generirajo modele procesov. Značilnost tako nastalih modelov procesov je visoka stopnja veljavnosti (a ne nujno popolnosti) oziroma dobro prileganje dejanski izvedbi tehničnega okolja in (skoraj) realno-časovna ažurnost modelov. Formalno je ruderjenje procesov definirano kot: »tehnike, oroda in metode odkrivanja, spremljanja in izboljševanja realnih procesov, ki temeljijo na pridobivanju znanja iz dnevnikov dogodkov informacijskih sistemov« [4].

Tabela 1: Tabelarični prikaz(poenostavljenega) medicinskega dnevnika dogodkov

Case ID	Activity	time:timestamp	lifecycle: transition	CRP	DiagnosticUrinary Sediment
XJ	ER Registration	7.11.2019 08:18	complete		TRUE
XJ	ER Triage	7.11.2019 08:29	complete		
XJ	ER Sepsis Triage	7.11.2019 08:37	complete		
XJ	CRP	7.11.2019 08:51	complete	16.0	
XJ	IV Liquid	7.11.2019 09:05	complete		
XJ	IV Antibiotics	7.11.2019 10:05	complete		
XJ	Admission NC	7.11.2019 11:11	complete		
XJ	Leucocytes	8.11.2019 08:00	complete		
I	ER Registration	9.11.2019 09:21	complete		TRUE
I	ER Triage	9.11.2019 09:34	complete		
I	Leucocytes	9.11.2019 09:42	complete		
I	CRP	9.11.2019 09:42	complete	9.0	

zuje Tabela 1, (po kakovosti jih je možno umestiti v pet razredov [4]) zato je potrebno pred samo izvedbo ruderjenja podatkov le te ustrezno pripraviti za obdelavo, kar je poznano pod okrajšavo ETL (angl. Extract, Transform, Load) oziroma: (1) pridobivanje podatkov iz informacijskih rešitev; (2) sintaktična in semantična pretvorba podatkov v obliko, ki je primerna za ruderjenje procesov; (3) nalaganje podatkov v ciljni sistem, na primer podatkovno skladišče ali relacijsko podatkovno zbirko. Omenjeni postopek bistveno olajša zapisovanje dnevnikov dogodkov v

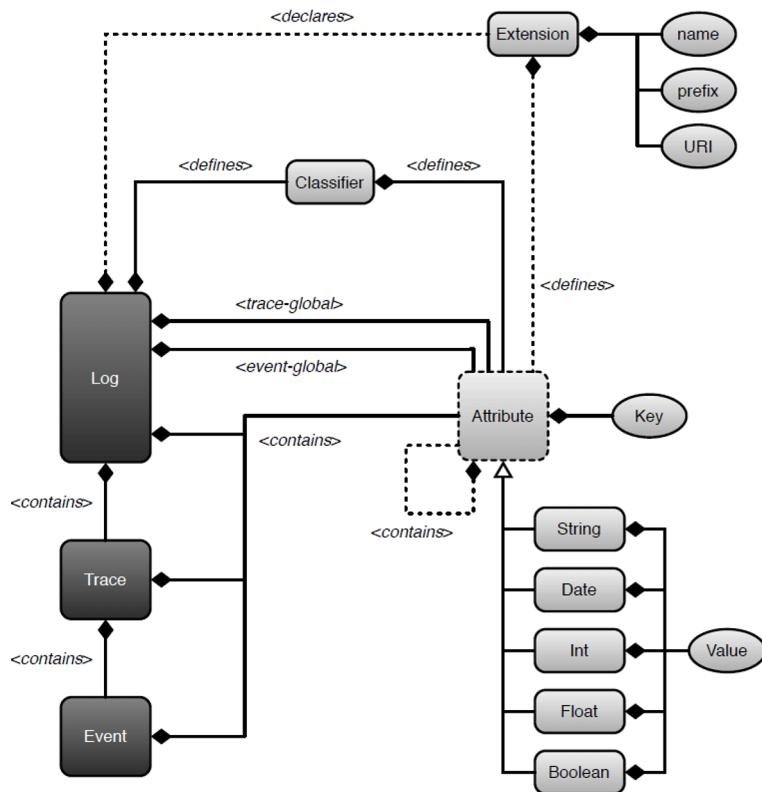
## 3 DNEVNIK DOGODKOV

Empirične podatke oziroma vhodno točko ruderjenja procesov najpogosteje predstavlja (transakcijski) dnevnik dogodkov, ki ga je možno s pomočjo algoritmov preoblikovati v model procesa, če so upoštevane naslednje predpostavke: (1) dnevnik dogodkov beleži dogajanje enega procesa; (2) posamezne dogodke (vrstice) je možno povezati s primerkom oziroma instanco procesa (angl. case, instance); (3) zapisi dogodki so rezultat izvedene aktivnosti procesa in (4) dnevnik dogodkov je popoln. Primer poenostavljenega dnevnika dogodkov, ki izpoljuje omenjene predpostavke, je v tabelični obliki ponazorjen v Tabela 1, kjer: (1) atribut »CaseID« predstavlja primer procesa; (2) »Activity« predstavlja naziv izvedene aktivnosti; in (3) »time:timestamp« predstavlja časovno značko dogodka zaključka aktivnosti.

V praksi se izkaže, da vhodni podatki v ruderjenje podatkov niso tako dobro strukturirani kot prika-

standardnih formatih, kot sta IEEE 1849-2016 XES (eXtensible Event Stream) in njegov predhodnik MXML (Mining eXtensible Markup Language). Slika 2 prikazuje Meta model standarda XES v obliki UML razrednega diagrama.

Iz zgornje slike je razvidno da XES datoteka oziroma dokument vsebuje 1 dnevnik dogodkov, ki je sestavljen iz množice sledi (angl. traces). Vsaka sled predstavlja zaporedje dogodkov (angl. event), ki pripadajo določenemu primerku izvedbe procesa. Tako dnevnik, kakor tudi sledi in dogodki, lahko imajo



Slika 2: Meta model XES [5]

množico dodatnih atributov, ki se lahko urejajo v hierarhično obliko. Določeni atributi se lahko opredelijo kot obvezni, na primer: vsaka sled mora imeti poimenovanja, vsak dogodek pa mora imeti časovno značko. Semantiko atributov določajo t.i. razširitve (angl. extensions).

Rudarjenje procesov iz dnevnikov dogodkov je povezani z nekaterimi izzivi [6]. Kot prvo, morajo biti dogodki povezani z določenim primerkom procesa, kar je lahko problematično v primeru dogodkov, ki so razpršeni v obsežni podatkovni bazi. Drugi izziv je povezan z granulacijo in formatom časovnih značk, ki se lahko razlikujejo v različnih tabelah podatkovne baze. Tretji izziv lahko predstavlja omejeno doseg dnevnika dogodkov, ki morda beleži le del celotnega procesa. Četrti izziv lahko predstavlja obsežne podatkovne zbirke poslovnih informacijskih sistemov, ki otežijo definiranje dnevnikov dogodkov za rudarjenje procesov. Peti izziv je povezan s stopnjo granulacije beleženih dogodkov, ki je lahko glede na dejanski proces večja ali manjša.

## 4 ALGORITMI RUDARJENJA PROCESOV

Avtomatizirano odkrivjanje procesov predstavlja tehniko pridobivanja modela procesa na osnovi dnevnika dogodkov z uporabo ustreznega algoritma. Algoritem, ki se najpogosteje uporablja za ponazoritev delovanja avtomatiziranega odkrivanja procesov je algoritem  $\alpha$  (alfa) (angl. alpha algorithm) in njegove izpeljanke ( $\alpha^+$ ,  $\alpha^{++}$ ,  $\alpha^\#$  in  $\alpha\$$ ) [6].

Kot samo rudarjenje procesov, ima tudi algoritem  $\alpha$  osnove v akademskem okolju, natančneje v teoriji zaporedij (multimnožice, kjer je pomembna urejenost oziroma vrstni red). Algoritem analizira relacije urejenosti med pari opravil v sledeh (angl. traces) (zaporedje dogodkov, urejenih po časovnih značkah, ki pripadajo istemu primerku) dnevnika dogodkov kot so: neposredni naslednik (angl. direct successor), vzročnost (angl. causality), sočasnost (angl. concurrency) in ekskluzivnost (angl. exclusiveness). Rezultat algoritma  $\alpha$  je mreža delovnega toka »W«, ki ohranja omenjene relacije dnevnika dogodkov L, kar zapišemo kot:

$$\alpha L = W.$$

```

<log xes.version="1.0" xes.features="nested-attributes" openxes.version="1.0RC7" xmlns="http://www.xes-standard.org/">
<extension name="Lifecycle" prefix="lifecycle" uri="http://www.xes-standard.org/lifecycle.xesext"/>
<extension name="Organizational" prefix="org" uri="http://www.xes-standard.org/org.xesext"/>
<extension name="Time" prefix="time" uri="http://www.xes-standard.org/time.xesext"/>
<extension name="Concept" prefix="concept" uri="http://www.xes-standard.org/concept.xesext"/>
<extension name="Semantic" prefix="semantic" uri="http://www.xes-standard.org/semantic.xesext"/>
<global scope="trace">
<string key="concept:name" value="__INVALID__"/>
</global>
<global scope="event">
<string key="concept:name" value="__INVALID__"/>
<string key="lifecycle:transition" value="complete"/>
</global>
<classifier name="MXML Legacy Classifier" keys="concept:name lifecycle:transition"/>
<classifier name="Event Name" keys="concept:name"/>
<classifier name="Resource" keys="org:resource"/>
<string key="source" value="Rapid Synthesizer"/>
<string key="concept:name" value="excercise4.mxxml"/>
<string key="lifecycle:model" value="standard"/>
<trace>
<string key="concept:name" value="Case3.0"/>
<event>
<string key="org:resource" value="UNDEFINED"/>
<date key="time:timestamp" value="2009-06-04T17:21:03.471+02:00"/>
<string key="concept:name" value="a"/>
<string key="lifecycle:transition" value="complete"/>
</event>
<event>
<string key="org:resource" value="UNDEFINED"/>
<date key="time:timestamp" value="2009-06-04T17:22:03.471+02:00"/>
<string key="concept:name" value="b"/>
<string key="lifecycle:transition" value="complete"/>
</event>
<event>
<string key="org:resource" value="UNDEFINED"/>
<date key="time:timestamp" value="2009-06-04T17:23:03.471+02:00"/>
<string key="concept:name" value="d"/>
<string key="lifecycle:transition" value="complete"/>
</event>
<event>
<string key="org:resource" value="UNDEFINED"/>
<date key="time:timestamp" value="2009-06-04T17:24:03.471+02:00"/>
<string key="concept:name" value="c"/>
<string key="lifecycle:transition" value="complete"/>
</event>
<event>
<string key="org:resource" value="UNDEFINED"/>
<date key="time:timestamp" value="2009-06-04T17:25:03.471+02:00"/>
<string key="concept:name" value="f"/>
<string key="lifecycle:transition" value="complete"/>
</event>
</trace>

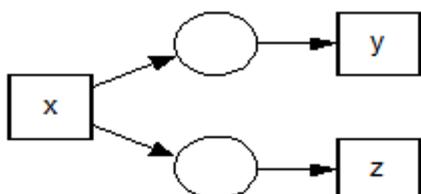
```

Slika 3: Izsek dnevnika dogodkov, zapisanega v formatu XES

Kot primer vzemimo vzporedni razcep oziroma razcep 'in' (angl. AND split) v mreži delovnega toka (Slika 4).

Kot je razvidno iz Slika 4, je vzporedni razcep (angl. AND split) sestavljen iz treh medsebojno povezanih opravil  $\{x,y,z\}$  v naslednjih zgoraj predstavljenih relacijah: vzročnost med opraviloma  $\langle x,y \rangle$  in  $\langle x,z \rangle$  ter relacijo sočasnosti med opraviloma  $\langle y,z \rangle$ , kar zapišemo kot:

$$x \rightarrow y, x \rightarrow z \wedge y/z,$$



Slika 4: Vzporedni razcep predstavljen v Petrijevi mreži

Podobno kot za vzporedni razcep, algoritem  $\alpha$  definira preslikave še za druge osnovne vzorce kontrolnega toka (angl. workflow patterns), kot so: zaporedje (angl. sequence), vzporedno združevanje (angl. AND join), ekskluzivni razcep (angl. XOR split) in ekskluzivno združevanje (angl. XOR join).

$$L_1 = [\langle a,b,c,d \rangle^3, \langle a,c,b,d \rangle^2, \langle a,e,d \rangle]$$

	$a$	$b$	$c$	$d$	$e$
$a$	$\#_{L_1}$	$\rightarrow_{L_1}$	$\rightarrow_{L_1}$	$\#_{L_1}$	$\rightarrow_{L_1}$
$b$	$\leftarrow_{L_1}$	$\#_{L_1}$	$\parallel_{L_1}$	$\rightarrow_{L_1}$	$\#_{L_1}$
$c$	$\leftarrow_{L_1}$	$\parallel_{L_1}$	$\#_{L_1}$	$\rightarrow_{L_1}$	$\#_{L_1}$
$d$	$\#_{L_1}$	$\leftarrow_{L_1}$	$\leftarrow_{L_1}$	$\#_{L_1}$	$\leftarrow_{L_1}$
$e$	$\leftarrow_{L_1}$	$\#_{L_1}$	$\#_{L_1}$	$\rightarrow_{L_1}$	$\#_{L_1}$

Slika 5: Sledi dnevnika dogodkov L1 (zgoraj) in njegov odoris (spodaj)

Na osnovi odtisa dnevnika dogodkov (angl. footprint) (Slika 5), ki predstavlja relacije kavzalnih ( $\rightarrow$ ), sočasnih (II) in ekskluzivnih (#) relacij vseh parov dogodkov vseh sledi dnevnika dogodkov  $L$  (Slika 5), nato algoritem  $\alpha$  izdela celovito mrežo delovnega toka v naslednjih osmih korakih: (1) določitev množice aktivnosti ozziroma prehodov Petrijeve mreže, ki se pojavijo v dnevniku dogodkov; (2) določitev vhodnih prehodov, ki predstavljajo začetne prehode v sledeh dnevnika dogodkov; (3) določitev izhodnih prehodov, ki predstavljajo končne prehode v sledeh dnevnika dogodkov; (4) identifikacija parov med-vzročnih (angl. inter-causal) in notranje-sočasnih (angl. intra-concurrent) aktivnosti in (5) redukcija pridobljenih množic na način, ki ohranja le nad-množice; (6) definiranje mest  $P$ , ki jih dodamo med prehode; (7) sintaktično ustrezno povezovanje mest in prehodov z relacijo toka  $F$  (angl. flow relation) in (8) združevanje rezultatov v z izrisom mreže delovnega toka.

Jedro algoritma  $\alpha$  predstavlja četrti in peti korak, kjer je poglavitni izzik določitev mest in pripadajočih povezav v mreži delovnega toka, na način, da se določita množici vhodnih in izhodnih prehodov zgoraj omenjenih mest (angl. places). Omenjeno je možno doseči s preureditvijo vrstic in stolpcov odtisa dnevnika dogodkov (Slika 5), na način, da se oblikujeta dve množici dogodkov, katerih elementi so med množicama vzročno povezani (povezava v mreži delovnega toka), medtem, ko znotraj posameznih množic niso v vzročni zvezi.

Med omejitve algoritma  $\alpha$ , spadajo t.i. kratke zanke v procesu, ki imajo dolžino ena (v sledi je več zaporednih enakih dogodkov) ali dva (v sledi je več zaporedno ponavljajočih parov dogodkov). V takšnih primerih algoritem  $\alpha$  ne zazna povezav s pripadajočimi prehodi.

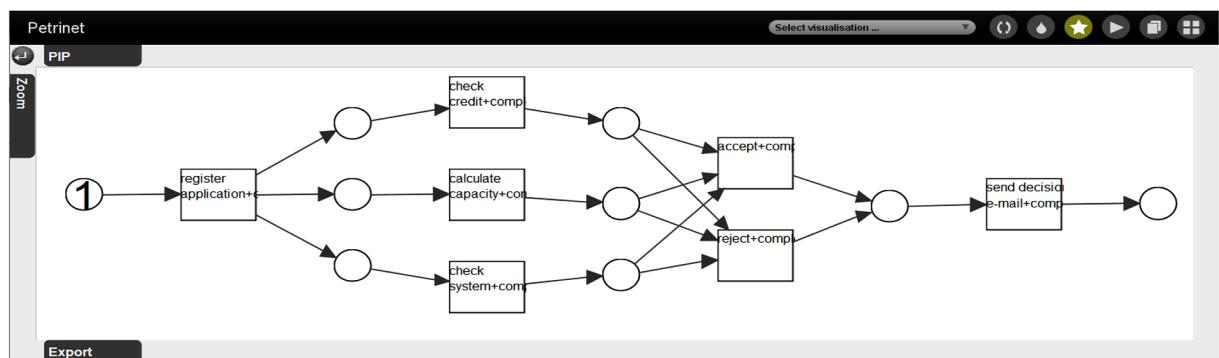
Poleg algoritma  $\alpha$  obstaja še množica algoritmov za odkrivanje procesov, kot so na primer [6]: hevristično rudarjenje (angl. heuristic mining), genetsko rudarjenje procesov (angl. genetic process mining), področno rudarjenje (angl. region-based mining), induktivno rudarjenje (angl. inductive mining) in njihove številne variacije, vključno z lastniškimi algoritmi, ki so vključeni v komercialne rešitve (na primer, Celonis). Orodje Apromore uporablja algoritem razcepljenega rudarjenja (angl. split miner) [7].

Razlog za poplavu algoritmov je v pomanjkljivosti posameznih algoritmov, kot so [6]: (1) stopnja prileganja (angl. fitness) ki opredeljuje, kako dobro se izdelan model procesa prilagaja podatkom v dnevniku ozziroma kako dobro je možno le tega replicirati iz izdelanega modela procesa; (2) enostavnost (angl. simplicity), ki opredeljuje preprostost izdelanega modela procesa; (3) generalizacija (angl. generalization), ki opredeljuje kako dobro algoritem predvideva dejanski model, ki morda presega zapise v dnevniku dogodkov (le ti najverjetneje niso popolni) in (4) natančnost (angl. precision), ki je nasprotna lastnost generalizacije in določa, v kolikšni meri model opisuje natančno to kar je opredeljeno v sledeh dnevnika dogodkov ozziroma, da model ne dovoljuje obnašanja, ki ni evidentirano v dnevniku dogodkov.

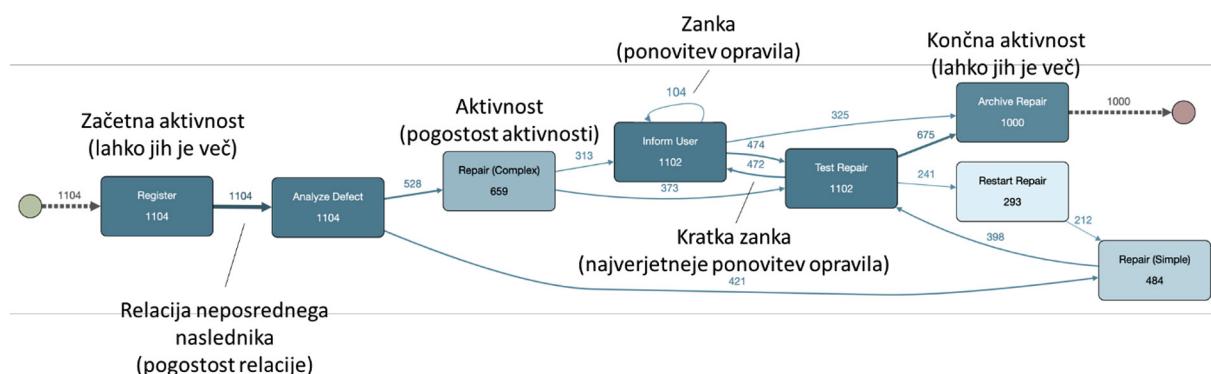
## 5 VIZUALIZACIJA PROCESOV

Modeli procesov, ki jih generirajo algoritmi za rudarjenje procesov, so najpogosteje vizualizirani v eni izmed naslednjih procesnih notacij: mreže delovnih tokov (angl. workflow maps), procesne mape (angl. process maps) in BPMN diagrami (Business Process Model and Notation).

