

# SLOVENSKÁ ŠTATISTIKA a DEMOGRAFIA

SLOVAK STATISTICS  
and DEMOGRAPHY

1/2024

ročník/volume 34

Recenzovaný vedecký časopis so zameraním na prezentáciu moderných štatistických a demografických metód a postupov.

Scientific peer-reviewed journal focusing on the presentation of modern statistical and demographic methods and procedures.

Článok/Article: 9

Typ článku/Type of article: informatívny článok/informative article

Strany/Pages: 93 – 110

Dátum vydania/Publication date: 15. január 2024/January 15, 2024



Informatívny článok/Informative article

**Dagmar CELUCHOVÁ BOŠANSKÁ, Martin JANÍK, Filip NGUYEN**  
Alistiq, s. r. o.

## **POKUS O MONITOROVANIE SOCIÁLNEHO NAPÄTIA Z PRÍSPEVKOV NA SOCIÁLNEJ SIETI FACEBOOK**

### **ATTEMPT OF MONITORING OF SOCIAL TENSION FROM POSTS ON THE FACEBOOK SOCIAL NETWORKING WEBSITE**

#### **ABSTRAKT**

Sociálne siete sú čoraz populárnejším miestom, kde ľudia zdieľajú svoje pocity a názory na rôzne udalosti a tematicky súvisiace správy. Táto popularita vytvára veľké množstvo údajov týkajúcich sa nálady a sociálneho napätia ľudí. Cieľom bolo analyzovať sentiment príspevkov na sociálnej sieti Facebook v slovenčine a použiť tieto údaje na získanie informácií o emocionálnom stave ľudí. Použitá metóda využíva model na spracovanie prirodzeného jazyka XLM-RoBERTa-large a umožňuje korelovať sociálne napätie s udalosťami zo skutočného sveta. Analýza sentimentu príspevkov na sociálnych sieťach môže byť užitočná pre tvorcov politik a sociológov, a v budúcnosti sa môže rozšíriť na ďalšie platformy a jazyky.

#### **ABSTRACT**

Social networks are an increasingly popular place where people share their feelings and opinions on various events and thematically related topics. This popularity creates a large amount of data regarding people's mood and social tension. The aim was to analyze the sentiment of the posts on the social networking website Facebook in Slovak and to use this data to obtain information about the emotional state of people. This method uses the natural language processing model XLM-RoBERTa-large and allows social tensions to be correlated with real-world events. Sentiment analysis of social media posts can be useful for policymakers and sociologists, and may be extended to other platforms and languages in the future.

#### **KLÚČOVÉ SLOVÁ**

analýza sentimentu, sociálne siete, strojové učenie, sociálne napätie, hĺbková analýza dát

#### **KEY WORDS**

sentiment analysis, social networks, machine learning, social tension, data mining

#### **1. ÚVOD**

Používatelia online sociálnych sietí sú prepojení prostredníctvom vzťahov a interakcií podobne ako v reálnom živote. Vzťahy sú stabilné spojenia medzi dvoma alebo viacerými používateľmi. Existuje viacero typov vzťahov, napríklad priateľstvo alebo príslušnosť k rovnakej skupine. Niektoré typy vzťahov sú vzájomné, ako napríklad príbuzenstvo, zatiaľ čo iné sú riadené alebo asymetrické, ako napríklad vzťah sledovania populárnej osobnosti na sociálnej sieti. Interakcie sa objavujú, keď používateľ komunikuje s ostatnými. Typy interakcií zahŕňajú zverejnené statusy, priame správy, odpovede a zmienky používateľov. Väčšina týchto typov zahŕňa aj tvorbu obsahu. Keď používateľ vytvorí alebo zverejní nový obsah, vytvorí sa autorský

vzťah medzi používateľom a obsahom. Nový obsah môže súvisieť aj s existujúcim obsahom (napr. ako odpoveď alebo zmienka) alebo s inými používateľmi (napr. používateľ je spomenutý v obsahu). Používatelia potom môžu interagovať s novovytvoreným obsahom tak, že naň odpovedia, napríklad že sa im páči, alebo si ho uložia.

Interakcie na sociálnych sieťach je možné vnímať ako objemné množstvo údajov neštruktúrovaného textu ako sú články, blogové príspevky, statusy a komentáre. Dajú sa ľahko analyzovať pomocou niekoľkých techník dátovej vedy, pričom ako vhodná metóda analýzy neštruktúrovaných textových dát sa javí sémantická sieťová analýza, ktorá umožňuje sledovať fenomény, ako je sociálne napätie, dôvera alebo polarizácia [26].

Vzostup sociálnych sietí ako prostriedkov na vyjadrenie názorov a emócií možno pripísať zvyšujúcej sa dostupnosti technológií. S rozšírením smartfónov a internetového pripojenia majú ľudia neustály prístup k platformám sociálnych médií, čo umožňuje jednotlivcom vyjadrovať svoje názory a emócie v pohybe, kedykoľvek a z akéhokoľvek miesta. Najvyužívanejšou sociálnou sieťou u nás (ale aj globálne) je Facebook. Podľa prieskumu Go4insight ju [9] používa až 76 % obyvateľov Slovenska aspoň raz do mesiaca. Denné využívanie je na úrovni 55 %. Keďže popularita týchto platforiem stále rastie, rastie aj dôraz na dôležitosť porozumenia interakcií v týchto digitálnych priestoroch.

### **1.1. Analýza sentimentu na sociálnej sieti pohľadom modernej sociológie**

Emócie predstavujú dôležitý spoločenský signál pre ostatných – informujú ich o rôznych spôsoboch interakcie s ohľadom na vlastnú motiváciu a ciele. Svoje emócie ľudia pravidelne zdieľajú s ostatnými ľuďmi aj na sociálnych sieťach vzhľadom na ich hodnotnú spoločenskú funkciu a ovplyvňujú emócie ostatných. Napríklad šťastie sa môže rozšíriť cez sociálnu sieť a spôsobiť vznik klastrov šťastných a nešťastných ľudí. Prístupov, ako nazerať a skúmať emócie, je celý rad, svoj pohľad na emócie ponúkajú antropológovia, neurofyziológovia, psychológovia a mnohí ďalší. Český psychológ Milan Nakonečný vymedzuje pojem emócie ako prežívanie jednoty citenia a telesných zmien s odkazom na ich pôvodný biologický význam, ktorým bola adaptívna reakcia na dôležité životné situácie. V tomto zmysle uvádza emócie ako procesy hodnotenia životného významu situácií, ktoré sú súčasne spojené s mobilizáciou energie (aktiváciou organizmu) nutné na vytvorenie účelného správania. Podľa Nakonečného boli primárne emócie súčasťou inštinktov [19].

V zahraničí sa vo vzťahu k analýze sentimentu uznáva Plutchikova teória primárnych emócií a ich zmiešání. Podľa Plutchika vychádzajú emócie z genetického základu a vznikli selekciou životne úspešných adaptívnych mechanizmov a ich postupným zdokonaľovaním, a ako také sú formou adaptácie. Plutchik uvádza osem primárnych emócií, ktoré sú vrodené, ostatné vznikajú ich miešaním. Primárne emócie sú akceptovanie, strach, prekvapenie, smútok, hnus, hnev, očakávanie, a radosť. Sekundárne emócie sú tzv. dyády, triády a ďalšie zmiešaniny vybraných emócií [23].

V klasickej sociologickej literatúre sa pojem sociálne napätie používa pri analýze procesov pretrhávania sociálnych väzieb, straty hodnôt a zvýšenia anómie. Sociológ Neil Joseph Smelser definuje „napätie“ ako tendenciu k nerovnováhe výmeny medzi dvoma alebo viacerými zložkami systém [27]. Sociálne napätie je možné opísať aj ako

špecifickú podmienku sociálneho vedomia a sociálnych emócií. Tento stav je charakterizovaný hromadením duševnej únavy a podráždenosti, frustrácie a deprivácie, agresivity a depresie významnej časti spoločnosti. K sociálnemu napätiu je možné pristúpiť aj tak, že verejné inštitúcie môžu fungovať ako „bezpečnostné ventily“, tie môžu slúžiť na prerušenie pocitov nepriateľstva, môžu fungovať ako bleskozvody, ale nemôžu zabrániť opakovanému nahromadeniu napätia [5].