Mreže delovnih tokov so podzvrst Petrijevih mrež (natančneje, imajo natanko en začetek in konec ter bi



Slika 6: Mreža delovnega toka v okolju ProM

Slika 7: Primer procesne mape, ki jo je generiralo okolje Apromore<sup>3</sup>

v primeru vpeljave prehoda med začetkom in koncem izkazovale lastnost »močne povezanosti«). Zaradi močnega teoretičnega ozadja in možnosti tako formalnega, kot vizualnega prikaza so zelo primerne za algoritmično obdelavo, prikazujejo pa lahko tako statično kakor tudi dinamično sliko procesa. Slika 6 prikazuje mrežo delovnega toka procesa pridobivanja kredita, ki je bila pridobljena iz testnega dnevnika dogodkov v formatu XES<sup>1</sup> s pomočjo algoritma Alfa implementiranega v orodju ProM<sup>2</sup>.

Slabost mreže delovnih tokov se kaže predvsem v njihovi praktični uporabnosti, saj zaradi konceptualne preprostosti (vsebujejo le tri teoretične koncepte: prehod, stanje in povezavo) ne nudijo neposredne podpore za višje-nivojske koncepte poslovnih procesov in so tako slabše razumljive za poslovne uporabnike.

Procesne mape (angl. process map, directly follows graph) so neformalna in preprosta notacija za prikaz poslovnih procesov, ki najpogosteje vključujejo le dva gradnika: (1) aktivnost, ki je predstavljena z vozliščem (najpogosteje pravokotnik) in (2) povezavo med vozlišči, ki predstavlja zaporedje izvedbe aktivnosti oz. pripadajočih dogodkov. V primeru rudarjenja procesov so procesne mape priljubljene zaradi preprostosti in dejstva, da rudarjenje procesov najpogosteje rezultira prav v modelih, ki predstavljajo množice aktivnosti in relacij med njimi.

Kot je razvidno iz Slike 7, so elementi procesnih map pogosto dopolnjeni še s »statističnim slojem«, na primer: trajanje ali pojavnost elementa. Le te je moč pridobiti s tehnikami rudarjenja procesov, predstavljajo pa pomembne informacije za procesne odločitve.

Zaradi kompleksnosti realnih procesov, predvsem iz vidika števila variacij izvedb enega procesa (varianta predstavlja vse sledi procesa z istim zaporedjem aktivnosti), so običajno tudi procesne mape kompleksne, zato orodja običajno nudijo možnosti abstrakcije pridobljenih modelov in sicer se najpogosteje omejuje prikaz glede na pogostost izvedbe aktivnosti ali povezav (na primer prikaz najpogosteje ali najredkeje izvedenih variant procesa). Slika 8 prikazuje procesno mape, ki jo generira okolje Celonis. Na desni strani so v grafični obliki ponazorjene frekvence variant izvedbe procesa in območje ter delež variant, ki so ponazorjene v prikazani procesni mapi. Iz Slike 8 je tako razvidno da procesna mapa prikazuje potek treh najpogosteje izvajanih sledi, ki skupno pokrivajo 77% vseh primerkov procesa.

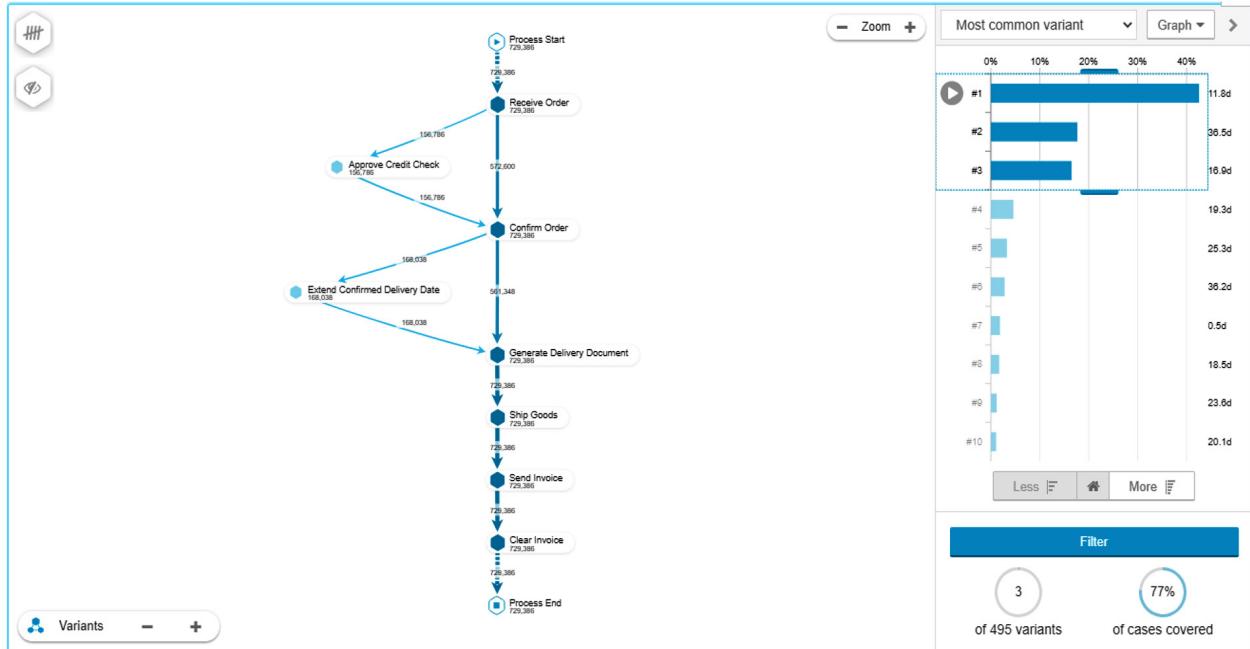
Drug prikaz istega procesa oziroma dnevnika dogodkov prikazuje Slika 9, ki vizualizira 495 variant procesa, ki pa skupaj predstavljajo le 8% vseh izvedb oziroma primerkov procesa.

Med slabosti procesnih map spada pomanjkanje procesnih konceptov, na primer težje je prepoznati pogojne in vzporedne tokove. Alternativa, ki odpravlja omenjeno slabost je uporaba BPMN 2.0, ki je de-facto in ISO standard (ISO/IEC 19510:2013) za modele procesov. Zaradi standardiziranosti tako notacije, kot tudi meta-modela, nudi le ta številne prednosti, kot so: bogat nabor konceptov poslovnih procesov, ki jih notacija podpira, prenosljivost modelov med orodji, možnosti simulacije in avtomatizacije procesov. Slika 10 prikazuje segment BPMN modela, ki ga je generiralo okolje Apromore na dnevniku iz Tabela

<sup>1</sup> <http://www.promtools.org/prom6/downloads/FutureLearn%20-%20Process%20mining%20with%20ProM%20-%20Event%20logs.zip>.

<sup>2</sup> <https://www.promtools.org/>.

<sup>3</sup> <https://apromore.org/>.



Slika 8: Abstrakcije modelov procesov v okolju Celonis<sup>4</sup> s prikazom najbolj pogostih variant

1 z uporabo »split miner« algoritma, ki je sposoben zaznati koncepte BPMN brez dodatnih transformacij med notacijami [3].

Slabost uporabe notacije izhaja predvsem iz omejitve orodij za ruderjenje procesov, ki generirajo že na videz drugačne modele, kot jih izdelajo analitiki in tudi v »omejenosti« algoritmov, ki so zmožni pre-

poznati le osnovne koncepte in vzorce kontrolnega toka. Zato je običajno izkoriščen le majhen del građnikov notacije BPMN 2.0.

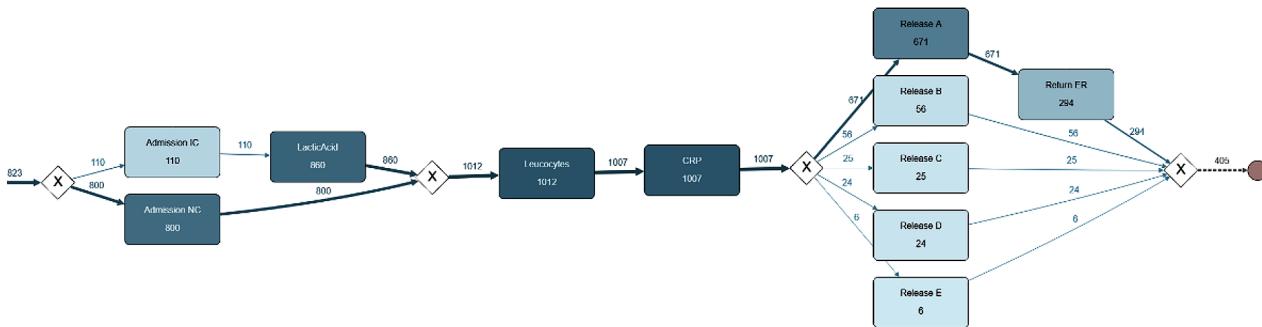
## 6 ZMOŽNOSTI RUDARJENJA PROCESOV

Ključna lastnost ruderjenja procesov je močna povezanost med modeli procesov in realnostjo, ki je



Slika 9: Abstrakcije modelov procesov v okolju Celonis s prikazom najredkeje izvajanih variant

<sup>4</sup> <https://www.celonis.com/>.

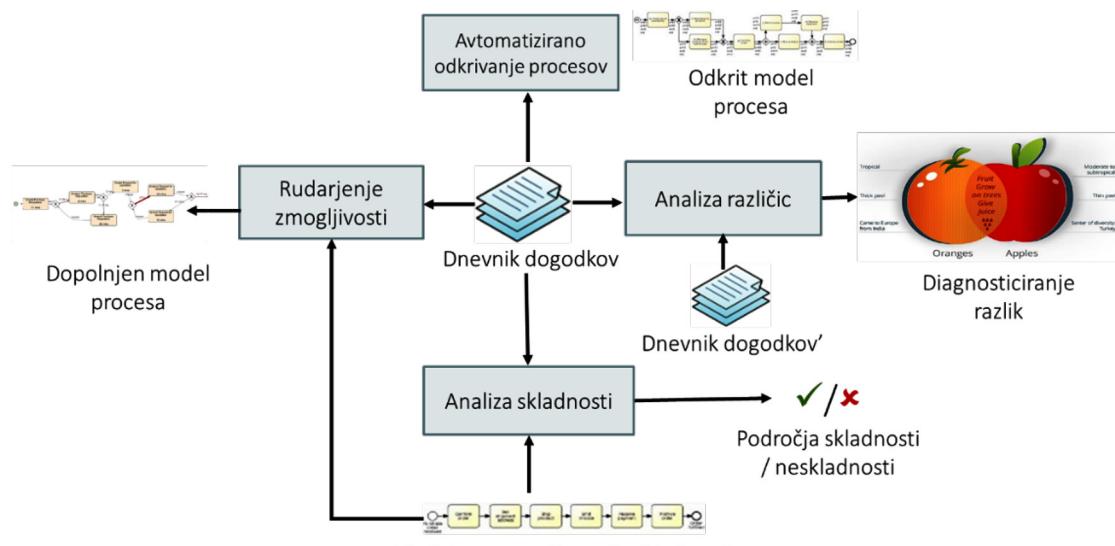


Slika 10: Segment modela BPMN, z eksplicitnimi elementi kontrolnega toka (BPMN), ki ga je generiralo okolje Apromore

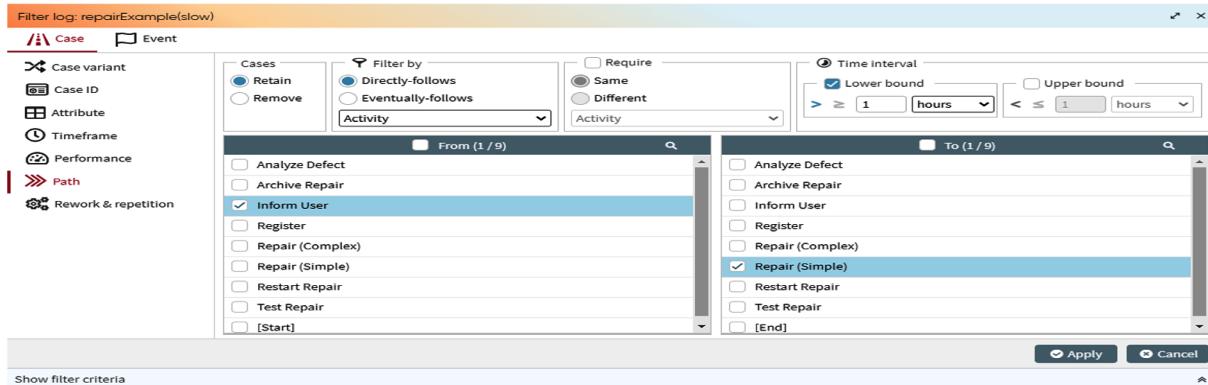
lahko definirana na tre načine: »play-in«, »play-out« in »replay«. Primer »play-in« je generiranje modela procesa na osnovi dnevnika dogodkov. »Play-out« predstavlja nasprotno aktivnost in sicer generiranje dnevnika dogodkov na osnovi definiranega modela procesa. Zadnji način »replay« predstavlja kombinacijo predhodnih načinov, kjer se na osnovi dnevnika dogodkov generira model procesa, le tega pa nato uporabimo za generiranje novega dnevnika dogodkov. Način »replay« je primeren za ugotavljanje skladnosti med dejanskim in generiranim dnevnikom dogodkov ali za ponazoritev dodatnih informacij v modelu procesa (na primer: frekvence in trajanje). Zato lahko s tehnikami in orodji za rudarjenje procesov poleg avtomatiziranega odkrivanja procesov, ki je bilo podrobneje predstavljeno v predhodnem poglavju, izvajamo še druge procesne aktivnosti (Slika 11), ki so predstavljene v nadaljevanju.

## 7 PREVERJANJE SKLADNOSTI

Preverjanje skladnosti (angl. conformance checking) omogoča primerjavo izvajanega modela (ozziroma dnevnika dogodkov) z definiranimi poslovnimi pravili ali definiranim modelom procesa (angl. prescribed process model) in je s tem relevantno za usklajevanje poslovanja z zahtevami in za presojanje poslovanja (angl. auditing). Primeri poslovnih pravil, ki jih lahko preverjamamo, so: (1) omejitve kontrolnega toka, kot je analiza izvajanja obveznih aktivnosti (na primer: odobritve zahtevkov ali obvezna kontrola kakovosti); (2) omejitve nivoja storitev ozziroma SLA (angl. service level agreement), kot je najdaljši dovoljen čas izvajanja aktivnosti, regije ali procesa; (3) omejitve virov kot je »ločevanje dolžnosti« (na primer: ista oseba ne sme izvesti dveh zaporednih aktivnosti) in (4) identifikacija redkih primerkov izvedbe, ki so potencialno neskladni s



Slika 11: Zmožnosti rudarjenja procesov [8]



Slika 12: Časovna analiza skladnosti v okolju Apromore

poslovnimi pravili. Rezultat analize preverjanja skladnosti je seznam odstopanj od pravil ali definiranega modela procesa. Slika 12 prikazuje analizo časovne skladnosti izvedbe storitve popravila, kjer imamo na primer opredeljeno časovno pravilo »čakanje med informiranjem uporabnika in izvedbo preprostega opravila ne sme trajati več kot eno uro«. Orodje Apromore lahko odkrije vse primerke procesa, ki trajajo dlje od navedenega.

## 8 RUDARJENJE ZMOGLJIVOSTI

Z rudarjenjem zmogljivosti pridobimo dodatne informacije o modelih procesov, ki lahko vodijo v njihove izboljšave. Rezultat rudarjenja zmogljivosti so grafi zmogljivosti in modeli procesov, ki so dopolnjeni z informacijami kot so trajanja aktivnosti ali pogledi na procese iz vidika določenega vira. Na tak način lahko odkrivamo ozka grla (angl. bottleneck analysis) v izvajaju, kot so: (1) aktivnost je počasna zato predstavlja ozko grlo; (2) vse vhodne povezave v aktivnost so počasne, zato je najverjetnejše ozko grlo vir, ki mu je dodeljena izvedba aktivnosti; in (3) počasna je predaja dela (angl. handoff) med dvema viroma (odebeljena povezava »21 mins« na Slika 13).

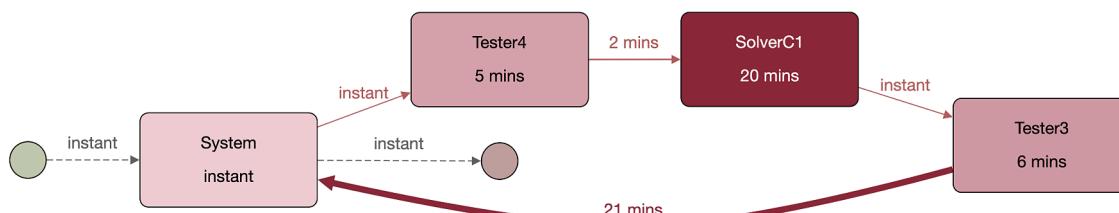
Pogled virov lahko prav tako omogoči identifikacijo potencialno preobremenjenih udeležencev pro-

cesa (velika frekvenca ali visoko trajanje izvedbe) ali premalo obremenjenih udeležencev procesa (nizka frekvenca ali kratko trajanje izvedbe).

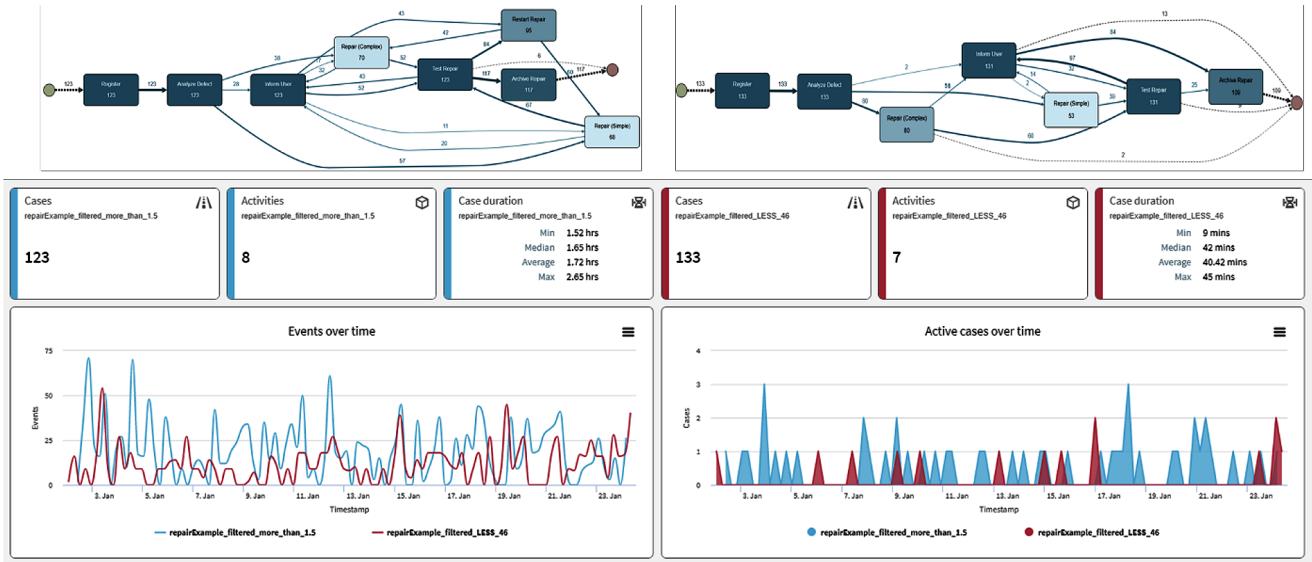
Na zmogljivost delovanja lahko prav tako bistveno vplivajo ponovitve opravil, ki so lahko posledica slabo ali nepopolno opravljenega dela, ki se kaže kot: (1) zankanje ene aktivnosti (angl. self loop); (2) kratke zanke, kjer se izmenično večkrat izvedeta dve aktivnosti (angl. short loop, ping-pong behavior); ali (3) posredne ponovitve, kjer se po istem vzorcu ponavlja ista skupina aktivnosti (angl. indirect repetition).

## 9 ANALIZA RAZLIČIC

Analiza različic (angl. variant analysis) temelji na primerjavi dveh ali več različic dnevnikov dogodkov istega procesa, ki tako predstavljajo različne variante procesa (na primer, primerjava vseh primerkov procesa, ki so se uspešno zaključili glede na neuspešne). Primerjava variant procesov poda vpogled na vprašanja tipa »zakaj?«, na primer: (1) zakaj se določeni primerki procesa (ki smo jih združili v eno izmed variant procesa) izvajajo hitreje kot drugi? (2) Zakaj se določeni primerki procesa uspešno zaključijo, medtem ko se drugi neuspešno? (3) Zakaj je vir, ki je vključen v izbrano varianto procesa manj učinkovit kot drugi?