Prvým krokom v analýze sentimentu je zvyčajne definovanie viet, ktoré vyjadrujú sentiment. V minulosti sa tieto vety kategorizovali buď ako subjektívne alebo objektívne, pričom iba prvé z nich boli spojené so sentimentom. Objektívne vety prezentovali fakty, zatiaľ čo subjektívne vety vyjadrovali osobné pocity alebo presvedčenie. V súčasnosti sa však všeobecne uznáva, že subjektivita by sa nemala vždy stotožňovať s názorom. Napríklad, subjektívne vety nemusia vždy vyjadrovať sentiment, ako napr.: „*nepoznám farmára, ktorému by aspoň raz zvieru neušlo*“. Na druhej strane, objektívne vety môžu skutočne vyjadrovať sentiment, ako napr. „*Slúchadlá sa rozbili za dva dni*“. Okrem toho vety často obsahujú viacero polarít, takže je náročné klasifikovať vetu ako čisto pozitívnu alebo negatívnu [16]. Sentiment príspevkov a komentárov sa preto hodnotí vždy z pohľadu autora, t. j. zisťuje sa emocionálny podtón textu z pohľadu, či v prejave autora prevláda pozitívna alebo negatívna nálada. Inými slovami, cieľom analýzy sentimentu je určiť postoj alebo emocionálny stav autora príspevku vrátane primárnych emócií.

Odkedy si online sociálne médiá získali celosvetovú popularitu, objavil sa široký prúd výskumu extrakcie a štruktúrovania dostupných informácií [7]. Indikátory sentimentu sa vytvárajú s cieľom reflektovať nálady, názory alebo očakávania skupiny respondentov. Môže ísť o rôzne skupiny jednotlivcov, domácností alebo podnikov. Indikátory sentimentu sú väčšinou založené na kvalitatívnych prieskumoch, v ktorých sa kladú otázky týkajúce sa názorov na minulé alebo aktuálne dianie, či na vývoj do budúcnosti. Podľa Hartla [10] sa nálada všeobecne definuje ako emocionálny stav, ktorý v priebehu určitého času sprevádza prežívanie a činnosť človeka. Ako uvádza Nakonečný kvalita cítenia zotravnávajúca v čase sa nazýva nálada, a je to teda citový stav, ktorý tvorí akési pozadie duševného života jedinca [19].

Najpopulárnejšími sociálnymi sieťami sú X (predtým známa ako Twitter) a Facebook. X je obzvlášť populárny medzi zahraničnými vedcami kvôli dostupnosti veľkého množstva údajov, ktoré je možné zhromaždiť. Tieto sociálne siete sú ideálnym zdrojom údajov na analýzu sentimentu, pretože poskytujú jednotlivcom platformu na vyjadrenie ich myšlienok, pocitov a názorov na rôzne témy, od aktuálnych udalostí a spoločenských problémov až po osobné skúsenosti a záujmy. Schopnosť slobodne sa vyjadrovať a byť vypočutý ostatnými prispieva k rastúcej príťažlivosti sociálnych sietí. Vďaka možnosti sledovať, páčiť sa a komentovať príspevky ostatných sa jednotlivci môžu zapojiť do konverzácií a diskusií. Táto interakcia umožňuje výmenu rôznych názorov a emócií, výsledkom čoho je podnetné online prostredie.

Vedecké práce v sociológii zamerané na analýzu sentimentu príspevkov na sieťach Facebook a X sa zaoberali najmä reakciou verejnosti na extrémne udalosti [15, 21], modelovaním ľudského správania [1] a predpovedaním akcií [20], postojov [17] či dokonca výsledkov volieb [28].