Slika 13: Analiza ozkih grl iz pogleda virov v okolju Apromore



Slika 14: Primerjava modelov primerkov istega procesa, ki trajajo manj kot 45 minut (levo) s primerki ki trajajo več kot 90 minut (desno) in statistična primerjava v nadzorni plošči (spodaj)

Odgovore na zgornja vprašanja lahko pridobimo z enim izmed naslednjih pristopov analize različic procesov: (1) analizo metrik uspešnosti (angl. performance measures) različic procesov; (2) analizo različic procesov glede na čas izvedbe (na primer: analiza in primerjava različic procesov, ki so se izvajali pred in med pandemijo); (3) analiza različic procesov glede na lastnosti primerkov (na primer: vrsta izdelka, segment kupcev, geografsko področje, ipd.)

## 10 ZAKLJUČEK

Digitalna preobrazba in optimizacija poslovanja je prepletena s tehnološkimi inovacijami, ki morajo zagotavljati hiter in veljaven vpogled v delovanje organizacij, temelječ na realnih podatkih, na način, ki je razumljiv vsem vpletenim. Med ključne tehnike za doseganje navedenega spada rudarjenje procesov, ki izkorišča močno povezanost med fizično in informacijsko realnostjo (digitalni dvojček) poslovanja, v kateri se poslovni dogodki beležijo v realnem času, le ti pa so uporabljeni za usmerjanje, prilagajanje in nadzor poslovnih procesov. Rudarjenje procesov postaja del rutine večjih podjetij razvitih držav [3], k čemu je pripomogel tudi širok nabor »enterprise-ready« orodij za rudarjenje procesov. Le ta so dostopna različnim vrstam in potrebam organizacij in omogočajo relativno nizek vstopni prag v aktivnosti rudarjenja procesov. Slabost vpeljave orodij je pogosto, da so le ta v podjetjih implementirana v omejenem obsegu in zato ne pokrivajo celotnega poslovanja.

Poglavitna izizza širše vpeljave rudarjenja procesov ostajata kakovost podatkov in človeški dejavniki. Izkušnje kažejo, da je okoli 80% časa potrebnega za lociranje, izbiranje, pridobivanje in transformacijo podatkov, pogosto pa omenjene aktivnosti odkrijejo tudi težave s kakovostjo podatkov, ki jih je potrebno odpraviti neodvisno od rudarjenja procesov. Človeški dejavniki so pogosto povezani z nepoznavanjem področja rudarjenja procesov in »strahom« pred odkritjem dejanskih procesov, ki bi lahko izpostavili pomanjkljivo vodenje, neučinkovitosti ali neskladnosti med operativnih delovanjem in predpisi.

V preteklem desetletju se je rudarjenje procesov uveljavilo predvsem kot tehnologija za odkrivanje in vizualizacijo realnih procesov, v prihodnosti pa se obeta razvoj področja v smer optimizacije procesov, podprtje z umetno inteligenco [9]. Prvi trend je robotsko rudarjenje procesov (angl. robotic process mining), ki omogoča odkrivanje rutinskih digitalnih opravil iz dnevnikov uporabniških vmesnikov (angl. UI log), s pomočjo katerih se lahko nato generirajo avtomatske skripte. Drugi trend je vzročno rudarjenje procesov (angl. causal process mining), ki omogoča odkrivanje vzročno-posledičnih povezav med specifikami primerkov procesov in njihovimi rezultati (na primer, primerek procesa se izvede drugače v kolikor je stranka iz določene regije). Odkrivanje omenjenih povezav lahko vodi v izboljšave procesov in višje zadovoljstvo deležnikov. Tretji trend je »kaj – če« rudarjenje procesov (angl. what-if process mi-

ning), ki namesto analize obstoječega stanja omogoča simulacije delovanja procesov v primeru spremembe določenih vhodnih podatkov. Na primer, »kako se bo odzval proces, če se število zahtevkov podvoji?«. Četrти trend je predpisano ali normativno spremeljanje procesov (angl. prescriptive process monitoring), ki s pomočjo strojnega učenja omogoča predvidevanja (negativnih) rezultatov primerkov (na primer, ali se bo določen primerek zaključil pravočasno). Peti trend rudarjenja procesov v prihodnosti je avtomatizirano izboljševanje procesov (angl. automated process improvement), ki za razliko od trenutnih pristopov omogoča avtomatizirano vpeljavo sprememb procesov, ki izboljšujejo izbran indikator (na primer: stroški, čas in stopnja napak).

Izjemne razmere, kot je pandemija, so pokazale kako pomembna je digitalizacija, procesi, zanesljivi podatki in zmožnost hitrih prilagoditev novim razmeram. Nagle spremembe v poslovanju se odražajo v naglih spremembah procesov, ki jih je možno zagotoviti z ustrezno procesno avtomatizacijo in spremljati s tehnikami in tehnologijami rudarjenja procesov.

## LITERATURA

- [1] M. Dumas, M. L. Rosa, J. Mendling, in H. A. Reijers, *Fundamentals of Business Process Management*. Springer Berlin Heidelberg, 2018. [Na spletu]. Dostopno na: <https://books.google.si/books?id=KgVTDwAAQBAJ>
- [2] G. Jošt, J. Huber, M. Heričko, in G. Polančič, »Improving cognitive effectiveness of business process diagrams with opacity-driven graphical highlights«, *Decision Support Systems*, let. 103, str. 58–69, nov. 2017, doi: 10.1016/j.dss.2017.09.003.
- [3] M. Kerremans, S. Searle, T. Srivastava, in K. Iijima, »Market Guide for Process Mining«, Gartner, sep. 2020. Pridobljeno: sep. 08, 2021. [Na spletu]. Dostopno na: <https://www.gartner.com/doc/reprints?id=1-24ARMY34&ct=201002&st=sb>
- [4] W. van der Aalst idr., »Process Mining Manifesto«, v *Business Process Management Workshops*, let. 99, F. Daniel, K. Barkaoui, in S. Dustdar, Ur. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012, str. 169–194. doi: 10.1007/978-3-642-28108-2\_19.
- [5] G. Acampora, A. Vitiello, B. N. D. Stefano, W. M. P. van der Aalst, C. W. Günther, in E. Verbeek, »IEEE 1849: The XES Standard: The Second IEEE Standard Sponsored by IEEE Computational Intelligence Society [Society Briefs]«, *IEEE Comput. Intell. Mag.*, let. 12, št. 2, str. 4–8, 2017, doi: 10.1109/MCI.2017.2670420.
- [6] W. M. P. van der Aalst, *Process Mining: Data Science in Action*, 2nd ed. 2016 edition. New York, NY: Springer, 2016.
- [7] A. Augusto, R. Conforti, M. Dumas, M. La Rosa, in A. Polyvyanyy, »Split miner: automated discovery of accurate and simple business process models from event logs«, *Knowl/Inf Syst.*, let. 59, št. 2, str. 251–284, maj 2019, doi: 10.1007/s10115-018-1214-x.
- [8] „Process Mining 101«. Pridobljeno: sep. 09, 2021. [Na spletu]. Dostopno na: <https://apromore.org/process-mining-101/>
- [9] M. Dumas, »Process Mining in 2021 and Beyond«, mar. 09, 2021. Pridobljeno: sep. 09, 2021. [Na spletu]. Dostopno na: <https://apromore.org/whitepaper-process-mining-in-2021-and-beyond>

**Gregor Polančič** je znanstveni svetnik in izredni profesor na področju informatike. Spada med vodilne raziskovalce na področjih modeliranja poslovnih procesov in konceptualnega modeliranja v informatiki, tehnik in tehnologij upravljanja poslovnih procesov, tehnologij komuniciranja in sodelovanja. Bil je gostujuči profesor in raziskovalec na številnih tujih akademskih institucijah, recenzent številnih vrhunskih znanstvenih revij in član več odborov znanstvenih srečanj. Njegova bibliografija obsega preko 300 zapisov, od tega preko 30 izvirnih znanstvenih člankov s faktorjem vpliva.

**Mateja Kocbek Bule** je asistentka in doktorska študentka na Fakulteti za elektrotehniko, računalništvo in informatiko, Univerze v Mariboru. Med njene interesne dejavnosti spada predvsem področje upravljanja poslovnih procesov.

# ► Funkcionalnosti in uporaba portala za paciente zVEM in centralnega registra podatkov o pacientu

Živa Rant, Dalibor Stanimirović, Jure Janet  
 Nacionalni inštitut za javno zdravje, Trubarjeva 2, 1000 Ljubljana  
 ziva.rant@nijz.si, dalibor.stanimirovic@nijz.si, jure.janet@nijz.si

## Izvleček

eZdravje, ki ga od leta 2015 dalje vodi Nacionalni inštitut za javno zdravje (NIJZ), je eden ključnih dolgoročnih ciljev digitalizacije javnega sektorja v Sloveniji. Epidemija covid-19 je v močno vplivala tako na razvoj celotne zdravstvene informatike v Sloveniji, kot tudi na razvoj rešitev eZdravja. Posebno velik napredek sta v zadnjih letih doživelji rešitvi Zdravstveni portal za paciente zVEM in Centralni register podatkov o pacientu. Prispevek predstavlja opis in analizo teh dveh rešitev, njune novosti in podatke o njuni uporabi. Z vidika pacienta je razvoj in vzpostavitev zdravstvenega portala za paciente zVEM zagotovo ena izmed večjih pridobitev v zadnjih desetletjih. Portal zVEM je v času epidemije prevzel pomembno vlogo obveščanja in ozaveščanja prebivalstva. Podatki, ki se prikazujejo preko Portala zVEM, se črpajo iz CRPP. Danes je CRPP najkompleksnejši javni informacijski sistem v Sloveniji. Uporaba portala zVEM in CRPP v zadnjih dveh letih eksponentno narašča. Čeprav so rešitve eZdravja v zadnjih letih doživele nesluten razvoj, bo potrebno v prihodnje vložiti še mnogo napora s strani vseh deležnikov ter zagotoviti dodatne človeške in materialne vire, če bomo želi ohraniti doseženi napredek in mogoče celo pospešiti razvojni trend na področju zdravstvene informatike v Sloveniji.

**Ključne besede:** Centralni register podatkov o pacientu, digitalizacija, eZdravje, portal za paciente zVEM, zdravstvena informatika, funkcionalnost, uporaba.

## Abstract

eHealth, which has been led by the National Institute of Public Health (NIJZ) since 2015, is one of the key long-term goals of the public sector in Slovenia. Despite certain challenges, great progress has been made in the field of eHealth solutions in recent years. The COVID-19 epidemic has in many ways marked the development of the entire healthcare informatics in Slovenia. The paper presents an in-depth analysis of the functionality and use of the zVEM web portal and the Central Registry of Patient Data (CRPD) in recent years, especially during the COVID-19 epidemic. From the patient's point of view, the development and establishment of the zVEM patient portal is certainly one of the most important achievements in recent decades. During the epidemic, the zVEM portal took on an important role in informing and raising public awareness. The data displayed via the zVEM Portal is drawn from the CRPD. Today, this is without a doubt the most complex public information system in Slovenia. The use of the zVEM portal and CRPD has been growing exponentially in the last two years. Although eHealth solutions have undergone unprecedented development in recent years, much effort will have to be made by all stakeholders in the future and additional human and material resources will have to be provided if we want to maintain the progress and perhaps even accelerate the development trend in healthcare informatics in Slovenia.

**Keywords:** Central Registry of Patient Data, digitalization, eHealth, patient portal zVEM, healthcare informatics, functionality, usage

## 1 UVOD

Učinkovita in celovita digitalna transformacija slovenskega zdravstvenega sistema je ena izmed temeljnih sprememb, ki naj bi pripomogla k bolj uspešnemu spopadanju s številnimi izzivi, ki se nahajajo

pred slovenskim zdravstvom. Izkušnje razvitih držav kažejo (Bokolo, 2021; Arcury et al., 2020; Petrova, Balyka in Kachan, 2000) da imajo uspešno izvedeni projekti digitalizacije zdravstva izjemno velik strateški pomen za nadaljnji razvoj zdravstvenega sistema,

kažejo pa tudi širše implikacije v smeri povečanja družbene blaginje in gospodarske rasti (Evropska komisija, 2018). Projekt digitalizacije slovenskega zdravstva (eZdravje), ki sledi nacionalnim, evropskim in tudi usmeritvam Svetovne zdravstvene organizacije (SZO), je bil eden ključnih dolgoročnih ciljev javnega sektorja v Sloveniji. Celotna zasnova projekta eZdravje in razvojne smernice temeljijo na izhodiščih, ki so bile opredeljene v krovнем dokumentu »eZdravje2010 Strategija informatizacije slovenskega zdravstvenega sistema 2005-2010« iz leta 2005 in ga je pripravilo Ministrstvo za zdravje (Ministrstvo za zdravje, 2005).

Izčrpen pregled razmer na področju kaže, da težave, s katerimi se že od vsega začetka srečuje projekt digitalizacije slovenskega zdravstva (eZdravje), na eni strani izhajajo iz tehnično-tehnoloških značilnosti obstoječih ter povečini razdrobljenih zdravstvenih informacijskih sistemov (ZIS), ki so posledica neusklenjenega razvoja na področju zdravstvene informatike v zadnjih desetletjih. Na drugi strani pa gre odgovornost za obstoječe stanje pripisati predvsem odločevalskim krogom, ki so razvoj zdravstvene informatike v tem obdobju prepustili lastnim pobudam, potrebam in partikularnim interesom posameznikov na ravni zdravstvenih zavodov (ali celo oddelkov), brez enotnih strateških usmeritev. Poleg tega pristojni v tem obdobju niso uspeli spodbuditi razvoja in uresničitve projekta digitalizacije z močnejšo politično (finančno, kadrovsko, organizacijsko) podporo ter oblikovanjem moderne in konsistentne strategije na področju.

Posledice navedenih vzrokov se odražajo v določenih izzivih, ki jih je Nacionalni inštitut za javno zdravje (NIJZ) zaznal v teku dosedanjih aktivnosti za vesopšno digitalizacijo slovenskega zdravstva in implementacijo rešitev eZdravja:

- ozka usmerjenost posameznih deležnikov v lastno strokovno področje brez zavedanja o soodvisnosti vseh deležnikov zdravstvenega sistema;
  - pomanjkanje kompetentnih strokovnjakov s področja informatike pri izvajalcih zdravstvene dejavnosti, ki bi skrbeli za ustrezno vzdrževanje in delovanje rešitev eZdravja;
  - nezadostna sredstva za digitalizacijo pri izvajalcih zdravstvene dejavnosti in na NIJZ, ki skrbi za razvoj, vzdrževanje in nadgradnje centralnih nacionalnih rešitev eZdravja.
- Navkljub navedenim izzivom, pomanjkanju enotnih strateških dokumentov (strategija digitalizacije zdravstva se pripravlja šele v zadnjem letu) in nezadostnemu vlaganju na področju zdravstvene informatike je v zadnjih štirih letih prišlo do velikega napredka pri razvoju in implementaciji tako nekaterih temeljnih infrastrukturnih rešitev kot tudi določenih uporabniških aplikacij eZdravja. Glede na dinamiko dogodkov od objave prvega strateškega dokumenta na področju digitalizacije zdravstva iz leta 2005 predstavlja implementacija rešitev eZdravja, ki je bila izvedena od začetka leta 2016 dalje, pomemben mejnik, ki bo nedvomno v veliki meri določal nadaljnji razvoj slovenskega zdravstvenega sistema. Tukaj je treba poudariti, da kljub merljivim uspehom rešitev eZdravja v zadnjem obdobju, kar dokazujejo tako nacionalne evalvacije (Vrednotenje učinkov implementacije projekta eZdravje: eRecept in eNaročanje, Ministrstvo za javno upravo, 2019) kot tudi mednarodne evalvacije (Evropska komisija, Indeks digitalnega gospodarstva in družbe – DESI, 2019), kjer se je Slovenija glede na uporabo eZdravja uvrstila na šesto mesto, glede na uporabo eRecepta pa na tretje mesto med državami članicami EU, eZdravje še vedno ne uživa takšnega ugleda, kot bi si ga zaslužilo.
- Rešitvam eZdravja, ki jih je NIJZ prevzel od Ministrstva za zdravje leta 2015, smo v letih 2020 in 2021 zaradi epidemije covid-19 dodali še dve rešitvi: testiranje na covid-19 in naročanje na cepljenje proti covid-19 (NIJZ, 2021a). NIJZ upravlja nacionalne rešitve eZdravja že od konca leta 2015 in ves čas skrbi za izboljšave in nadgradnje rešitev. Vendar sta leti 2020 in 2021 v tem pogledu res posebni, saj je epidemija covid-19 povzročila, da običajen način dela pri tem ni bil mogoč (Stanimirović in Matetić, 2020). Vse nadgradnje je bilo potrebno razviti in uvesti v čim krajšem času. Za nekatere rešitve smo lahko uporabili že

obstoječe rešitve s prilagoditvami, nekatere rešitve je bilo potrebno narediti na novo. Zadnji dve leti še posebej izstopata Zdravstveni portal za paciente zVEM in Centralni register podatkov o pacientu (CRPP). Skladno z navedenimi izhodišči se prispevek v nadaljevanju osredotoča na sledеča raziskovalna cilja, in sicer opis in analizo razvoja ter funkcionalnosti in uporabe Zdravstvenega portala za paciente zVEM in CRPP.

## 2 METODE

Prispevek predstavlja poglobljeno analizo funkcionalnosti in uporabe spletnega portala zVEM in CRPP. Analiza je bila na eni strani izvedena na podlagi pregleda literature s tega področja (Tulu et al., 2021; Glöggler & Ammenwerth, 2021), ter projektne dokumentacije in tehničnih specifikacij spletnega portala zVEM in CRPP, na drugi strani pa na podlagi izkušenj ter strokovnega mnenja strokovnjakov na NIJZ, ki upravljajo z rešitvami eZdravja (tudi s portalom zVEM in CRPP) in dejanskih statističnih podatkov o uporabi portala zVEM in CRPP iz administratorskega modula samih rešitev (Sim & Waterfield, 2019). Izbira raziskovalne metode je temeljila na posebnostih raziskovalnega področja in dejству, da je celotno področje digitalizacije zdravstva v Sloveniji še vedno v relativno zgodnji fazi, zato obstaja le ozek krog strokovnjakov z ustreznim znanjem in izkušnjami na tem področju. Slednji metodološki pristop je omogočil tako vpogled v dosedanja teoretska in tehnološka izhodišča tovrstnih digitalnih rešitev, kot tudi empirični pregled dejanskega stanja, razvojnih faz in uporabe spletnega portala zVEM in CRPP v slovenskem zdravstvenem sistemu in širšem družbenem okolju (Mohajan, 2018). Sodelovanje strokovnjakov z NIJZ pri raziskavi je poleg vpogleda v tehnološko / tehnične, statistične in upravljavške vidike delovanja spletnega portala zVEM in CRPP, omogočilo tudi kritičen in temeljit vpogled v uporabniške vidike omenjenih rešitev. Strokovnjaki z NIJZ so namreč dobro seznanjeni z uporabniškimi izkušnjami pacientov in zdravstvenih delavcev na terenu ter njihovim zadovoljstvom s spletnim portalom zVEM in CRPP, saj skrbniki rešitev vsakodnevno sodelujejo pri reševanju zahtevkov in odgovarjanju na vprašanja preko Službe za pomoč uporabnikom, ki je v letu 2020 zabeležila 15.217, do konca novembra 2021 pa že 104.684 zahtevkov uporabnikov rešitev eZdravja iz celotne Slovenije (NIJZ, 2021b). Ogromen skok v šte-

vilu zahtevkov oz. vprašanj v letu 2021 gre pripisati predvsem velikemu zanimanju državljanov za načrtanje na cepljenje proti covidu-19 in pridobivanje digitalnih covid potrdil. Glede na to, da strokovnjaki z NIJZ sodelujejo pri obravnavi in reševanju tako velikega števila zahtevkov oz. vprašanj uporabnikov na letni ravni, lahko podajo relativno zanesljivo in objektivno oceno tako uporabniške izkušnje na eni strani, kot tudi tehnološke ustreznosti in kakovosti rešitev eZdravja.

Analiza funkcionalnosti in uporabe spletnega portala zVEM in CRPP, v smislu pregleda literature s tega področja ter projektne dokumentacije in tehničnih specifikacij spletnega portala zVEM in CRPP, je bila izvedena v prvi polovici leta 2021. Strukturirani razgovori s strokovnjaki NIJZ in pridobitev statističnih podatkov iz poslovnih in administratorskih modulov pa so bili izvedeni v obdobju od junija do decembra 2021.

Prispevek se osredotoča na portal zVEM in CRPP predvsem zaradi njune uporabnosti in pomembnosti tako za paciente kot tudi zdravstvene delavce ter velikega napredka v zadnjih dveh letih. Sinteza ugotovitev iz literature, uporabniških funkcionalnosti iz tehnične dokumentacije, statističnih poročil ter stališč strokovnjakov z NIJZ omogoča oblikovanje verodostojnih in na preverljivih podatkih temelječih zaključkov glede izpostavljenih raziskovalnih ciljev. Uporaba zgoraj opredeljenega metodološkega okvira vključujoč kombinacijo različnih pristopov ter tehnik zbiranja podatkov je bila ključnega pomena za verodostojnost analize funkcionalnosti in uporabe spletnega portala zVEM in CRPP. Celovita analiza podatkov, pridobljenih iz razneterih virov in strukturiranih razgovorov s strokovnjaki NIJZ, je v sklepni fazi raziskave zagotavljala ključno osnovo za interpretacijo podatkov ter oblikovanje konsistentnih zaključkov glede raziskovalnih izhodišč prispevka, ki naslavljajo funkcionalnosti in uporabo Zdravstvenega portala za paciente zVEM in CRPP.

## 3 REZULTATI

### 3.1 Zdravstveni portal za paciente zVEM

Zagotovo je največji razvoj v zadnjih dveh letih doživel rešitev Zdravstveni portal za paciente zVEM – zdravje vse na enem mestu (Stanimirović, 2021). Portal zVEM je bil zasnovan kot povezovalna storitev, osrednje stičišče osnovnih rešitev eZdravja

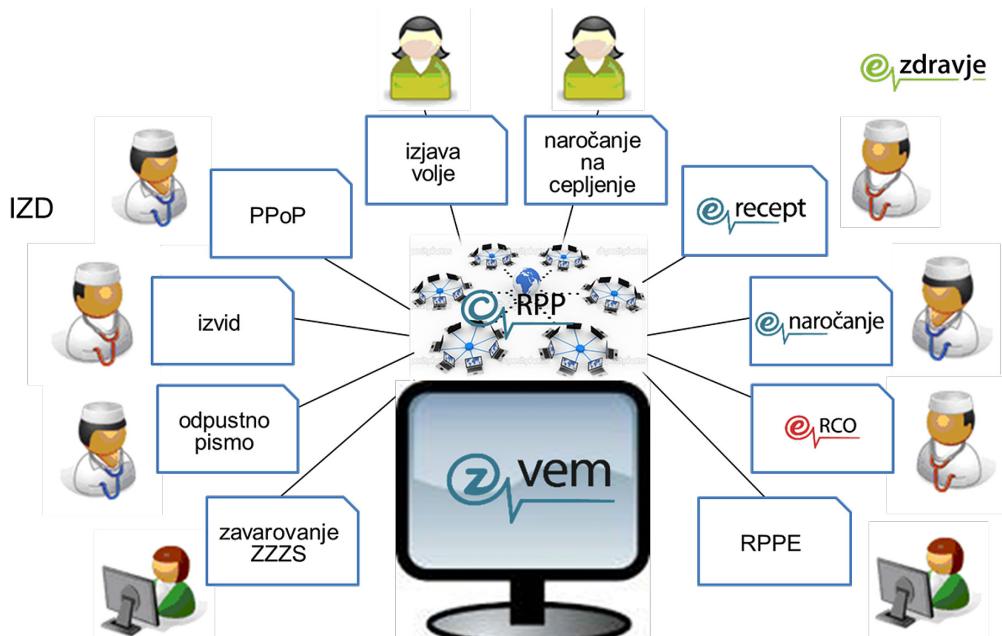
za paciente, za omogočanje varnega in učinkovitega dostopa do njihovih napotnic, receptov, izvidov in drugih dokumentov in naročanje na sekundarne storitve in pregledovanje čakalnih dob (Janet & Stanimirović, 2020). Z vidika pacienta je razvoj in vzpostavitev zdravstvenega portala za paciente zVEM zagotovo ena izmed večjih pridobitev v zadnjih desetletjih (van Gemert-Pijnen, 2011). Tehnično je bila rešitev vzpostavljena ob zaključku projekta eZdravje novembra 2015. Polna uporaba z možnostjo registracije je bila zagotovljena v začetku leta 2017 (Rant et al., 2018). Dostop do vseh funkcionalnosti je možen preko sistema SI-PASS s kvalificiranim digitalnim potrdilom ali smsPASS-om. Portal zVEM uporabnikom omogoča varen in zanesljiv dostop do njihovih podatkov v zbirkah eZdravja in dostop do storitev eZdravja. Uporabnikom ponuja še aktualne vsebine s področja javnega zdravja. Vsebuje določene funkcionalnosti za izvedbo izobraževanj (e-učilnice) in anket, upravljavcem Portala zVEM pa omogoča tudi objavo pomembnih sporočil v sklopu novic in oglasne deske (Rant, Stanimirović & Žlender, 2019). V prvi vrsti je portal zVEM namenjen pacientom in je dostopen na spletni strani <https://zvem.ezdrav.si/> (NIJZ, 2021c). Po prijavi lahko uporabnik pregleduje svoje podatke in podatke svojih otrok do petnajstega leta starosti. Možno se je tudi naročiti na obvestila o receptih in napotnicah. Ker v zadnjih letih nara-

šča delež oseb, ki želijo do spletnih vsebin dostopati prek interneta s pametnim telefonom, je bila razvita aplikacija zVEM za pametne telefone, ki ponuja hiter in pregleden dostop do večine storitev. Aplikacija je v uporabi od julija 2021.

Izvajalci zdravstvene dejavnosti (IZD) pošiljajo izvide, odpustna pisma in podatke za povzetek podatkov o pacientu (PPoP). Iz zbirk podatkov v okviru eZdravja se polnijo podatki o receptih (eRecept), napotnicah, naročilih (eNaročanje) in cepljenjih (eRCO). Podatki o zavarovanjih se prenašajo iz zbirk ZZZS-ja. Demografski podatki se prenašajo iz Registra pacientov in prostorskih enot (RPPE), ki se ažurira iz Centralnega registra prebivalcev (CRP) in Geodetske uprave RS. Pacient sam prispeva izjave volje in se lahko naroča na cepljenje (slika 1).

### 3.2 Vpogled v lastno zdravstveno dokumentacijo

Velika dodana vrednost je pogled v lastno zdravstveno dokumentacijo (Rant et al., 2019). Pacient lahko pregleduje izvide in odpustna pisma iz bolnišnic. Med njimi so tudi potrdila o opravljenih testiranjih in rezultatih testov na covid-19. Pacient si lahko natisne Evropsko digitalno covid potrdilo (EU DCP). Te dokumente lahko v svojem informacijskem sistemu vidijo tudi lečeci zdravniki in tako pacientom ni več potrebno prenašati izvidov med različnimi izvajalci zdravstvene dejavnosti.



Slika 1: Prikaz podatkov v zVEM

### 3.3 Povzetek podatkov o pacientu

Pacient si lahko ogleda povzetek podatkov o pacientu (PPoP, angl: Patient Summary) zase in za svoje otroke. PPoP je strukturiran zapis, ki ga sestavljajo najpomembnejši zdravstveni podatki, potrebni za kakovostno zdravstveno obravnavo in so del Centralnega registra podatkov o pacientih (CRPP). V njem so pacientovi identifikacijski podatki, podatki o alergijah in ostalih preobčutljivostih, boleznih in stanjih, cepljenjih, kirurških posegih, medicinskih pripomočkih in vsadkih, priporočenih terapijah, invalidnosti, socialni zgodovini, morebitni nosečnosti, povzetkih zdravljenja, meritvah in izdanih zdravilih.

Osnovni podatki o pacientu prikazujejo osnovne demografske podatke pacienta in podatke o izbranih osebnih zdravnikih. Povzetek pisnih izjav volje pacienta vsebuje pisne izjave volje pacienta. Prepoved vpogleda pa lahko pacient tudi vnese.

### 3.4 Podatki o receptih

Pacient si lahko ogleda podatke o predpisanih in izdanih zdravilih na recept. Pri vsakem receptu so prikazani podatki o predpisanim zdravilu in njegovih izdajah v lekarnah. Za vsak predpis in izdajo si je možno ogledati tudi podrobnosti, npr. število preostalih izdaj zdravila pri obnovljivih receptih.

### 3.5 Podatki o eNaročanju

Pacient lahko vidi seznam napotnic, seznam naročil in čakalnih dob, ki jih poročajo izvajalci zdravstvene dejavnosti. Za vsako napotnico si lahko ogleda njen status (ali je že porabljen), zdravnika izdajatelja in datum obravnave. Lahko si pogleda tudi podrobnosti napotnice in izpiše potrdilo o izdani e-napotnici. V seznamu naročil pregleda obravnave, na katere je naročen, in podatke o tem naročilu. Naročilo lahko tudi odpove. V okviru storitve eNaročanje je vsem državljanom omogočen vpogled v čakalne dobe in proste termine pri izvajalcih zdravstvene dejavnosti, kot jih le-ti poročajo, ter operativna izvedba e-naročila na želeno zdravstveno storitev. Portal zVEM omogoča naročanje na cepljenje proti covid-19.

### 3.6 zVEM plus – zdravstveni portal zVEM za izvajalce zdravstvene dejavnosti

Portal zVEM plus omogoča zajem podatkov in njihovo obdelavo ter oddajo različnih poročil, ki jih morajo pošiljati izvajalci zdravstvene dejavnosti. Namenjen je izvajalcem, ki za to ne uporabljajo svojega informa-

cjskega sistema. Naložbo je financirala Evropska unija iz Evropskega sklada za regionalni razvoj v okviru odziva Unije na pandemijo covid-19 (Janet & Stanimirović, 2020). Prek sistema zVEM plus je mogoče:

- izdajanje EU DCP (npr. za lekarne),
- naročanje oseb na cepljenje proti covid-19,
- pregledovati čakalne sezname na cepljenje,
- vnašati rezultate covid-19 testov v CRPP,
- pregledovati sezname testiranih na covid-19,
- izvajati poizvedbe o osebah v RPPE,
- pregledovanje umrlih po obdobju,
- oddajati in preklicati dokumente v CRPP,
- izvajati kontrolne poizvedbe v CRPP.

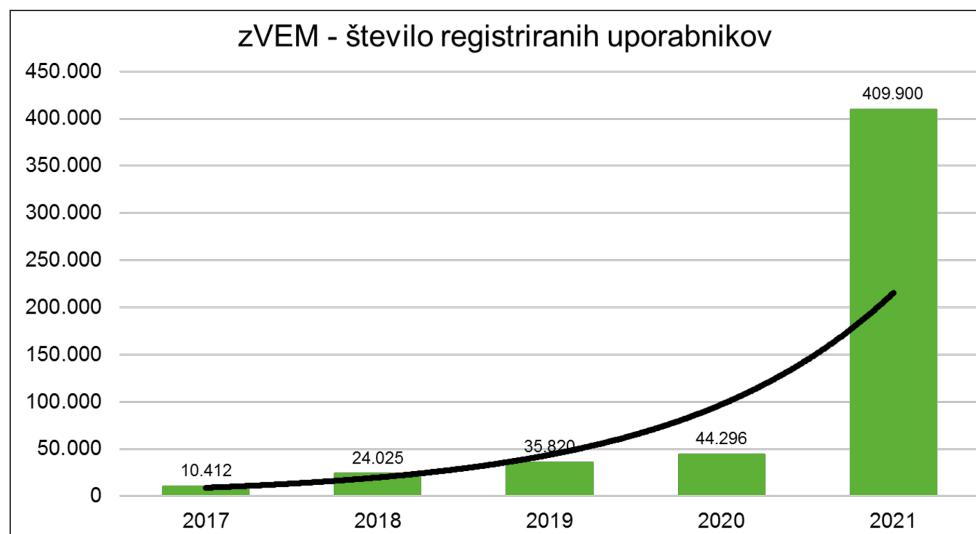
### 3.7 Podatki o uporabi Portala zVEM

Portal zVEM se je začel pospešeno uporabljati v začetku leta 2017, zelo velik skok je uporaba dosegla v letih 2020 in še posebej 2021 z možnostjo izpisa rezultatov testiranj in cepljenj proti covid-19 in Evropskega digitalnega covid potrdila. Prvo digitalno potrdilo o cepljenju je bilo možno izpisati že 19. 3. 2021. Evropsko digitalno covid potrdilo (EU DCP) pa od 24. 6. 2021. Od 13. 7. 2021 je na voljo aplikacija zVEM tudi na mobilnih telefonih. Aplikacijo za preverjanje EU DCP si lahko uporabniki namestijo od 5. 8. 2021.

Portal zVEM je v času epidemije prevzel pomembno vlogo obveščanja in ozaveščanja prebivalstva. Decembra 2020 smo začeli na portalu objavljati mikrobiološke izvide iz CRPP, vključujoč rezultate hitrih in PCR testov za covid-19. S tem se je začela hitra rast števila uporabnikov na portalu. Število registriranih uporabnikov je več let ostajalo na relativno nizki ravni, dokler ni postal portal pomembno orodje za pridobivanje dokumentov v povezavi z zdravjem in covid-19 (Wong et al., 2021). Pomembno povečanje je zaslediti z možnostjo izpisa EU DCP junija 2021 in z aplikacijo zVEM za pametne telefone avgusta 2021 (slika 2). V letu 2021 je število registriranih uporabnikov portala zVEM doseglo 409.900. Trenutna rast registriranih uporabnikov na portalu se giblje okrog 5000 oseb na dan.

Tudi število edinstvenih obiskov na portalu zVEM je v zadnjem letu eksponentno naraslo in je leta 2021 doseglo 23.975.212. Eksponentna rast je posledica predvsem uvedbe potrdil o testiranjih in certifikatih o cepljenju proti covid-19, še posebno pa z možnostjo izpisa EU DCP julija 2021 (slika 3).

Pri portalu zVEM plus (za izvajalce zdravstvene dejavnosti) je bilo konec leta 2021 že 101.581 uporabnikov.



Slika 2: Naraščanje števila registriranih uporabnikov Portala zVEM po letih

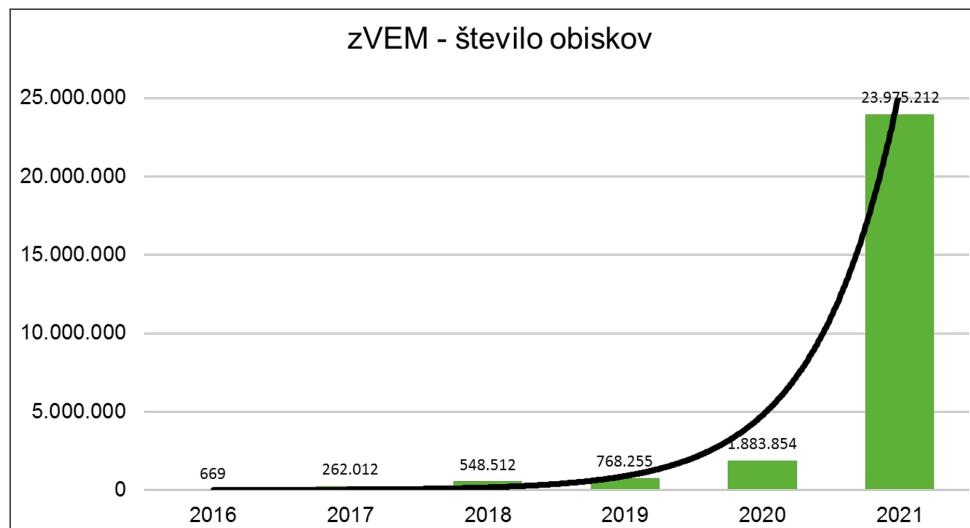
Rast uporabnikov na portalu zVEM je dobrodošla in nujna za uspešen razvoj eZdravja in povezanost storitev. Dejstvo je, da je bil portal zVEM zasnovan pred šestimi leti, zato bo treba nadgraditi zaledne sisteme in baze, da bomo pripravljeni na prihajajoče izzive in neomejeno delovanje portala v prihodnosti.

### 3.8 Centralni register podatkov o pacientu (CRPP)

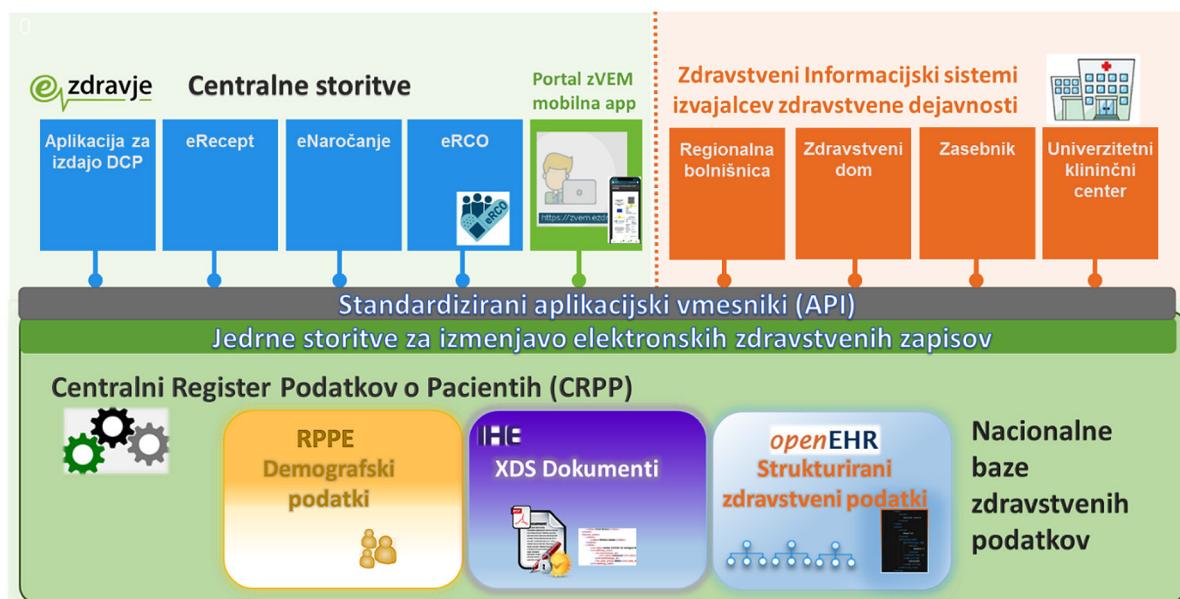
Podatki, ki se prikazujejo preko Portala zVEM, se berejo iz Centralnega registra podatkov o pacientu (CRPP). Danes je CRPP brez dvoma najkompleksnejši javni informacijski sistem v Sloveniji. CRPP je zbirka podatkov eZdravja o pacientih s stalnim ali začasnim prebivališčem v Republiki Sloveniji. Podatki v

CRPP se obdelujejo zato, da se izvajalcem omogoči dostop do podatkov, izmenjava podatkov za izvajanje zdravstvene oskrbe in mrlisko pregledne službe ter z namenom ažuriranja podatkov zdravstvene dokumentacije (ZZPPZ, 2021). Dostopanje do podatkov v CRPP določa Pravilnik o pooblastilih za obdelavo podatkov v Centralnem registru podatkov o pacientih (Ministrstvo za zdravje, 2021).

CRPP sestavljajo Register pacientov in prostorskih enot (RPPE), zdravstveni dokumenti in povztek podatkov o pacientu PPoP (angl. Patient Summary). Demografski podatki v RPPE se polnijo iz Centralnega registra prebivalcev (CRP) in Geodetske uprave RS. Zdravstveni dokumenti se prenašajo iz



Slika 3: Naraščanje števila obiskov Portala zVEM po letih



Slika 4: Centralni register podatkov o pacientu (CRPP), vir: Lucija Tepej Jocić

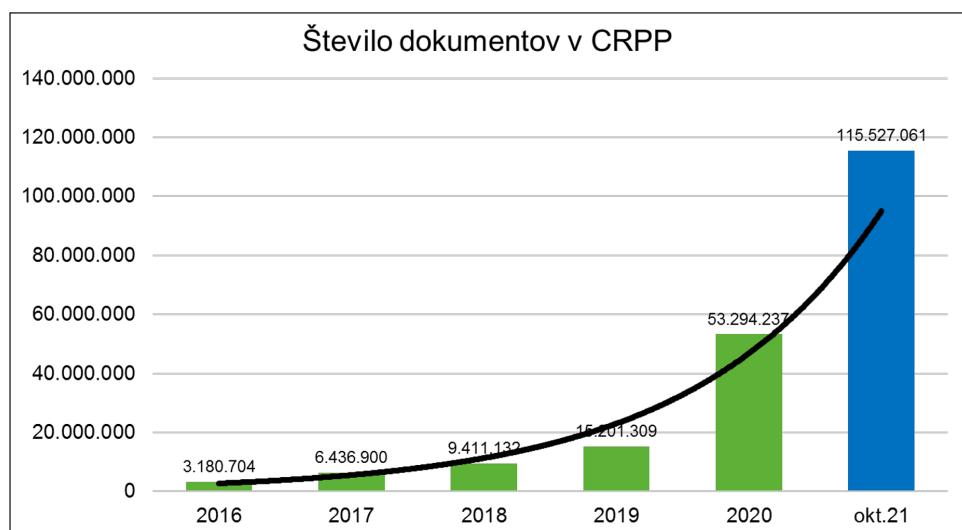
IS izvajalcev zdravstvene dejavnosti. PPoP je strukturiran zapis, ki ga sestavljajo najpomembnejši zdravstveni podatki, potrebni za kakovostno zdravstveno obravnavo in se polni s podatki, ki jih pošiljajo IZD (slika 4).