Analýza sentimentu sociálnych sietí je okrem uvedených príkladov aj cenným nástrojom pre marketing, pretože pomáha výskumníkom a podnikom získať prehľad o tom, ako zákazníci vnímajú ich produkty, značku alebo celkovú zákaznícku skúsenosť. Analýzou a pochopením pocitov vyjadrených v recenziách zákazníkov, príspevkoch na sociálnych sieťach a iných formách spätnej väzby online môžu marketéri efektívne prispôbiť svoje marketingové stratégie a správy. Analýza pozitívneho sentimentu sa môže použiť na identifikáciu spokojných zákazníkov a influencerov, na ktorých sa môžu zamerať [11].

## 2. POUŽITÉ ÚDAJE

V podprojekte *Monitorovanie sociálneho napätia z príspevkov na sociálnej sieti Facebook* sa pri analýze sentimentu využili verejné príspevky na Facebooku, pozostávajúce zo statusov, komentárov, odpovedí a reakcií (Páči sa mi) za obdobie jedného roka, od 1. septembra 2022 do 31. augusta 2023. Zdrojom zhromažďovania týchto údajov bola sociálna sieť Facebook spoločnosti Meta, pričom technika použitá na kompiláciu údajov z tejto platformy bola Facebook GraphAPI. Zhromažďovanie údajov sa realizovalo v prísnom súlade s etickými normami s dôrazom na anonymizáciu akýchkoľvek osobných údajov, čím sa zabezpečila neutralita a integrita zhromaždených údajov. Získavali sa len verejne zdieľané príspevky a komentáre bez informácie o profiloch používateľov, čiže anonymizované údaje.

Zdrojové údaje predstavujú súbor neštruktúrovaných údajov a obsahujú celkove 31 755 230 príspevkov, ktoré majú svoj identifikátor a časovú pečiatku, čo umožňuje zoradiť ich v čase a agregovať po jednotlivých dňoch. Komentáre sú prelinkované s príspevkom, ktorého sa týkajú a komentáre na komentáre aj s komentárom, na ktorý reagujú. Každý príspevok a komentár má navyše pripísaný počet reakcií cez emotikony ako *Páči sa mi* a *srdiečko*. Momentálne sa však ešte pre takýto typ prepojení a informácií nenašlo využitie.

Na analýzu sentimentu sa využili príspevky (POST) a komentáre (COMMENT) od používateľov na skupinových stránkach (FB groups), dedikovaných stránkach organizácií a firiem (FB pages) alebo profiloch verejne známych osobností. Zdroje – teda profily, skupiny a stránky – sa vybrali kombináciou algoritmov strojového učenia a ľudskej expertízy. Pokročilé neurónové siete najprv zmapovali široký terén informácií v online priestore a identifikovali hlavné a okrajové zdroje na sociálnych sieťach, v blogoch, na fórach, webových stránkach, platformách na zasielanie správ, v skupinách a ďalších zdrojoch. Na identifikáciu ďalších zdrojov vrátane subkultúrnych a okrajových skupín sa používali pokročilé algoritmy založené na grafoch. Potom odborní analytici s dlhoročnými skúsenosťami v oblasti bezpečnosti, dezinformácií a politickej analýzy tieto zdroje preskúmali, aby vytvorili vyvážený súbor tisícov najrelevantnejších zdrojov otázok, ako je extrémizmus, verejná mienka a propaganda. Tento hybridný prístup zabezpečuje široké pokrytie vplyvných zdrojov zo všetkých kútov online priestoru. Patria sem najvplyvnejší mediálni a politickí aktéri (strany aj jednotliví politici), relevantní influenceri a alternatívne mediálne projekty. Zoznam je doplnený o ďalšie zdroje z hľadiska informačnej bezpečnosti vrátane dezinformačných a extrémistických kanálov a skupín. Konkrétne ide o: politikov, politické strany, mainstream médiá, alternatívne médiá, vplyvné médiá, štátne inštitúcie/orgány, predstaviteľov vlády, mimovládne organizácie, komunity.

Z vytvoreného zoznamu zdrojov sa následne vybrali tie, ktoré sa nachádzajú na sociálnej sieti Facebook, a sledovali sa rôzne metriky ich relevantnosti, ako napríklad počet príspevkov za deň. Zdroje sa automaticky pridávajú – to znamená, že ak niekto v príspevku spomenie iný profil alebo stránku, pridá sa do zoznamu. Vytvorený zoznam zdrojov pravidelne kontrolujú a aktualizujú analytici spoločnosti Gerulata. Obdobie aktualizácie zoznamu nie je dlhšie ako 3 mesiace. Pre tento prípad použitia sú zo zoznamu zdrojov identifikované len tie, ktoré produkujú obsah v slovenčine, a to pomocou modelu s otvoreným zdrojovým kódom<sup>1</sup>, natrénovaným na klasifikáciu textu podľa jazyka, v ktorom je napísaný.

Cieľom analytického spracovania zdrojových údajov bolo identifikovanie tematického zamerania príspevku alebo komentára, a určenie sentimentu v danom príspevku alebo komentára, čím sa myslí kategorizovanie textu ako pozitívneho, negatívneho alebo neutrálneho. V prvom kroku bolo dôležité získať odhad alebo predpoveď, ktorá by slúžila ako základný model na porovnanie s komplexnejšími modelmi. Základný model je triviálne riešenie, ktoré na výpočet predpovede používa heuristiku alebo jednoduchú štatistiku. Pri každom modelovaní je dôležité mať základný model, pretože ho možno použiť na porovnanie výkonnosti zložitejších finálnych modelov. Jediný spôsob, ako zistiť, či je daný model dobrý alebo výkonný, je porovnať ho so základným modelom [12].

### 3. VYTVORENIE ZÁKLADNÉHO MODELU

Na vytvorenie základného modelu na určovanie sentimentu alebo témy bol zvolený binárny klasifikátor založený na technike „Support Vector Machines“ (SVM). SVM sú novou technikou vhodnou na úlohy binárnej klasifikácie, ktorá obsahuje prvky neparametrickej aplikovanej štatistiky, neurónových sietí a strojového učenia. SVM model môže byť lineárny alebo nelineárny [14].

SVM klasifikátor slúži na rozdelenie príspevkov hyperrovinou na negatívne (hodnota klasifikátora -1) a pozitívne (hodnota klasifikátora +1). Cieľom SVM je nájsť oddeľujúcu hyperrovinu (rozhodovaciu hranicu), ktorá je maximálne vzdialená od akéhokoľvek bodu v trénovacích údajoch. V tomto prípade sa aplikuje lineárny SVM algoritmus na binárny klasifikačný problém, kde rozhodovacia hranica je lineárna. Klasifikačný problém predstavuje priradenie sentimentu (pozitívneho alebo negatívneho) súboru vstupných vektorov  $\vec{x}$ , získaných z príspevkov a komentárov zo sociálnej siete. Lineárny binárny klasifikátor  $f(\vec{x})$  založený na SVM možno získať pomocou nasledujúcej rovnice:  $f(\vec{x}) = \text{sign}(\vec{w}^T \vec{x} + b)$ , kde  $\vec{w}^T$  je transpozícia váhových vektorov, znamienko („sign“) označuje rozhodnutie na základe skóre  $\vec{w}^T \vec{x} + b$ . Dve možné rozhodnutia sú +1 a -1, ktoré označujú pozitívny a negatívny sentiment. Absolútny člen  $b$  sa používa na určenie hyperrovin, ktoré sú kolmé na normalizovaný vektor [8].