### 3.9 Podatki o uporabi CRPP

Pošiljanje podatkov v CRPP je obvezno po Zakonu o zbirkah podatkov s področja zdravstvenega varstva (ZZPPZ, 2021). Izvajalci zdravstvene dejavnosti

so po ZZPPZ obvezni uporabniki CRPP. Podatke pošiljajo vsi javni zdravstveni zavodi. Podatke pošiljajo tudi koncesionarji in zasebniki brez koncesije. Ena izmed ključnih ovir za širitev uporabe CRPP je nevključenost v zNET.

Podatki o številu dokumentov v CRPP kažejo na velik skok leta 2020 in nadaljnjo eksponentno rast v letu 2021. Oktobra 2021 je število dokumentov v CRPP doseglo 115.527.061. (slika 5; opomba: podatki za leto 2021 so do konca oktobra).



Slika 5: Rast števila dokumentov v CRPP po letih

### 3.10 Razvoj novih funkcionalnosti in rešitev

CRPP in zVEM se vseskozi razvijata, kar povečuje njuno kompleksnost. Najpomembnejše novosti v zadnjem času so:

- tretje četrletje 2019: prva verzija spletne rešitve zVEM plus za profesionalne uporabnike; namenjena je bila interni uporabi v NIJZ za naloge, povezane z upravljanjem CRPP;
- tretje četrletje 2019: prvi mikrobiološki laboratoriji so začeli posredovati izvide, ob nastopu epidemije pa se je kmalu vključila večina laboratorijs; to je vsem lečečim zdravnikom omogočilo takojšnjo seznanitev z rezultati mikrobioloških preiskav;
- drugo četrletje 2020: nadgradnja jedrnih storitev za pridobivanje demografskih podatkov in razvoj spletne rešitve zVEM plus, ki je omogočila poizvedbe po demografskih podatkih posameznikov za potrebe epidemiološke dejavnosti ter ažurno spremljanje in analiziranje aktualnih podatkov o umrljivosti, ki so ključni pri obvladovanju epidemije; danes se dnevno uporablja v epidemiološki dejavnosti;
- december 2020: vzpostavljena je nacionalna rešitev za poročanje covid-19 testiranja in obveščanje patientov; omogoča zajem strukturiranega rezultata testov ter njegov zapis v CRPP, avtomatizirano pošiljanje SMS obvestil o rezultatih testov za paciente, avtomatizirano informiranje izvajalcev testiranja (vstopnih točk) o rezultatih testov in statusu obveščanja patientov ter posredovanje podatkov o pozitivnih rezultatih v zbirko nalezljivih bolezni (NIJZ 48 Evidenca nalezljivih bolezni);
- januar 2021: razvita je spletna rešitev zVEM plus za vstopne točke, ki omogoča celovito informacijsko podporo obveščanja patientov;
- januar 2021: razvita je nacionalna spletna rešitev zVEM plus za izvajalce, ki nimajo ustreznih informacijskih sistemov, zlasti za domove za starejše občane in socialno varstvene zavode; danes jo uporabljam tudi zasebniki;
- marec 2021: možen je izpis digitalnega potrdila o cepljenju iz zVEM; na osnovi podatkov o opravljenih cepljenjih, ki jih poročajo cepitelji v CRPP in eRCO, je preko portala zVEM možno izpisati digitalno potrdilo o cepljenju;
- maj 2021: razvita je nacionalna enotna spletna rešitev za naročanje na cepljenje; preko te rešitve se lahko pacienti sami naročijo na cepljenje;
- junij 2021: možen je izpis Evropskega digitalnega covid potrdila (EU DCP; NIJZ, 2021d); na osnovi podatkov o prebolevnosti, cepljenju ali testiranju je preko portala zVEM možno izpisati EU DCP, enotno evropsko potrdilo o prebolevnosti, cepljenosti ali testiranju, ki je veljavno v vseh državah članicah EU; pacienti lahko EU DCP pridobivajo preko spletnega portala ali mobilne aplikacije zVEM, zdravstveni delavci jih lahko za paciente pridobivajo preko obstoječih informacijskih sistemov pri IZD;
- julij 2021: aplikacija zVEM je na voljo tudi na mobilnih telefonih in sicer pri vseh večjih spletnih trgovinah z aplikacijami. S sodobnim uporabniškim vmesnikom, ki se naslanja na primere dobre praks drugih podobnih aplikacij, ponuja zVEM vse storitve, ki so na voljo na portalu prek računalnika; v kratkem bomo razvili tudi popolnoma prenovljen vmesnik za uporabo eNapotnic, omogočili potisna sporočila in nadgradili uporabniško izkušnjo;
- avgust 2021: na voljo je aplikacija za preverjanje EU digitalnih covid potrdil za mobilne naprave; aplikacija kontrolorjem omogoča skeniranje kode QR potrdila EU DCP in preverjanje veljavnosti v njej shranjenih podatkov potrdila z omejenim prikazom osebnih podatkov; skladna je z Odlokom o načinu ugotavljanja izpolnjevanja pogojev prebolevnosti, cepljenosti in testiranja v zvezi z nalezljivo bolezni COVID-19, (Ministrstvo za zdravje, 2021b).

Vse nadgradnje je bilo potrebno razviti in uvesti v čim krajšem času. Za nekatere rešitve smo lahko uporabili že obstoječe rešitve s prilagoditvami, nekatere rešitve je bilo potrebno narediti na novo. Ti razvojni dosežki ne bi bili mogoči brez preteklega dela pri uvajanju, vzdrževanju in razvoju jedrnih storitev CRPP in zVEM.

## 4 RAZPRAVA

V času epidemije covid-19 je uporaba rešitev eZdravja skokovito narasla in se na nekaterih področjih povečala za več desetkrat (Doraíswamy, Abraham, Mamani, & Cheema, 2020). Zaradi naraščajočih zahtev uporabnikov in potreb sistema (potrebe patientov, javnozdravstvene potrebe, potrebe izvajalcev zdravstvene dejavnosti, potrebe zdravstvene politike) so bile nadgrajene številne obstoječe rešitve in razvite številne nove rešitve. Vse to je povzročilo velik pritisk na premalo številne kadre; trenutno

deluje na področju eZdravja 15 zaposlenih. Ta dejstva močno vplivajo tudi na proračun eZdravja, saj nadgradnje in razvoj novih storitev terja tako začetne investicijske stroške kot tudi dolgoročne stroške za vzdrževanje in zaposlitev novih kadrov, ki bodo skrbeli za delovanje teh rešitev. Epidemija covid-19 je nazorno pokazala pomembnost rešitev eZdravja za slovenski zdravstveni sistem, saj je mogoče odgovorno trditi, da bi brez uporabe rešitev eZdravja posamezni segmenti zdravstvenega sistema dobesedno razpadli (Lee in Lee, 2021), večji del zdravstvenega sistema pa bi bil zelo resno ohromljen in omejen pri svojem delu. Največjo škodo v takšni situaciji bi utrpteli pacienti (Turer et al., 2021; Guitton, 2021).

Analiza, ki jo je v letu 2019 izvedlo Ministrstvo za zdravje, razkriva, da zdravstveni sistem vsebuje enega izmed največjih sklopov informacijskih sistemov v Republiki Sloveniji. Različni zdravstveni informacijski sistemi (ZIS) se uporabljajo v približno 26 bolnišnicah, 60 zdravstvenih domovih in več kot 1500 ambulantah javnega zdravstvenega sistema. Druge države vlagajo v zdravstveno informatiko v povprečju štirikrat več kot Slovenija, delež stroškov za informatiko glede na celotne prihodke pri nas je 1 %, mednarodno povprečje je 3,9 %. V letu 2018 je bilo glede na Poslovno poročilo bolnišnic v vseh bolnišnicah v Sloveniji 21.334 zaposlenih, od tega 85 informatikov, kar predstavlja 0,4 % vseh zaposlenih, mednarodno povprečje za zdravstvo znaša 2,8 % kar pomeni, da zelo odstopamo tudi pri strokovnem kadru.

#### **4.1 Prioritetne aktivnosti za ohranitev spodbudnega trenda in nadaljnji razvoj**

Podatki na področju uporabe rešitev eZdravja so spodbudni, saj kažejo, da se rešitve eZdravja vse bolj uveljavljajo v vsakodnevni poslovanju slovenskega zdravstvenega sistema in so nepogrešljive v epidemioloških razmerah (Sust et al., 2020). Za ohranitev spodbudnega trenda ter v luči nadaljnjega razvoja in še bolj učinkovite uporabe rešitev eZdravja v prihodnje je v slovenskem zdravstvenem sistemu potrebno izvesti nadaljnje aktivnosti.

Prioritetne naloge na področju eZdravja so:

- priprava strategije eZdravja (vključno s konceptom zdravja na daljavo in telemedicine) in prenova zakonskih podlag za delovanje eZdravja;
- dvigovanje ravni uporabe rešitev eZdravja s strani končnih uporabnikov;
- izboljšanje kakovosti delovanja rešitev ter njihovo

celovito vzdrževanje in nadgrajevanje v skladu z zaznanimi potrebami oz. zakonskimi zahtevami;

- razvoj in implementacija novih in dopolnjenih rešitev eZdravja v skladu z ugotovljenimi potrebami;
- dodelitev dodatnih sredstev (materialni in kadrovski viri) za vzdrževanje in razvoj centralnih nacionalnih rešitev eZdravja, ki jih upravlja NIJZ, ter digitalizacijo poslovanja izvajalcev zdravstvene dejavnosti;
- vključitev koncesionarjev v varno zdravstveno omrežje zNET, ki jim bo omogočilo uporabo rešitev eZdravja;
- spodbuda vseh IZD k celovitemu in doslednemu pošiljanju vseh dokumentov in podatkov v CRPP (s ciljem oblikovanja in zagotavljanja vseh prednosti elektronskega zdravstvenega kartona);
- spodbuda vseh IZD k pošiljanju točnih podatkov o čakalnih dobah v centralni sistem eNaročanja in vzpostavitev info-točk za naročanje pacientov;
- promocija eZdravja in priložnosti, ki jih ponujajo rešitve eZdravja.

#### **5 ZAKLJUČEK**

Rešitve eZdravja v Sloveniji so od zaključka projekta leta 2015 doživele nesluten razvoj. Še posebej je ta razvoj pospešen v zadnjih dveh letih v času epidemije covid-19. Nekateri strokovnjaki ocenjujejo, da je informatika v zdravstvu v zadnjih dveh letih napredovala toliko, kot bi v običajnih razmerah v desetih letih. Niso se razvile le rešitve, več kot desetkrat se je povečala tudi njihova uporaba. Pri tem so se razgabile težave, ki so v veliki meri nastale tudi zaradi neustreznih preteklih vlaganj v informatiko; tako v kadru in infrastrukturo kot v razvoju obstoječih in novih rešitev. Zelo je bilo izpostavljeno tudi slabo znanje uporabnikov informacijskih rešitev, od najosnovnejše uporabe računalniške in telekomunikacijske opreme, preko računalniške in informacijske pismenosti, do uporabe računalniških rešitev samih.

Potrebno je dvigniti digitalno kulturo v zdravstvenih ustanovah in digitalne kompetence vseh zaposlenih. Digitalna kultura je pomembna tudi za tesno sodelovanje med informatiko in ostalimi področji dela. Pri tem so zelo pomembne digitalne kompetence vseh zaposlenih.

Vložiti je potrebno veliko naporov, pa tudi sredstev, da tudi v prihodnosti ohranimo in nadaljujemo res ogromen napredok v zdravstveni informatiki v zadnjih letih.

## VIRI IN LITERATURA

- [1] Arcury, T. A., Sandberg, J. C., Melius, K. P., Quandt, S. A., Leng, X., Latulipe, C., Miller, D. P., Jr, Smith, D. A., & Bertoni, A. G. (2020). Older Adult Internet Use and eHealth Literacy. *Journal of applied gerontology : the official journal of the Southern Gerontological Society*, 39(2), 141–150. <https://doi.org/10.1177/0733464818807468>
- [2] Bokolo A. J. (2021). Application of telemedicine and eHealth technology for clinical services in response to COVID19 pandemic. *Health and technology*, 1–8. Advance online publication.
- [3] Doraiswamy, S., Abraham, A., Mamiani, R., & Cheema, S. (2020). Use of telehealth during the COVID-19 pandemic: scoping review. *Journal of medical Internet research*, 22(12), e24087.
- [4] Doraiswamy, S., Abraham, A., Mamiani, R., & Cheema, S. (2020). Use of Telehealth During the COVID-19 Pandemic: Scoping Review. *Journal of medical Internet research*, 22(12), e24087.
- [5] European Commission. (2018). *Communication from the Commission to the European Parliament, the European Council, the European Economic and Social Committee and the Committee of the Regions on enabling the digital transformation of health and care in the Digital Single Market; empowering citizens and building a healthier society*. SWD (2018) 126 final. Brussels.
- [6] European Commission. (2019). *Digital Economy and Society Index (DESI); 2019 Country Report; Slovenia*. Retrieved from [https://ec.europa.eu/newsroom/dae/document.cfm?doc\\_id=59912](https://ec.europa.eu/newsroom/dae/document.cfm?doc_id=59912)
- [7] Glöggler, M., & Ammenwerth, E. (2021). Development and Validation of a Useful Taxonomy of Patient Portals Based on Characteristics of Patient Engagement. *Methods of Information in Medicine*, 60(S 01), e44-e55.
- [8] Guitton, M. J. (2021). Something good out of something bad: eHealth and telemedicine in the Post-COVID era. *Computers in Human Behavior*, 123, 106882.
- [9] Janet, J., & Stanimirović, D. (2020). Prenova portala zVEM. In T. Marčun & E. Dornik (Eds.), *Digitalni mostovi v zdravstvu : e-Kongres MI'2020 : zbornik prispevkov in povzetkov* : Ljubljana, 5. november 2020 (pp. 55–59). SDMI.
- [10] Lee, S. M., & Lee, D. (2021). Opportunities and challenges for contactless healthcare services in the post-COVID-19 Era. *Technological Forecasting and Social Change*, 167, 120712.
- [11] Ministrstvo za zdravje. (2005). eZdravje2010 Strategija informatizacije slovenskega zdravstvenega sistema 2005-2010, Ministrstvo za zdravje. <https://joinup.ec.europa.eu/sites/default/files/document/2014-12/e-Zdravje2010%20-%20Strategija%20informatizacije%20slovenskega%20zdravstvenega%20sistema%202005-2010.pdf>
- [12] Ministrstvo za zdravje (2021a). Pravilnik o pooblaštilih za obdelavo podatkov v Centralnem registru podatkov o pacientih (Uradni list RS, št. 51/16 in 95/21)
- [13] Ministrstvo za zdravje (2021b). Odlok o načinu ugotavljanja izpolnjevanja pogojev prebolevnosti, cepljenosti in testiranja v zvezi z nalezljivo boleznijo COVID-19 (2021). (Uradni list RS, št. 126/21).
- [14] Ministrstvo za javno upravo (2019). EVALVACIJA UKREPOV IZ ENOTNE ZBIRKE UKREPOV, Vrednotenje učinkov implementacije projekta eZdravje: eRecept, eNaročanje, <https://www.stopbirokraciji.gov.si/novice/razbremenitve-z-uvedbo-elektronskih-resitev-erecept-in-enarocanje-1>
- [15] Mohajan, H. K. (2018). Qualitative research methodology in social sciences and related subjects. *Journal of Economic Development, Environment and People*, 7(1), 23-48.
- [16] Nacionalni inštitut za javno zdravje (2021a). *Rešitve eZdravja*. <https://www.ezdrav.si/>
- [17] Nacionalni inštitut za javno zdravje (2021b). Statistika zahtevkov na Prvem nivoju podpore uporabnikom eZdravja. Nacionalni inštitut za javno zdravje, Ljubljana.
- [18] Nacionalni inštitut za javno zdravje (2021c). *Portal zVEM*. <https://zvem.ezdrav.si/>
- [19] Nacionalni inštitut za javno zdravje (2021d). *EU digitalno COVID potrdilo*. <https://www.ezdrav.si/storitve/digitalno-covid-potrdilo-eu/>
- [20] Petrova, I., Balyka, O., & Kachan, H. (2020). *Digital economy, and digital employment appearance. Social and labour relations: theory and practice*, 10(2), 10-20.
- [21] Rant, Ž., Stanimirović, D., Tepej Jočić, L., Žlender, A., Gaspari, I., Božič, D., Indihar, S., Beštek, M., Simeunović, B., Vrečko, A., Matetić, V., & Zidarn, J. (2018). Rešitve e-Zdravja. In I. Eržen (Ed.), *30 let Slovenskega društva za medicinsko informatiko : [publikacija ob 30-letnici Slovenskega društva za medicinsko informatiko]* (pp. 184–190). Slovensko društvo za medicinsko informatiko.
- [22] Rant, Ž., Stanimirović, D., & Žlender, A. (2019). Nacionalni Portal zVEM v okviru eZdravja = National portal zVEM within eHealth. In P. Šprajc, I. Podbregar, D. Maletič, & M. Radovanović (Eds.), *Ekosistem organizacij v dobi digitalizacije [Elektronski vir] : konferenčni zbornik = [Ecosystem of organizations in the digital age : conference proceedings* (pp. 873–884). Univerzitetna založba Univerze.
- [23] ZZPPZ. (2021). Zakon o zbirkah podatkov s področja zdravstvenega varstva (Uradni list RS, št. 65/00, 47/15, 31/18, 152/20 – ZZUOP, 175/20 – ZIUOPDVE, 203/20 – ZIUPOPDVE in 112/21 – ZNUPZ)
- [24] Sim, J., Waterfield, J. (2019). Focus group methodology: some ethical challenges. *Quality & Quantity*. 2019 Jul;53(6):3003-3022.
- [25] Stanimirović, D., & Matetić, V. (2020). Can the COVID-19 pandemic boost the global adoption and usage of eHealth solutions? *Journal of Global Health [Elektronski Vir]*, 10(2), 1–5.
- [26] Stanimirović, D. (2021). eHealth Patient Portal – becoming an indispensable public health tool in the time of Covid-19. In J. Mantas (Ed.), *Public Health and Informatics : the future of co-created eHealth : 31st Medical Informatics in Europe Conference (MIE 2021)*, online 29-31 May 2021 (Issue 281, pp. 880–884). IOS Press.
- [27] Sust, P. P., Solans, O., Fajardo, J. C., Peralta, M. M., Rodenas, P., Gabaldà, J., ... & Piera-Jimenez, J. (2020). Turning the crisis into an opportunity: digital health strategies deployed during the COVID-19 outbreak. *JMIR public health and surveillance*, 6(2), e19106.
- [28] Tulu, B., Trapp, A. C., Strong, D. M., Johnson, S. A., Hoque, M., Trudel, J., & Garber, L. (2016). An analysis of patient portal utilization: what can we learn about online patient behavior by examining portal click data?. *Health Systems*, 5(1), 66-79.
- [29] Turer, R. W., DesRoches, C. M., Salmi, L., Helmer, T., & Rosenbloom, S. T. (2021). Patient Perceptions of Receiving COVID-19 Test Results via an Online Patient Portal: An Open Results Survey. *Applied Clinical Informatics*, 12(04), 954-959.
- [30] van Gemert-Pijnen, J. E., Nijland, N., van Limburg, M., Ossebaard, H. C., Kelders, S. M., Eysenbach, G., & Seydel, E. R. (2011). A holistic framework to improve the uptake and impact of eHealth technologies. *Journal of medical Internet research*, 13(4), e111.
- [31] Wong, M. Y. Z., Gunasekeran, D. V., Nusinovici, S., Sabanayagam, C., Yeo, K. K., Cheng, C. Y., & Tham, Y. C. (2021). Telehealth demand trends during the COVID-19 pandemic in the top 50 most affected countries: Infodemiological evaluation. *JMIR public health and surveillance*, 7(2), e24445.