### 4. POUŽITÝ MODEL ZALOŽENÝ NA NEURÓNOVÝCH SIETACH A HLĚBKOVOM UČENÍ

Na klasifikáciu získaných údajov zo sociálnej siete Facebook bol použitý oveľa komplexnejší model XLM-RoBERTa-large, založený na neurónových sieťach, ktoré sú aktuálne nepísaným štandardom v oblasti spracovania prirodzeného jazyka. Tento model je založený na modeli transformátora predstavujúcom neurónovú sieť, ktorá sa

<sup>1</sup> Zdroj: <https://huggingface.co/facebook/fasttext-language-identification>, dátum referencie: 04.09.2023.

učí kontext a tým aj význam slov sledovaním vzťahov v sekvenčných údajoch, ako sú slová vo vete. Modely transformátora používajú vyvíjajúci sa súbor matematických techník, nazývaných pozornosť alebo sebaopozornosť, na detekciu prvkov, dokonca aj vzdialených dátových prvkov, ktoré sa v sérii navzájom ovplyvňujú a navzájom so sebou súvisia [1].

XLM-RoBERTa („A Robustly Optimized BERT Pretraining Approach“) je nový model od Facebook AI a je inšpirovaný modelom BERT („Bidirectional Encoder Representations from Transformers“) z roku 2018 od spoločnosti Google [4]. Hoci je komplexné porovnanie medzi rôznymi metódami zložitá, príprava tohto jazykového modelu výrazne zlepšila výkonnosť.

XLM-RoBERTa sa líši od XLM tým, že trénuje model RoBERTa na obrovskom viacjazyčnom súbore údajov<sup>2</sup>, ale vyhýba sa cieľu prekladového jazykového modelu – XLM-RoBERTa je trénovaný iba s cieľom modelu na maskovanie jazyka [6]. XLM-RoBERTa je preto viacjazyčný maskovaný jazykový model založený na transformátore, ktorý je predtrénovaný na texte veľkosti 2,5 TB v 100 jazykoch, a tým dosahuje uspokojivý výkon v oblasti medzijazykovej klasifikácie, sekvenčného označovania a odpovedí na otázky. Dosahuje tiež nevídaný výkon v medzijazykovom porozumení, čo je úloha, pri ktorej sa model trénuje v jednom jazyku a potom sa používa s inými jazykmi bez ďalších trénovacích údajov. Text použitý na trénovanie pochádza z otvoreného repozitára Common Crawl, ktorý obsahuje texty získané nástrojmi crawlers z verejne dostupných webových stránok. Model XLM-RoBERTa je dostupný v dvoch veľkostiach, ako uvádza tabuľka č. 1. V tabuľke je na porovnanie pridaný model SlovakBERT [22], ktorý je takisto založený na architektúre RoBERTa, ktorý ale bol trénovaný na slovenský jazyk.

**Tabuľka č. 1: Porovnanie relevantných parametrov dvoch modelov XLM-RoBERTa rôznej veľkosti a modelu SlovakBERT**

Relevantné premenné charakterizujúce model	XLM-RoBERTa-base	XLM-RoBERTa-large	SlovakBERT
Počet vrstiev (blokov transformátora)	12	24	12
Počet skrytých vrstiev neurónových sietí	768	1024	768
Počet „heads“ pre mechanizmus sebaopozornosti	12	16	12
Celkový počet parametrov modelu	278 miliónov	560 miliónov	125 miliónov
Počet podporovaných jazykov	100 (vrátane slovenského jazyka)		1
Veľkosť trénovacieho datasetu (v tokenoch)	167x10 <sup>9</sup>		4,6 x10 <sup>9</sup>
Veľkosť slovenského datasetu (v tokenoch)	3,2 x10 <sup>9</sup>		4,6 x10 <sup>9</sup>
Veľkosť slovníka	250 000		50 000

**Zdroj:** <https://huggingface.co/xlm-roberta-base/>, <https://huggingface.co/xlm-roberta-large/>, <https://huggingface.co/gerulata/slovakbert>

Na základe expertného hodnotenia, ktoré zahŕňalo kritériá ako presnosť, adaptabilitu a efektívnosť, bolo rozhodnuté pokračovať s XLM-RoBERTa-large. Podľa spomínaných kritérií sa hľadal model, ktorý bude najviac vyhovovať klasifikácii sentimentu a kategorizácii z pohľadu tém.

<sup>2</sup> Model BERT trénovaný na približne 100 jazykoch.

#### 4.1. Klasifikácia príspevkov z pohľadu témy

Predtrénovaný model s hĺbkovým učením XLM-RoBERTa-large sa použil na klasifikáciu textu do tém na základe neustále aktualizovanej taxonómie IPTC Media Topic Newscodes so zameraním na kategorizáciu textu.

**Tabuľka č. 2: Témy taxonómie IPTC Media Topic Newscodes**

Názov témy (MediaTopic ID)	Definícia
Umenie, kultúra, zábava a médiá (medtop:01000000)	Všetky formy umenia, zábavy, kultúrneho dedičstva a médií
Konflikt, vojna a mier (medtop:16000000)	Akty sociálne alebo politicky motivovaného protestu alebo násilia, vojenské činnosti, geopolitické konflikty, ako aj úsilie o riešenie problémov
Zločin, právo a spravodlivosť (medtop:02000000)	Stanovenie a / alebo vyhlásenie o pravidlách správania v spoločnosti, presadzovanie týchto pravidiel, porušovanie pravidiel, trestanie páchatel'ov a organizácie a orgány zapojené do týchto činností
Katastrofa, nehoda a mimoriadny incident (medtop:03000000)	Človek alebo prírodná udalosť, ktorá má za následok stratu na životoch alebo zranenie živých tvorov a / alebo poškodenie neživých predmetov alebo majetku
Hospodárstvo, podnikanie a financie (medtop:04000000)	Všetky záležitosti týkajúce sa plánovania, výroby a výmeny bohatstva.
Vzdelávanie (medtop:05000000)	Všetky aspekty formálneho alebo neformálneho zvyšovania vedomostí
Životné prostredie (medtop:06000000)	Všetky aspekty ochrany, poškodenia a stavu ekosystému planéty Zem a jej okolia.
Zdravie (medtop:07000000)	Všetky aspekty fyzického a duševného blaha
Ľudský záujem (medtop:08000000)	Položka, zahŕňajúca emocionálne diskusie o jednotlivcoch, skupinách, zvieratách, rastlinách alebo iných objektoch
Práca (medtop:09000000)	Sociálne aspekty, organizácie, pravidlá a podmienky ovplyvňujúce tvorbu bohatstva a poskytovanie služieb a ekonomickú podporu nezamestnaným.
Životný štýl a voľný čas (medtop:10000000)	Činnosti vykonávané na potešenie, relaxáciu alebo rekreáciu mimo plateného zamestnania vrátane stravovania a cestovania.
Politika (medtop:11000000)	Miestne, regionálne, národné a medzinárodné vykonávanie moci alebo boj o moc a vzťahy medzi riadiacimi orgánmi a štátmi.
Náboženstvo (medtop:12000000)	Systémy viery, inštitúcie a ľudia, ktorí poskytujú morálne vedenie nasledovníkom
Veda a technika (medtop:13000000)	Všetky aspekty týkajúce sa ľudského porozumenia, ako aj metodického štúdia a výskumu prírodných, formálnych a spoločenských vied, ako sú astronómia, lingvistika alebo ekonómia
Spoločnosť (medtop:14000000)	Obavy, problémy, záležitosti a inštitúcie súvisiace s ľudskými sociálnymi interakciami, problémami a blahobytom, ako sú chudoba, ľudské práva a plánovanie rodiny
Šport (medtop:15000000)	Športová činnosť alebo zručnosti, ktoré zahŕňajú fyzické a/alebo duševné úsilie a organizácie a orgány zapojené do týchto činností
Počasie (medtop:17000000)	Štúdia, predpoveď a hlásenie meteorologických javov

**Zdroj:** <https://www.iptc.org/std/NewsCodes/treeview/mediatopic/mediatopic-en-GB.html>

Na trénovanie modelu slúžili datasety zostavené použitím kombinácie reálnych a umelo vytvorených dát v slovenskom jazyku. Dáta boli spracované a optimalizované prostredníctvom rôznych prístupov vrátane multilingválnych a spoločne anotovaných údajov, aby sa maximalizovala ich účinnosť a presnosť. Anotovaných bolo 1000 inštancií textov – komentárov, pričom každý text anotovali štyria anotátori.