**Mag. Živa Rant** je članica skupine eZdravje na Nacionalnem inštitutu za javno zdravje. Pri eZdravju sodeluje od leta 2009. Bila je vodja projekta izgradnje informacijskega sistema več slovenskih podjetijih in je sodelovala pri več domačih in mednarodnih projektih. Pri svojem strokovnem delu se ukvarja s poslovnimi procesi, prenovo poslovnih procesov, enotnim informacijskim modelom, e-zdravjem kot sistemom. S svojimi prispevki redno sodeluje na strokovnih in znanstvenih srečanjih in kot gostujoči predavatelj predava na Univerzah v Ljubljani in Mariboru.

**Doc. dr. Dalibor Stanimirović** je predstojnik Centra za informatiko v zdravstvu na Nacionalnem inštitutu za javno zdravje in sodelavec Univerze v Ljubljani. Je aktiven član uredniških odborov več znanstvenih časopisov, rezultati njegovih raziskav so bili objavljeni v različnih mednarodnih znanstvenih časopisih ter predstavljeni na številnih konferencah. Njegovo raziskovalno delo obsega predvsem preučevanje zdravstvenih informacijskih sistemov in poslovno-informacijske arhitekture v javnem sektorju. V zadnjem obdobju kot raziskovalec sodeluje v več nacionalnih in evropskih projektih.

**Jure Janet** je razvojni sodelavec na Centru za informatiko v zdravstvu Nacionalnega inštituta za javno zdravje. Diplomiral je iz prevajalstva, trenutno pa se strokovno ukvarja z razvojem portala in aplikacije zVEM in zVEMplus ter nacionalne rešitve za triažiranje eTriaža.

# ► Problematika ohranjanja zasebnosti pri podatkovnem rudarjenju dokumentov z občutljivimi podatki

Matjaž Kragelj, National and University Library, Turjaška 1, 1000 Ljubljana, Slovenia matjaz.kragelj@nuk.uni-lj.si  
Mirjana Kljajić Borštnar, University of Maribor, Faculty of Organizational Sciences, Kranj, Slovenia, e-mail: Mirjana.Kljajic@um.si  
Alenka Brezavšček, University of Maribor, Faculty of Organizational Sciences, Kranj, Slovenia, e-mail: Alenka.Brezavscek@um.si

## Izvleček

V prispevku obravnavamo problem, s katerim se soočamo pri uporabi dokumentov, ki poleg vsebinskih podatkov vsebujejo tudi občutljive podatke o posamezniku, ki omogočajo njegovo razkritje tudi, ko to ni zaželeno. Med področja, kjer nastane veliko podatkov te vrste, štejemo zdravstveno varstvo, transport, kazenski pregon in nacionalno varnost, izobraževanje, sodobne internetne storitve, področje sodobnih aplikacijskih ekosistemov, internet stvari, finančni sektor in odprte podatke državne uprave. Cilj je zaščiti zasebnost subjekta ter hkrati zagotoviti kakovostne podatke za nadaljnje poglobljene analize in s tem nudjenje novih znanj za naprej. Za reševanje omenjenih izzivov na področju podatkovnega rudarjenja se je razvilo posebno podpodročje, imenovano PPDM – Privacy Preserving Data Mining, ki se ukvarja z ohranjanjem zasebnosti pri tem procesu. Sistematično smo pregledali relevantno literaturo podpodročja PPDM in opisali glavne metode in tehnike. Tehnike PPDM so zasnovane tako, da zagotavljajo določeno raven zasebnosti, obenem pa ohranjajo uporabnost podatkov, da se lahko uporaba še vedno učinkovito izvaja na transformiranih podatkih. Metode, s katerimi dosegamo zaščito posameznika na eni in uporabno vrednost podatkov na drugi strani v grobem delimo na metode razprševanja podatkov, metode izkrivljanja (z uporabo anonimizacije, randomizacije, vrtenja in vnašanjem šuma v podatke) ter metode šifriranja podatkov. Za doseganje višje zaščite lahko uporabimo tudi kombinacije teh metod. Poleg pregleda metod smo podali nekaj praktičnih primerov ter našteli domene oz. področja, kjer se kaže potreba po nadaljnji analizi in ponovni uporabi podatkov, a hkrati potreba po anonimizaciji oz. prikritju lastnika (subjekta) in njegovih podatkov (atributov).

**Ključne besede:** podatkovno rudarjenje, osebni podatki, ohranjanje zasebnosti, metode ohranjanja zasebnosti podatkov, pregled literature, varnost podatkov

## 1. UVOD

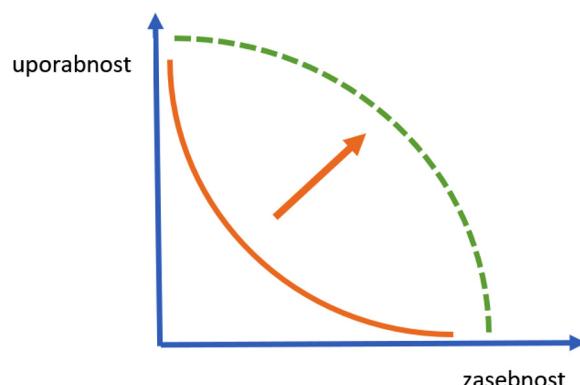
S pojavom interneta se je pojavila potreba in možnost po orodjih za iskanje, razvrščanje in kasneje analizo zbranih digitalnih podatkov. Kot primer lahko navdemonimo, da sta še v prejšnjem stoletju Smith & Chang (1997), razvila spletno orodje – WebSeek, ki je (bilo) namenjeno iskanju in sortiranju slik s spletja. Dokler so bile količine podatkov obvladljive, so bile tudi metode in orodja razmeroma enostavna, v današnjem času pa potreba po zbiranju in obdelavi podatkov strmo narašča [2]. V podjetju IBM ugotavljajo, da je bilo v letih 2012 in 2013 ustvarjeno več kot 90 % vseh podatkov na svetu [3]high energy physics, meteorology, genomics, biological and environmental research in which peta-and Exabyte of data are generated are common domain examples. Here even the capture and storage of the

data is a challenge. Google implemented hundreds of special-purpose computations that process large amounts of raw data, such as crawled documents, Web request logs, etc., to compute various kinds of derived data, such as inverted indices, various representations of the graph structure of Web documents, summaries of the number of pages crawled per host, and the set of most frequent queries in a given day. In this paper big data that is navigating in years from the past to present and to the future is analyzed. To address the problem space of unstructured analytics, Map Reduce with Hadoop distributed File System (HDFS, do leta 2025 pa bo za analizo primernih več kot 150 zetabajtov ( $10^9$  terabajtov). Z naraščanjem količine digitalnih podatkov, ki jih je potrebno obdelati, se je pojavila potreba po vpeljavi naprednejših metod, ki temeljijo

na principih umetne inteligence in strojnega učenja, natančneje – podatkovnega rudarjenja. Gre za proces pridobivanja implicitnih informacij in znanj, ki bi lahko bile koristne, črpanje le-teh pa poteka iz množičnih, neurejenih, nepopolnih, nejasnih ali naključnih, ne nujno strukturiranih podatkovnih struktur (Sahu, Shrma & Gondhalakar, 2008).

Med digitalnimi in digitaliziranimi dokumenti, ki jih rudarimo, so tudi takšni, ki so občutljive narave in zaradi tega zahtevajo posebno skrb in previdnost pri hranjenju, obdelavi in posredovanju tretjim osebam. Neustrezno postopanje pri rudarjenju takih dokumentov lahko povzroči grožnjo zasebnosti preko razkritja identitete in s tem posredno povezanih podatkov (atributov), saj attribute navadno povezujemo z lastništvom ravno preko identitete [5]. V skladu z definicijo iz slovarja Cambridge, je zasebnost definirana kot pravica posameznika, da obdrži svoje osebne podatke, zadeve in odnose v tajnosti [6]. Definicija sledi 12. členu Splošne deklaracije o človekovih pravicah, ki pravi, da se ni dovoljeno nikomur samovoljno vmešavati v zasebno življenje, družino, dom ali dopisovanje, prav tako pa ni dovoljeno žaljenje časti in dobrega imena slehernega posameznika. Vsakdo ima pravico do pravnega varstva pred takšnim vmešanjem ali napadi [7]. Težava, ki jo pri rudarjenju dokumentov z občutljivo vsebino zaznavamo, je naslednja: analizo želimo izvajati tako, da v popolnosti ohranjamo vrednosti in pomen podatkov, ki pomenijo attribute, a hkrati želimo zaščititi občutljive podatke o posamezniku, torej zaščititi njegovo zasebnost. Kot ugotavlja Gokulnath et al. (2015), je ohranjanje zasebnosti pri rudarjenju občutljivih in osebnih podatkov ključnega pomena za učinkovito izvedeno podatkovno rudarjenje.

V drugem poglavju bomo navedli glavna področja, kjer se ustvarjajo podatki in dokumenti z občutljivimi atributi. Med temi področji veljajo podatki o zdravstvenem varstvu za najpomembnejše, a so hkrati najbolj občutljivi, saj vsebujejo vse zasebne podatke, ki so informacije o pacientu, kot so bolezni, podatke o zdravljenju, recept, ime, naslov itd. Takšna zbirka podatkov katerekoli zdravstvene organizacije je dovzetna za različne napade [6]. Veliki podatki (ang. big data) ponujajo epidemiologom, zdravnikom in strokovnjakom za zdravstveno politiko veliko priložnost za presojo na podlagi analize dostopnih podatkov, ki bo sčasoma dvignila raven oskrbe bolnikov [8].



Slika 1: **Iskanje ravnoesa med zagotavljanjem zasebnosti uporabnikov in izvajanjem kvalitetnega nudenja podatkov o uporabnikih**  
Vir: povzeto po [9]

Kot prikazuje slika 1, je izziv iskanje metodologij in tehnik za zaščito zasebnosti in nerazkrivanje občutljivih podatkov na eni strani in nudenje kvalitetnih podatkov o uporabnikih za raziskave, analizo in ustvarjanje dodane vrednosti z novimi znanji na drugi strani. K reševanju tega izziva je potrebno pristopiti skrbno, saj lahko poseganje v same podatke in njihovo preoblikovanje okrni njihovo uporabnost, kar lahko vodi v napačne interpretacije zavajajoče informacije ter neustrezne odločitve [2].

Za reševanje te vrste izzivov se je na področju podatkovnega rudarjenja razvilo posebno podpodročje, ki se ukvarja z ohranjanjem zasebnosti pri rudarjenju dokumentov z občutljivimi podatki. To področje se je v tuji literaturi uveljavilo pod imenom »Privacy preserving data mining« – PPDM [10], [11]. Metodologije PPDM so zasnovane tako, da zagotavljajo dočeno raven zasebnosti, obenem pa ohranjajo uporabnost podatkov tako, da lahko rudarjenje še vedno učinkovito izvajamo na transformiranih podatkih. Da gre za zelo pomembno področje, je opozorila tudi Evropska komisija v »Mnenju številka 5« (EK, 2014). PPDM temelji na uporabi različnih metod, ki prispevajo k ohranjanju zasebnosti, kot npr. anonimizacija, randomizacija, uporaba permutacij, vnašanje šuma v podatke, kriptografske tehnike in druge [5]. Ker je področje razmeroma novo, a hkrati zanimivo, posebno danes, pri novih izzivih v zdravstvu (Covid19), bomo v nadaljevanju pripravili sistematičen pregled metod, ki se z izbrano problematiko ukvarjajo.

## 2. PODROČJA UPORABE PPDM

V tem razdelku bomo navedli področja, kjer prihaja do potreb po rudarjenju podatkov/dokumentov, ki

so po svoji naravi lahko občutljivi (Cranor et al., 2016). Čeprav avtorji navajajo domene uporab v ZDA, lahko izpostavljenia področja uporabe preslikamo tudi v našo regijo. Področja, kjer je potreba po uporabi metod PPDM pogosta in intenzivna, so naslednja:

- **Zdravstveno varstvo.** Informatizacija procesov v zdravstvu lahko močno izboljša zdravstvene storitve, vključno z možnostjo natančnejše diagnostike, omogočanjem bolj prilagojene in usklajene oskrbe, hitrejšega razvoja novih načinov zdravljenja, učinkovitejšega zdravljenja ob nižjih stroških. Izziv predstavlja razkritje občutljivih zdravstvenih podatkov, širjenje le-teh (legalno ali nelegalno), kar lahko privede do različnih neprijetnih in uporabniku škodljivih situacij (npr. do diskriminacije pri zaposlovanju<sup>1</sup>).
- **Transport.** Koristi informacijske tehnologije pri prevozu so lahko v zmanjšanju zastojev, preprečevanju nesreč, zmanjšanju smrti in poškodb, povečanju učinkovitosti porabe goriva, itd. Skrbi glede zasebnosti izvirajo iz možnosti sledenja gibanj posameznikov preko navigacijskih sistemov, cestnih senzorjev, prometnih kamer, zbiranja podatkov v avtomobilu in komunikacije med avtomobili.
- **Kazenski pregon in nacionalna varnost.** Organi pregona in obveščevalne agencije zbirajo in analizirajo različne vrste podatkov (kazenski zapisi in dopolnilne informacije) z namenom ustvarjanja »virtualne slike« posameznika, ki pomaga pri reševanju kriminalnih dejanj, preprečevanju napadov in sledenju teroristom. Glede ohranjanja zasebnosti so glavne skrbi te, da organizacije kot npr. policija množično zbirajo informacije o splošni populaciji, kar povečuje možnost nedovoljene uporabe in s tem niža kvaliteto učinka nadzora zaradi nezakonitega odtekanja podatkov. Kot primer lahko navedemo primer delovanja slovenske policije<sup>2</sup>.
- **Izobraževanje.** Informacijska tehnologija in podatki o izobraževanju lahko izboljšajo izobraževa-

nje z nudenjem prilagodljivih in prilagojenih vsebin in spletnih tečajev. Tveganje glede zasebnosti izhaja iz občutljivosti podatkov o angažiranosti in uspešnosti uporabnikov (učenci, dijaki, študenti).

- **Sodobne internetne storitve.** Iskalniki, družbena omrežja, spletnne video storitve in spletni trgovci imajo dostop do bogatega niza podatkov, ki jih je mogoče uporabiti za koristne namene, vključno z napredno personalizacijo vsebine in povezovanjem z drugimi (navadno poslovnimi) subjekti. Zaskrbljenost se kaže pri uporabi, zlorabi in skupni rabi podatkov za namene izven področja namembnosti.
- **Sodobni aplikacijski ekosistemi.** Naprave, kot so pametni telefoni, spletni brskalniki, pametne ure in njihove aplikacije, zagotavljajo uporabnikom veliko uporabnost (npr. pri športnih aktivnostih zaradi vgrajenih GPS naprav in pedometrov), zabavo in funkcionalnost. Kot potencialno težavo lahko navedemo sledljivost uporabnika (zaradi GPS podatkov, ki se zbirajo v aplikaciji). Izziv predstavlja zagotovitev, da aplikacije spoštujejo zasebnost in varnost njihovih uporabnikov.
- **Internet stvari.** Pametna mesta, pametne zgradbe, pametni domovi, pametni hladilniki, televizijske ipd. omogočajo izboljšanje življenjskih razmer, produktivnosti in kakovosti življenja. Vendar pa se lahko isti podatki uporabijo za sledenje, kdaj so posamezniki doma, katere TV programe gledajo, katera spletna mesta obiskujejo, njihovega urnika spanja in drugega vedenja. Tveganje predstavlja izkoriščanje takšnih podatkov za druge namene, kot npr. zavarovalne police (na voljo so informacije o prehrambnih navadah, aktivnostih in s tem tveganjih – profiliranje uporabnikovih navad), nezaželeno oglaševanje ali kriminal.
- **Finančni sektor.** Podatki finančnih institucij lahko regulatorjem pomagajo pri oceni skladnosti in omogočijo analizo trendov ter opozorilo na nevarnosti kot npr. prihajajoča finančna kriza. Vendar so finančni podatki občutljivi ne le na ravni posameznih strank, temveč tudi na ravni institucij, saj razkrivajo lastniške informacije o strategijah in tržnih deležih.
- **Odpti podatki državne uprave.** Vlade na vseh ravneh sproščajo velike količine podatkov, da bi povečale zaupanje in preglednost ter omogočile inovativne aplikacije. Vendar se te objave podatkov pogosto nanašajo na občutljive informacije o

<sup>1</sup> Tri tedne po tem, ko je Nydia Velázquez zmagala, kot kandidatka Demokratske stranke v New Yorku za predstavnico v Ameriškem predstavniškem domu, je nekdo iz bolnišnice St. Claire v New Yorku, preko faksu poslal Velázquezino zdravstveno kartoteko časopisu New York Post. V dokumentu je bila podrobno opisana oskrba pacientke, ki je tam pristala zaradi poskusa samomora. Poskus samomora se je zgodil nekaj let pred volitvami, na katerih je zmagala. Povzeto po (Wu and Velázquez, 2000).

<sup>2</sup> Avstrijska nevladna organizacija AlgorithmWatch je v svojem poročilu analize policijske uporabe tehnologije za prepoznavanje obrazov zapisala, da slovenska policija od leta 2014 uporablja doma razvito tehnologijo za prepoznavanje obrazov. Kot navajajo, gre za problem regulacije te tehnologije. Informacijska pooblaščenka je tako med leti 2015 in 2019 izdala več negativnih mnenj Ministrstvu za notranje zadeve. Slovenska policija in biometrijske metode nadzora [https://www.etcen.it/2019/12/12/slovenska-policja-in-biometrijske-metode-nadzora](https://www.etcen.it/2019/12/12/slovenska-policija-in-biometrijske-metode-nadzora), dostopano: januar 2020

državljanih. Lahko navedemo nekaj primerov takšnih spletnih storitev pri nas: eDavki<sup>3</sup>, eUprava<sup>4</sup>, eVem<sup>5</sup>, eZdravje<sup>6</sup> in drugi.

### 3. METODE ZA ZAŠČITO OBČUTLJIVIH PODATKOV

Analitika velikih podatkov (ang. big data) sestoji iz petih stopenj oz. faz, in sicer: pridobivanje podatkov, shranjevanje podatkov, upravljanje s podatki, analiza podatkov ter vizualizacija podatkov in poročanje. Pri dveh od teh se soočamo z ohranjanjem zasebnosti: **shranjevanje podatkov in, upravljanje s podatki** [8], [13], [14]. Podatki, ki jih pridobivamo, so lahko strukturirani, delno strukturirani, ali pa gre za nestrukturirane podatke. Podatke lahko pridobimo iz ustnih virov (intervju, telefonski pogovor) ali pisnih virov (npr. anketa, izvid, vprašalnik, diagnoza, mnenje). Pogosto so viri podatkov tudi slikovni ali multimediji (npr. magnetna resonanca, računalniška tomografija, ultrazvok itd.). Ne nazadnje, v dobi interneta lahko podatke pridobimo tudi iz spletnih anket, vprašalnikov, poskusov. Pogosto podatke že sami shranujemo, posredujemo in s tem ponujamo v varne ali ne – oblačne storitve (ang. cloud services). Gre za podatke, pridobljene iz pametnih naprav, telefonov z uporabo aplikacij, kot so npr. Drive, Training Peaks, Polar Flow, Strava, in podobne.

Glavni nalogi uporabe PPDM, kot ju navedejo Xu, Jiang, Wang, Yuan, & Ren (2014), sta soočanje in razreševanje problematike neprimernosti neposredne uporabe občutljivih, surovih podatkov (npr. številka osebne izkaznice, mobilnega telefona) za ruderjenje ter potreba po izključitvi občutljivih rezultatov ruderjenja, katerih razkritje bi povzročilo kršitev zasebnosti. Pionirsко delo, opis prvih metod ruderjenja občutljivih podatkov na tem področju najdemo v v člankih [16], [17].

Pri ruderjenju podatkov z namenom zaščite zasebnosti se uporablajo različne metode. Usmerjene so predvsem v omejevanje dostopa in uporabe občutljivih podatkov, ki bi sicer lahko identificirali posameznika, za nadaljnjo analizo. Po Abdul, Aldeen, Salleh, & Razzaque (2015), Qi & Zong (2012) in Taneja, Khanna, & Tilwalia, (2016) med glavne metode umeščamo:

- **Razprševanje podatkov** (ang. partitioning): podatke distribuiramo po eni ali več podatkovnih baz.
- **Izkrivljanje podatkov** (ang. data distortion, perturbation): pri tem načinu posegamo v podatke, ki jih želimo uporabiti in katerih vrednost je tista, ki jo želimo zaščititi. Sem umeščamo **anonimizacijo, randomizacijo, vrtenje, vnašanje šuma** v podatke.
- **Kriptografske tehnike šifriranja** (ang. cryptographic technique): gre za različne, pogosto računsko potratne metode, kjer se podatki s pomočjo ustreznega šifrirnega algoritma (simetričnega ali asimetričnega) in šifrirnega ključa pretvorijo v neberljivo obliko.

V nadaljevanju bomo posamezne metode nekoliko podrobnejše opisali.

#### 3.1 Razprševanje podatkov

O razprševanju podatkov (ang. partitioning) govorimo, kadar podatke, shranjene v eni podatkovni bazi, porazdelimo (razpršimo) v več podatkovnih baz. Podatke lahko razpršimo horizontalno, vertikalno ali funkcionalno. Vse omenjeno lahko počnemo centralizirano (na enem mestu) ali pa distribuirano (na več lokacijah).

Pri horizontalni razpršitvi podatkov pridobimo razširljivost (ang. scalability) in učinkovitosti v smislu hitrejšega dostopa do podatkov (ang. performance), na varnosti (ang. security) pa precej manj, saj so v posamezni relaciji (povezava med dvema ali več entitetami) zbrani vsi atributi. Iz vidika varnosti je poskrbljeno zgolj za to, da niso vsi podatki o vseh subjektih zbrani na enem mestu, ampak so razpršeni po več podatkovnih bazah.

Pri vertikalni razpršitvi gre za nasproten proces. Hitrost dostopa in uporabe podatkov pada, saj je treba atribute iz več podatkovnih baz med sabo združiti. Pri tem pristopu imamo atribute razdeljene v več skupin, vsaka izmed skupin pa je v svoji podatkovni bazi. Navadno ima vsaka relacija skupni ključ, ki povezuje podatke med seboj.

Pri funkcionalni razpršitvi ločujemo podatke glede na funkcijo, oz. uporabo<sup>7</sup> [18], [21].

Omeniti je treba, da z razprševanjem samih podatkov ne spremojmo, pač pa lahko zgolj ome-

<sup>3</sup> Edavki, <https://edavki.durs.si/EdavkiPortal/OpenPortal/CommonPages/Odynp/PageA.aspx>

<sup>4</sup> eUprava, <https://e-uprava.gov.si>

<sup>5</sup> eVem, <http://evem.gov.si/evem/drzavljeni/zacetna.evm>

<sup>6</sup> eZdravje, <https://zvem.ezdrav.si/e-zdravje>

<sup>7</sup> Horizontal, vertical, and functional data partitioning, <https://docs.microsoft.com/en-us/azure/architecture/best-practices/data-partitioning>, dostopano januar 2010

jimo dostop do njih. Pri vertikalni razpršitvi lahko uporabniku ponudimo dostop do delov podatkov (atributov, ki jih potrebuje), uporabnik pa si ne more ustvariti »celotne slike«, ker je dostop do celotne vsebine omejen. Za prikaz celotne slike moramo združiti podatke iz različnih podatkovnih baz oz. sistemov.

### 3.2 Izkriviljanje podatkov

V skupino izkriviljanja podatkov (ang. data perturbation) sodijo metode, tehnike in algoritmi, ki podatke spreminjajo, ali pa vanje dodajajo šum. Največ literature s področja PPDM je posvečeno ravno temu segmentu, ki je tudi najbolj kompleksen. Večinoma gre za matematične metode, ki posegajo v podatke in jih z uporabo vektorjev, matrik, faktorjev – spreminjajo. Na začetku je bilo implementiranih nekaj metod, ki so temeljile zgolj na naključnem seštevanju in množenju, a le-te niso bile imune na praktično nobeno vrsto napada [22].

Cilj izkriviljanja podatkov je ponuditi informacije, ki jih je mogoče uporabiti za ruderjenje na način, da ostane prikrita identifikacija lastnika (subjekta) atributov. Atribute v grobem delimo v tri skupine: *identifikacijski atributi* (identificirajo subjekt), *javni ali kvazi atributi* (njihove vrednosti lahko pridobimo tudi v drugih, javnih bazah podatkov, kot je npr. vo-lilni imenik, podatki v profilu na socialnih omrežjih (letnik ali starost, kraj, naslov, itd.), ter *privatni atributi*, ki npr. v primeru bolnišničnega kartona opisujejo stanje bolnika, bolezen, zdravljenje. Cilj je zagotoviti dostop do privatnih atributov, s pomočjo katerih bi radi ugotovili povezave, odvisnosti in s tem prišli do novih spoznanj in znanja, hkrati pa zavarovali informacije, ki identificirajo posameznika [23].

Medtem, ko pri metodah razprševanja in šifriranja podatke skrivamo, delimo, distribuiramo, jih s pomočjo anonimizacijskih tehnik **izkriviljamo** – z namenom nudenja nadaljnji uporabi. Obstojče metode na področju izkriviljanja podatkov opisujejo Sachan, Roy, & Arun (2013) in Qi & Zong (2012), ki med metodami omenjajo metodo **k-anonimnosti, generalizacijo, klasifikacijo, gručenje, povezovalna pravila, porazdeljeno ohranjanje zasebnosti, l-raznolikost, t-podobnost, randomizacijo in drevesno razvrščanje**.

Metode, ki uporabljajo algoritme dodajanja šuma, permutacij in randomizacijske tehnike, imajo prednosti, kot so npr. neodvisno izvajanje skozi vse vrednosti atributov (neodvisnost) in ohranjanje statistične natančnosti po rekonstrukciji originalnih podat-

kov. Med slabosti pa umeščamo zmanjšano uporabnost atributov pri generalizaciji v intervalu, skrivanje robnih podatkov, kar zahteva visoko uporabo šuma in s tem znižuje uporabnost podatkov [2]. V članku Li & Sarkar (2006) ponujata izboljšan pristop spreminjanja podatkov (dodajanja šuma), kot je zgolj povečevanje / zmanjševanje numeričnih vrednosti atributa za isti faktor, vrednost ali rotacijo. Ta temelji na razvrščanju v drevesa in na uporabi največje variante vrednosti med atributti.

**Generalizacijo** uporabljamamo v primeru, ko uporabnik podatkov ne potrebuje natančnih vrednosti atributov in lahko le-te posplošimo, npr. v intervalu, ki niso nujno vedno enako široki. Pri osebnem dohodu na primer lahko za nižje vrednosti uporabimo ožji, pri višjih vrednostih pa širši interval. Namesto prave vrednosti ponudimo interval, na katerem vrednost leži. Temu načinu spreminjanja rečemo *interval vrednostnih razredov* (ang. value-class interval). Drugi način je *vrednostno izkriviljanje* (ang. value distortion). Gre za dodajanje šuma, saj namesto vrednosti  $x_i$  ponudimo spremenjeno vrednost  $Z_{(i)} = x_i + r$ , kjer je  $r$  naključna vrednost iz nekega intervala  $[-a, +a]$ , ali pa generirana s pomočjo normalne (Gaussove) porazdelitve [10]. Pri izkriviljanju podatkov s to metodo, govorimo o izkriviljanju podatkov z dodatnim šumom, multiplikativnim šumom ali permutacijo [22], [26]. Kot šum si lahko predstavljamo podatek, ki je spremenjen na nivoju vseh elementov (npr. podatek o teži, višini pacientov, je za vse paciente spremenjen za določen faktor).

**k-anonimizacijo** uvrščamo v drugo skupino anonimizacijskih tehnik. Cilj te tehnike je anonimizirati člana množice ali skupine na način generalizacije vrednosti atributov (npr. mesto ali poštno številko z regijo, višino zaokrožiti na desetice, starost v interval, itd.). Pristop k-anonimnosti sta prva predlagala Samarati & Sweeney v (1998) in Sweeney (2002). Cilj postopka k-anonimizacije je vključitev vsakega posameznika, o katerem podatki so nam na voljo, v večjo skupino, s k-posamezniki in s tem povečati negotovost identifikacije posameznika. Tehnika k-anonimizacija ni imuna na uporabo posrednega znanja (ang. background knowledge), ki ga ima napadalec. To nastane zaradi slabo definiranih intervalov ali znanja, ki ga lahko ima napadalec o posamezniku, katerega podatke preiskuje (npr. zaradi atributov, ki niso skriti). Mendes & Vilela (2017) navajata, da sta prednosti metode k-anonimizacija enostavnost defi-

Tabela 1: Originalna tabela s podatki o pacientih Vir: Povzeto po Lin (2016)

Identif. atributi		Atributi kvazi identifikatorji (QI)			Občutljivi atributi
ID	Ime	Starost	Holesterol	Trigliceridi	Bolezen
45435	Janez	22	6	1.8	bolezen srca
46434	Petra	26	5.9	1.7	rak
65675	Tilen	36	7	2.3	hipertenzija
34567	Meta	35	8	3.9	rak
54345	Andrej	49	6.4	4.3	bolezen srca
34333	Špela	44	5.5	5.9	hipertenzija

nicije protokola in velik nabor obstoječih algoritmov za doseg k-anonimizacije, kot slabost pa predvidevanje, da vsak zapis predstavlja podatke o edinstvenem posamezniku. Če ni tako, se razred enakovrednosti s k zapisi ne poveže nujno s k različnimi posamezniki. Prav tako privatni (občutljivi) atributi ne pridejo v poštev za anonimizacijo v primeru, če imajo vsi podatki razreda isto vrednost.

V tabeli 1 in 2 prikazujemo primer originalne in spremenjene tabele s podatki o pacientih.

V tabeli 1 vidimo namišljene podatke o bolnikih, razdeljene v tri skupine atributov (identifikacijski, kvazi identifikatorji ter občutljivi ali privatni). Podatke bi radi anonimizirali do te mere, da ne bi bilo mogožno neposredno povezati bolnika z bolezniško, hkrati pa bi zaradi nadaljnje analize radi obdržali čim več podatkov, zanimivih za raziskave in razvoj znanosti na področju medicine. Rezultate modifikacije podatkov prikazujeta tabeli 2 in 3.

V tabeli 2 smo odstranili identifikacijske attribute in generalizirali tri druge. Prikazan generalizacijski postopek imenujemo k-anonimizacija [23], [26], [29], [30]. Cilj postopka k-anonimizacije je vključitev vsega posameznika, o katerem podatki so nam na vo-

ljo, v večjo skupino s k-posamezniki in s tem povečati negotovost identifikacije posameznika. V opisanem primeru (v tabelah 1 in 2) prikazujemo 2-anonimnost, saj za vsako kombinacijo generaliziranih kvazi atributov, obstajata vsaj dve bolezni.

Ena od slabosti opisanega postopka je premajhna vrednost k in dejstvo, da tehnika ne uporablja doda-janja šuma, kot npr. randomizacija. S sklepanjem ali ugibanjem je pri majhnem k verjetnost, da imata osebi eno ali drugo bolezen večja, kot pri velikem k. Npr., če vemo, da so v razpredelnici podatki nekoga, za kategroga približno poznamo kvazi identifikatorje, vemo, da ima bodisi eno ali pa drugo bolezen (pri 2-anonimnosti). V članku Mendes & Vilela (2017), avtorja med prednosti metode k-anonimizacija umeščata:

- enostavnost definicije protokola,
- velik nabor obstoječih algoritmov za doseg k-anonimizacije, med slabosti pa:
- Predvideva se, da vsak zapis predstavlja podatke o edinstvenem posamezniku. Če ni tako, se razred enakovrednosti s k zapisi ne poveže nujno s k različnimi posamezniki.
- Privatni (občutljivi) atributi ne pridejo v poštev za anonimizacijo, kar lahko prispeva k razkritju in-

Tabela 2: Spremenjena tabela s podatki o pacientih Vir: Povzeto po Lin (2016)

Atributi kvazi identifikatorjev (QI)			Občutljivi atributi
Starost	Holesterol	Trigliceridi	Bolezen
[20-29]	[5-7]	[0-2]	bolezen srca
[20-29]	[5-7]	[0-2]	rak
[30-39]	[7-9]	[2-4]	hipertenzija
[30-39]	[7-9]	[2-4]	rak
[40-49]	[5-7]	[4-6]	bolezen srca
[40-49]	[5-7]	[4-6]	hipertenzija

formacije/podatka v primeru, če imajo vsi podatki razreda isto vrednost.

Uporaba je razširjena predvsem pri podatkih, ustvarjenih v zdravstvu in podatkih, ki vključujejo (geo)lokacijske informacije.

Nadgradnja k-anonimnosti je **l-raznolikost**. Dodana je še ena omejitev, in sicer, da se vsak atribut v ekvivalentnem razredu pojavi vsaj l-krat tako, da je napadalec vedno precej negotov glede atributov tudi, če ima osnovne informacije o določenem posamezniku, na katerega se nanašajo osebni podatki (Machanavajjhala, Gehrke, Kifer, & Venkatasubramaniam, 2006). Med slabostmi metode je treba poudariti predvsem dejstvo, da je zahtevna za implementacijo (težko doseči primerno obliko), poleg tega pa se napadalec, v primeru, da so občutljivi atributi nekega razreda enaki, nauči / izve vrednost tega atributa za določenega posameznika [2], [32].

V tabeli 3 prikazujemo primer l-raznolikosti, kjer je za ceno varnosti zmanjšana zrnatost podatkov. Podatki so generalizirani do te mere, da je ustvarjena *3-raznolikost*, ker obstajajo trije različni občutljivi atributi znotraj vsakega bloka (bloka sta dva) v tabeli. S to potezo se zmanjša tveganje identifikacije, a na drugi strani bolj generalizira vrednosti kvazi identifikatorjev (povzeto po Machanavajjhala, Gehrke, Kifer, & Venkatasubramaniam (2006).

Čeprav model l-raznolikost učinkovito rešuje težave, ki obstajajo v modelu k-anonimnosti, se model ne more »upreti« napadom na podobnost (ang. similarity attacks). To pomeni, da je delež vrednosti občutljivega atributa prevelik. V tem primeru je velika verjetnost, da bo napadalec razkril zasebnost posameznika. Zato je znanstvenik Li Ning Hui predlagal model t-podobnost (ang. t-closeness). Ta zahteva, da

vrednost razlike med porazdelitvijo vrednosti občutljivih atributov v enakovrednih razredih in porazdelitvijo atributa v celotni podatkovni tabeli ni večja od t. Če je na primer občutljivi atribut številski, l-raznolikost ne upošteva, da so si nekatere vrednosti lahko zelo podobne (da so si blizu), kar rešuje metodo t-podobnost. Ta določa, da mora biti porazdelitev občutljivega atributa v vsakem ekvivalentnem razredu podobna porazdelitvi v celotni tabeli. To lahko prepreči napade na podobnost in dodatno reši težave, ki obstajajo v modelu l-raznolikosti. Model t-podobnost je velja za najboljši anonimizacijski model varovanja zasebnosti [26], [31], [33], [34].

### 3.3 Šifriranje podatkov

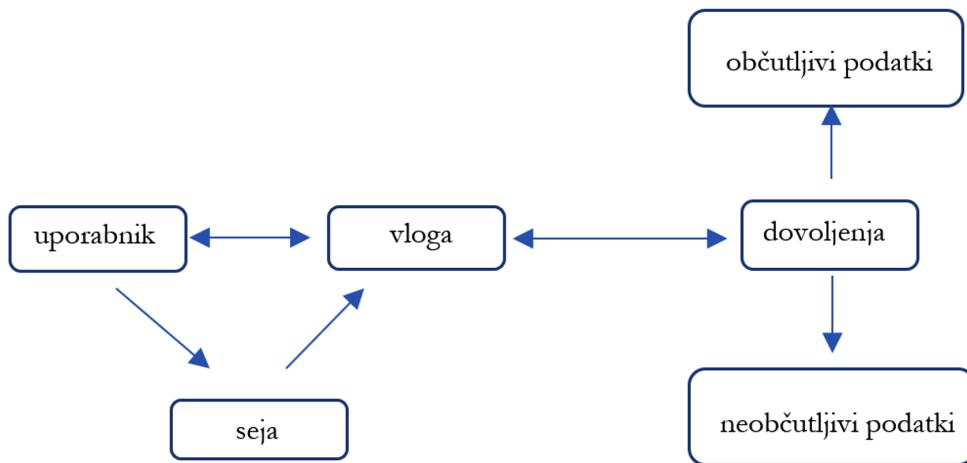
Šifriranje občutljivih podatkov (atributov) je dober pristop k procesu varovanju podatkov, saj ne spreminja podatkov, ne prihaja do izgube (generalizacije), ali šuma. Med slabosti štejemo predvsem težavno implementacijo pri velikih zbirkah podatkov, poleg tega pa rezultat (originalni podatki) odkriva tako javne kot skrite atribute [20], [35].

Metode šifriranja podatkov lahko uporabimo v kombinaciji z razprševanjem podatkov, in sicer na dva načina: podatki so lahko razdeljeni vertikalno skozi več podatkovnih baz (med več lastnikti), kjer so šifrirani zgolj zasebni podatki, lahko pa so šifrirani vsi podatki. V praksi se je razvil model »ohranjanje varnosti na podlagi kontrole dostopa preko vlog« (ang. privacy preserving role based access control approach – PRBAC), ki je ponazorjen na sliki 5. Ta model kombinira vertikalno razprševanje podatkov in tehnologijo šifriranja za dostop do podatkov, ki jih deli na javne in zasebne [36].

PRBAC je eden izmed pristopov za zaščito informacij v relacijski bazi podatkov, ki uporabnikom

Tabela 3: dodatno spremenjena tabela s podatki o pacientih Vir: Povzeto po Lin (2016)

Atributi kvazi identifikatorjev (QI)			Občutljivi atributi
Starost	Holesterol	Trigliceridi	Bolezni
< 50	[5-7]	[0-6]	bolezen srca
< 50	[5-7]	[0-6]	rak
< 50	[5-7]	[0-6]	hipertenzija
< 50	[5-9]	[2-6]	hipertenzija
< 50	[5-9]	[2-6]	rak
< 50	[5-9]	[2-6]	bolezen srca



Slika 5: Model PRBAC Vir: [36]

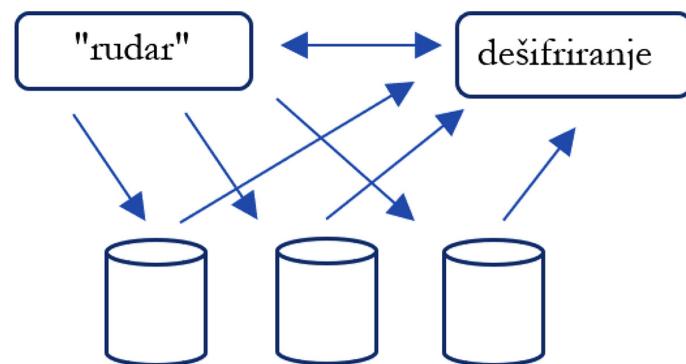
preprečuje pridobivanje dovolj velikih in raznolikih vzorcev baze podatkov. Prav tako onemogoča sledenje vzorcem, ki jih ne bi smeli razkriti. To omogoča razvrščanje podatkov na javne (neobčutljive) in tajne (občutljive). Slabost metode je časovna potratnost (zaradi zahtevnosti postopkov šifriranja in dešifriranja) ter čas, potreben za sestavljanje relacije (iz n podatkovnih baz). Postopek je moč pohitriti z uvedbo horizontalnega razprševanja podatkov. Tedaj je iskana relacija v celoti v eni izmed podatkovnih baz, a je takšna realizacija manj varna [36].

Pri uporabi *razprševanja podatkov* in šifriranja, ali uporabi kombinacije teh dveh metod, podatki ostajajo v obliki, kot so nastali. S tem, ko jih ne spremimo ali izkrivljamo, ostajajo za nadaljnjo analizo potencialno najustreznejši, a bi pri uporabi lahko prišlo do kršitve ohranjanja zasebnosti, predvsem v primeru, če bi do podatkov lahko dostopali nelegalno ali nepooblaščeno.

Model PRBAC je vertikalno, ter funkcionalno porazdeljene podatkovne baze težavo delno odpravljajo, saj je v prvem primeru zagotovljen dostop do podatkov preko vlog dostopa, v drugem pa do pridobitve zgolj dela podatkov (dela atributov relacije). Nobeden od teh dveh pristopov ni primeren za nudjenje podatkov v množično uporabo (npr. za podatkovno rudarjenje), saj ni poskrbljeno za anonimizacijo podatkov oz. za zakritje povezave med lastnikom podatkom in njegovimi atributi v relaciji drugače, kot s ponujanjem dostopa do zgolj dela podatkov končnemu uporabniku (slika 6).

#### 4. ZAKLJUČEK

Pri iskanju ravnovesja med nudjenjem podatkov za analizo, z namenom ustvarjanja dodane vrednosti in znanj, je potrebno poskrbeti za zaščito identitet in interesov posameznika po anonimnosti. Pri pregledu literature smo zasledili, da se za reševanje omenjenih



Slika 5: Dešifriranje vertikalno porazdeljenih podatkov Vir: [36]

izzivov na področju podatkovnega rudarjenja razvilo posebno podpodročje, ki se ukvarja z ohranjanjem zasebnosti pri tem procesu. Metode, s katerimi dosegamo zaščito posameznika na eni in uporabno vrednost podatkov na drugi strani v grobem delimo na metode razprševanja podatkov, metode izkriviljanja in metode šifriranja podatkov. Za doseganje višje zaščite lahko uporabimo tudi kombinacije teh metod.

Za primere iz prakse, kjer bi uporaba tovrstnih metod pripomogla k boljši uporabi (javnih) podatkov in informacij javnega značaja, omenimo Zakon o dostopu do informacij javnega značaja (ZDIJZ-NPB10)<sup>8</sup>. Ta v šestem členu navaja izjeme, kjer dostop do takšnih podatkov ni dovoljen, večinoma zaradi posledic razkritja in s tem kršitve varstva osebnih, ali drugih podatkov. Pri Splošni uredbi o varstvu podatkov (ang. general data protection regulation – GDPR<sup>9</sup>), uredba v 17. členu določa Pravico do izbrisala (»pravico do pozabe«), ki določa pogoje, pod katerimi lahko posameznik zahteva izbris osebnih podatkov iz dokumentov, ter 28. člen, kjer določa pristojnosti in omejitve obdelovalca podatkov. Za omogočanje dostopa do dokumentov takšne narave sta predlagana šifriranje in revizija dostopov [37] ter izkriviljanje podatkov. Skladno z GDPR se lahko dokumenti objavijo po odstranitvi vseh podatkov, ki identificirajo posameznika [38].

Največ izboljšav in novih metod in algoritmov smo zasledili ravno za področje spreminjanja podatkov (ang. data perturbation). To je edini pristop, ki podatke transformira, a pri tem ohranja (skozi funkcijo transformacije) možnost rekonstrukcije, podatki pa ohranjajo visoko uporabno vrednost za nadaljnjo uporabo – podatkovno rudarjenje.

## VIRI IN LITERATURA

- [1] J. R. Smith and S.-F. Chang, »New visual information in the form of images Visually Searching the Web for Content,« pp. 12–20, 1997, doi: 10.1080/10413200.2012.704621.
- [2] R. Mendes and J. P. Vilela, »Privacy-Preserving Data Mining: Methods, Metrics, and Applications,« *IEEE Access*, vol. 5, pp. 10562–10582, 2017, doi: 10.1109/ACCESS.2017.2706947.
- [3] R. Devakunchari, »Analysis on big data over the years,« *International Journal of Scientific and Research Publications*, vol. 4, no. 1, pp. 1–7, 2014, [Online]. Available: [www.ijrsp.org](http://www.ijrsp.org).
- [4] H. Sahu, S. Shrama, and S. Gondhalakar, »A Brief Overview on Data Mining Survey,« *Ijctee*, vol. 1, no. 3, pp. 114–121, 2008.
- [5] A. S. Shanthi and M. Karthikeyan, »A review on privacy preserving data mining,« *2012 IEEE International Conference on Computational Intelligence and Computing Research, ICCIC 2012*. 2012, doi: 10.1109/ICCI.2012.6510302.
- [6] A. Singh, »Data Publishing Techniques and Privacy Preserving,« *Int. J. Inf. Secur. Res.*, vol. 9, no. 3, pp. 1–23, 2019.
- [7] K. (Eds. .) Markov, A., Polak Petrič, A., & Nastovska, *Splošna deklaracija človekovih pravic*. Ljubljana : Fakulteta za družbenne vede, Založba FDV : Ministrstvo za zunanje zadeve Republike Slovenije, 2018, 2018.
- [8] S. SA, »Big Data in Healthcare Management: A Review of Literature,« *American Journal of Theoretical and Applied Business*, vol. 4, no. 2, p. 57, 2018, doi: 10.11648/j.ajtab.20180402.14.
- [9] L. Cranor, T. Rabin, V. Shmatikov, S. Vadhan, and D. Weitzner, »Towards a Privacy Research Roadmap for the Computing Community,« [Http://Cra.Org/Ccc/Resources/Ccc-Led-Whitepapers/](http://Cra.Org/Ccc/Resources/Ccc-Led-Whitepapers/), pp. 1–23, 2016, [Online]. Available: <http://arxiv.org/abs/1604.03160>.
- [10] R. Agrawal and R. Srikant, »Privacy-preserving data mining,« *SIGMOD Rec. (ACM Spec. Interes. Gr. Manag. Data)*, vol. 29, no. 2, pp. 439–450, Jan. 2000, doi: 10.1145/335191.335438.
- [11] Y. Lindell and B. Pinkas, »Privacy Preserving Data Mining,« pp. 36–54, 2000.
- [12] L. Cranor, T. Rabin, V. Shmatikov, S. Vadhan, and D. Weitzner, »Towards a Privacy Research Roadmap for the Computing Community,« [Http://Cra.Org/Ccc/Resources/Ccc-Led-Whitepapers/](http://Cra.Org/Ccc/Resources/Ccc-Led-Whitepapers/), pp. 1–23, 2016.
- [13] K. Vassakis, E. Petrakis, and I. Kopanakis, »Big Data Analytics: Applications, Prospects and Challenges,« 2018, pp. 3–20.
- [14] A. Pawar, S. Ahirrao, and P. P. Churi, »Anonymization Techniques for Protecting Privacy : A Survey,«
- [15] L. Xu, C. Jiang, J. Wang, J. Yuan, and Y. Ren, »Information security in big data: Privacy and data mining,« *IEEE Access*, vol. 2, no. January, pp. 1151–1178, 2014, doi: 10.1109/ACCESS.2014.2362522.
- [16] R. Agrawal and R. Srikant, »Privacy-preserving data mining,« *SIGMOD Rec. (ACM Spec. Interes. Gr. Manag. Data)*, vol. 29, no. 2, pp. 439–450, Jan. 2000, doi: 10.1145/335191.335438.
- [17] Y. Lindell and B. Pinkas, »Privacy Preserving Data Mining BT – Advances in Cryptology – CRYPTO 2000,« 2000, pp. 36–54.
- [18] X. Qi and M. Zong, »An Overview of Privacy Preserving Data Mining,« *Procedia Environ. Sci.*, vol. 12, no. Part B, pp. 1341–1347, Jan. 2012, [Online]. Available: <http://10.0.3.248/j.proenv.2012.01.432>.
- [19] Y. Abdul, A. S. Aldeen, M. Salleh, and M. A. Razzaque, »A comprehensive review on privacy preserving data mining,« *Springerplus*, 2015, doi: 10.1186/s40064-015-1481-x.
- [20] S. Taneja, S. Khanna, and S. Tilwalia, »A Review on Privacy Preserving Data Mining: Techniques and Research Challenges,« vol. 6, no. 3, pp. 35–40, 2016.
- [21] P. P. Panse and P. L. Paikrao, »Survey of Privacy Preserving Techniques and Upcoming Techniques : A Review,« vol. 6, no. 2, pp. 1798–1802, 2017.
- [22] S. Upadhyay, C. Sharma, P. Sharma, P. Bharadwaj, and K. R. Seeja, »Privacy preserving data mining with 3-D rotation transformation,« *J. King Saud Univ. – Comput. Inf. Sci.*, vol. 30, no. 4, pp. 524–530, 2018, doi: 10.1016/j.jksuci.2016.11.009.
- [23] A. Gionis and T. Tassa, »K-anonymization with minimal loss of information,« *IEEE Transactions on Knowledge and Data Engineering*, vol. 21, no. 2, pp. 206–219, 2009, doi: 10.1109/TKDE.2008.129.
- [24] A. Sachan, D. Roy, and P. V Arun, »An Analysis of Privacy Preservation Techniques in Data Mining BT – Advances in Computing and Information Technology,« 2013, pp. 119–128.

<sup>8</sup> Zakon o dostopu do informacij javnega značaja, [https://zakonodaja.com/zakon/zdjjz\\_dostopano\\_september\\_2021](https://zakonodaja.com/zakon/zdjjz_dostopano_september_2021)

<sup>9</sup> GDPR, <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX:02016R0679-20160504>, dostopano september 2021

- [25] X. B. Li and S. Sarkar, »A tree-based data perturbation approach for privacy-preserving data mining,« *IEEE Transactions on Knowledge and Data Engineering*, vol. 18, no. 9. pp. 1278–1283, 2006, doi: 10.1109/TKDE.2006.136.
- [26] EK, »Mnenje št. 5/2014 o anonimizacijskih tehnikah,« Evropska komisija, Delovna skupina za varstvo podatkov člena 29, 2014, [Online]. Available: [https://ec.europa.eu/justice/article-29/documentation/opinion-recommendation/files/2014/wp216\\_sl.pdf](https://ec.europa.eu/justice/article-29/documentation/opinion-recommendation/files/2014/wp216_sl.pdf).
- [27] P. Samarati and L. Sweeney, »Generalizing data to provide anonymity when disclosing information (abstract),« 1998.
- [28] L. Sweeney, »K-Anonymity: A Model for Protecting Privacy,« *Int. J. Uncertain. Fuzziness Knowl.-Based Syst.*, vol. 10, no. 5, pp. 557–570, 2002, doi: 10.1142/S0218488502001648.
- [29] C. Y. Lin, »A reversible data transform algorithm using integer transform for privacy-preserving data mining,« *J. Syst. Softw.*, vol. 117, pp. 104–112, 2016, doi: 10.1016/j.jss.2016.02.005.
- [30] A. Gkoulalas-Divanis and V. S. Verykiosc, »An overview of privacy preserving data mining,« *Crossroads*, vol. 15, no. 4, pp. 23–26, 2009, doi: 10.1145/1558897.1558903.
- [31] A. Machanavajjhala, J. Gehrke, D. Kifer, and M. Venkitasubramaniam, » $\ell$ -Diversity: Privacy beyond k-anonymity,« *Proceedings – International Conference on Data Engineering*, vol. 2006. p. 24, 2006, doi: 10.1109/ICDE.2006.1.
- [32] J. Vasa and P. Modi, »Review of Different Privacy Preserving Techniques in PPDP,« *International Journal of Engineering Trends and Technology*, vol. 59, no. 5. pp. 223–227, 2018, doi: 10.14445/22315381/ijett-v59p242.
- [33] G. Hao and X. Ya-Bin, »Research on privacy preserving method based on T-closeness model,« in *2017 3rd IEEE International Conference on Computer and Communications (ICCC)*, 2017, pp. 1455–1459, doi: 10.1109/Comp-Comm.2017.8322783.
- [34] P. (1) Quirós, P. (1) Alonso, I. (2) Diaz, and S. (3) Montes, »Protecting data: a fuzzy approach,« *Int. J. Comput. Math.*, vol. 92, no. 9, pp. 1989–2000, Sep. 2015, doi: 10.1080/00207160.2014.928700.
- [35] B. Pinkas, »Cryptographic Techniques for Privacy-Preserving Data Mining,« *SIGKDD Explor. Newsl.*, vol. 4, no. 2, pp. 12–19, Dec. 2002, doi: 10.1145/772862.772865.
- [36] L. Vasudevan, S. E. D. Sukanya, and N. Aarthi, »Privacy preserving data mining using cryptographic role based access control approach,« *Imecs 2008: International Multiconference of Engineers and Computer Scientists, Vols I and II*. pp. 474–479, 2008.
- [37] C. Evans, »HOW GDPR WILL SHAKE UP DATA STORAGE.,« *Comput. Wkly.*, pp. 25–28, Aug. 2017, [Online]. Available: <http://nukweb.nuk.uni-lj.si/login?url=https://search.ebscohost.com/login.aspx?direct=true&AuthType=ip,uid&db=f5h&AN=124782283&lang=sl&site=eds-live&scope=site>.
- [38] K. Broen, R. Trangucci, and J. Zelher, »Measuring the impact of spatial perturbations on the relationship between data privacy and validity of descriptive statistics,« *Int. J. Health Geogr.*, vol. 20, no. 1, pp. 1–17, 2021, doi: 10.1186/s12942-020-00256-8.

**Matjaž Kragelj** Zaposlen v Narodni in univerzitetni knjižnici, zadnje desetletje kot vodja enote za informacijsko tehnologijo in digitalno knjižnico. Njegovo področje dela je stičišče računalništva in knjižnične stroke. Večina njegovih dejavnosti vključuje načrtovanje in upravljanje digitalne knjižnice in spletnih storitev, razvoj in usklajevanje dejavnosti nacionalnega aggregatorja e-vsebin na področju kulture, izobraževanja in svetovanja na področju integriranega upravljanja digitalnih virov, sodelovanje pri razvoju in vzdrževanju celovitih informacijskih rešitev v knjižnici. Sodeluje tudi pri razvoju in vzdrževanju digitalnega arhiva knjižnice in storitev zajema in ohranjanja slovenskega spletja. Sodeluje pri digitalizaciji nacionalne kulturne dediščine, shranjene v knjižnici, ter na področju spremeljanja in oblikovanja (mednarodnih) priporočil in smernic na področju pridobivanja, dolgoročnega arhiviranja in dostopa do digitalnih virov. Sodeloval je v več mednarodnih projektih in bil avtor več člankov s svojega področja dela. V zadnjih letih je več pozornosti namenil vizualizaciji podatkov in ruderjenja besedil, iskanju povezav in vzorcev v podatkih.

**Mirjana Kljajić Borštnar** je izredna profesorica za področje informacijskih sistemov na Fakulteti za organizacijske vede, Univerze v Mariboru. Njeno raziskovalno delo je usmerjeno v sisteme za podporo odločjanju, odkrivanje znanja v podatkih in organizacijsko učenje. Izsledke raziskav objavlja v mednarodnih znanstvenih revijah in konferencah, med drugim Expert Systems with Application, PLOS ONE, Industrial Management & Data Systems, System Dynamics Review. Sodeluje v evropskih in domačih projektih. Je sovodka programskega odbora Blejske e-konference in Simpozija o operacijskih raziskavah v Sloveniji ter članica programskih odborov konferenc DSI, DataScience, WorldCist in drugih. V domačem okolju je aktivna kot predstavnica raziskovalnih organizacij v SRIP PMIS za področje Ai, HPC & Big Data, članica izvršnega odbora pobude AI4Slovenia in članica uredniškega odbora revije Uporabna informatika.

**Alenka Brezavšček** je izredni profesor na Fakulteti za organizacijske vede Univerze v Mariboru. Njeno habilitacijsko področje so kvantitativne metode v organizacijskih vedah. Ukvaja se z raziskavami na področju stohastičnih procesov, zanesljivosti in razpoložljivosti tehničnih sistemov ter varnosti informacijskih sistemov.

# ► Iz Islovarja

Islovar je spletni terminološki slovar informatike, ki ga objavlja jezikovna sekcija Slovenskega društva INFORMATIKA na naslovu <http://www.islovar.org>. Slovar je javno dostopen za vpogled in vnašanje novih izrazov. Objavljamo izbor novejših izrazov, ki smo jih vnesli in uredili v Islovarju:

**aplikacijski napád -ega -a m** (*angl. application attack*)  
porazdeljeni napad onemogočanja storitve, kjer se s posebej skonstruiranimi zahtevami povzroči izpad ali upočasnitev delovanje aplikacije ali strežnika

**izkoriščeválec ranljivosti -lca -- m** (*angl. exploit*)  
škodljiva koda, ki izkorišča ranljivost računalniškega sistema

**komplét za izkoríščanje -a --- m** (*angl. exploit toolkit, exploit kit*) programski paket z različnimi orodji za izkoríščanje ranljivosti računalniških sistemov, npr. brskalnikov, operacijskih sistemov

**módra skupína -e -e ž** (*angl. blue team*) varnostni strokovnjaki, ki branijo informacijski sistem pred napadi; prim. rdeča skupina

**podatkovno vrtanje -ega -a s** (*angl. data drilling*)  
operacije na hierarhično urejenih podatkih; prim. podatkovno rudarjenje

**protokólni napád -ega -a m** (*angl. protocol attack*)  
porazdeljeni napad onemogočanja storitve, kjer se izkoristi lastnosti v zasnovah komunikacijskih protokolov

**rdeča skupína -e -e ž** (*angl. red team*) varnostni strokovnjaki, ki s testnimi napadi preizkušajo odpornost informacijskega sistema; prim. modra skupina

**rézanje -a s** (*angl. slice and dice*) delitev celotnega nabora podatkov na manjše dele ali poglede

**vrtanje navzdól -a -- s** (*angl. drill down, drilldown*)  
podatkovno vrtanje, ki vodi od splošnega k podrobnejšemu prikazu podatkov; sin. vrtanje v globino; prim. vrtanje navzgor, vrtanje skozi

**vrtanje navzgór -a -- s** (*angl. drill up, drillup*)  
podatkovno vrtanje, ki vodi od podrobnega k bolj splošnemu prikazu podatkov; prim. vrtanje navzdol, vrtanje skozi

**vrtanje skozi -a -- s** (*angl. drill through, drillthrough*)  
podatkovno vrtanje, ki vodi neposredno do določene entitete v podatkovni bazi; prim. vrtanje navzgor, vrtanje navzdol

# Izpitni centri ECDL

**ECDL** (European Computer Driving License), ki ga v Sloveniji imenujemo evropsko računalniško spričevalo, je standardni program usposabljanja uporabnikov, ki da zaposlenim potrebno znanje za delo s standardnimi računalniškimi programi na informatiziranem delovnem mestu, delodajalcem pa pomeni dokazilo o usposobljenosti. V Evropi je za uvajanje, usposabljanje in nadzor izvajanja ECDL pooblaščena ustanova ECDL Fundation, v Sloveniji pa je kot član CEPIS (Council of European Professional Informatics) to pravico pridobilo Slovensko društvo INFORMATIKA. V državah Evropske unije so pri uvajanju ECDL močno angažirane srednje in visoke šole, aktivni pa so tudi različni vladni resorji. Posebno pomembno je, da velja spričevalo v 148 državah, ki so vključene v program ECDL. Doslej je bilo v svetu v program certificiranja ECDL vključenih že preko 16 milijonov oseb, ki so uspešno opravile preko 80 milijonov izpitov in pridobile ustrezne certificate. V Sloveniji je bilo doslej v program certificiranja ECDL vključenih več kot 18.000 oseb in opravljenih več kot 92.000 izpitov. V Sloveniji sta akreditirana dva izpitna centra ECDL, ki imata izpostave po vsej državi.



**Micro Team**

# Znanstveni prispevki

Maša Kljun, Matija Teršek, Slavko Žitnik

POMENSKA ANALIZA KATEGORIJ SOVRAŽNEGA GOVORA  
V OBSTOJEČIH OZNAČENIH KORPUSIH

Jan Bajt, Marko Robnik Šikonja

STROJNA ANALIZA TEMATIK IN SENTIMENTA SLOVENSKIH  
NOVIČARSKIH MEDIJEV

## Strokovni prispevki

Alenka Baggia, Robert Leskovar, Branislav Šmitek, Saša Mlakar, Katja Pesjak,  
Mateja Bahun, Manuel Lillo-Crespo, Jorge Riquelme Galindo, Christine FitzGerald,  
Liz Kingston, Alice Coffey, Lucia Cadorin, Alvisa Palese, Barbara Narduzzi,  
Sara Scarsini, Uroš Rajkovič

E-UČILNICA ZA UČENJE NA DOKAZIH PODPRTE ZDRAVSTVENE NEGE

Gregor Polančič, Mateja Kocbek Bule

STANJE IN TRENDI NA PODROČJU RUDARJENJA PROCESOV

Živa Rant, Dalibor Stanimirovič, Jure Janet

FUNKCIONALNOSTI IN UPORABA PORTALA ZA PACIENTE ZVEM IN  
CENTRALNEGA REGISTRA PODATKOV O PACIENTU

## Prispevki iz Konference Dnevi slovenske informatike

Matjaž Kragelj, Mirjana Kljajić Borštnar, Alenka Brezavšček

PROBLEMATIKA OHRANJANJA ZASEBNOSTI PRI PODATKOVNEM  
RUDARJENJU DOKUMENTOV Z OBČUTLJIVIMI PODATKI

## Informacije

IZ ISLOVARJA

ISSN 1318-1882



9 771318 188001