Na trénovanie a validáciu modelu sa využili len tie dáta, pri ktorých sa zhodli aspoň traja anotátori. Takto sa zabezpečilo vytvorenie tzv. zlatého datasetu.

Trénovanie bolo rozdelené do viacerých iterácií. Každou iteráciou sa zvyšovala správnosť modelu – z pôvodných 79 % na 87 %. Dosiahnutý výsledok pri komplexnejších úlohách a jazykových modeloch sa považuje za pomerne vysoko kompetentný.

Ďalej sú uvedené postupné fázy trénovania s akcentom na experimenty s rôznymi kombináciami reálnych a umelo vytvorených dát. Tento proces umožnil vyvinúť optimalizovaný model, ktorý mohol lepšie riešiť problémy s rozpoznávaním emotikonov a zabraňovať chybným klasifikáciám. Ukázalo sa, že v tomto prípade ladenia dochádza navyše k prenesenému učeniu (transfer learning), teda trénovacie dáta v inom jazyku pozitívne ovplyvňujú výsledky v slovenskom jazyku. Išlo o nasledovné iterácie trénovania, pričom sa použili nasledujúce postupy a dosiahnutá uvedená presnosť modelu:

- reálne dáta v slovenskom jazyku (správnosť 79 %),
- reálne + Umelo vytvorené dáta v slovenskom jazyku (správnosť 83 %),
- reálne + Umelo vytvorené dáta v slovenskom jazyku + Spoločne anotované dáta (správnosť 81 %),
- reálne + umelo vytvorené dáta v slovenskom jazyku + spoločne anotované dáta + multilingválne reálne dáta a umelo vytvorené dáta (správnosť 86 %),
- dáta na obmedzenie nesprávnej klasifikácie na základe emotikonov (k vetám s negatívnym sentimentom boli priradené niektoré emotikony, ktoré v takých prípadoch nenesú sentiment, prípadne sú často využívané pri vyjadrení sarkazmu). Model trénovaný na tomto datasete je v produkcii (správnosť 87 %).

Výstupom bol súbor vo formáte JSON, ktorý každému textu priraduje tému zo spomínanej taxonómie ako aj skóre (pravdepodobnosť), že sa tejto témy skutočne týka. Z pohľadu témy boli klasifikované iba príspevky typu POST (to znamená, že komentáre sa neklasifikovali), ku každému príspevku bola priložená celá odpoveď klasifikátora, aby bolo možné pri výpočte indexu sociálneho napätia pracovať s nastavením požadovanej hranice pravdepodobnosti aj s množinou tém, ktoré reálne majú vstupovať do výpočtu. Pre príspevky typu COMMENT (komentár) bola téma priradená na základe POSTu, na ktorý sa COMMENT vzťahuje. Teda všetky komentáre k príspevku majú spoločnú tému príspevku.

Vyladený model XLM-RoBERTa-large bol schopný efektívne kategorizovať tematické oblasti podľa IPTC štandardu do hĺbky prvej úrovne, ukazujúc jeho robustnosť a spoľahlivosť v analýze a klasifikácii textových dát. Pri vybraných kategóriách IPTC štandardu model podporuje aj hĺbku druhej úrovne. V rámci dostupných tém taxonómie IPTC sme zvolili podmnožinu tém, ktorá dáva význam z pohľadu sledovania nálad v spoločnosti. Konkrétne sme sa zamerali na témy prvej a druhej úrovne. Prvou témou je Umenie, kultúra, zábava a médiá ((medtop:01000000)). Druhou témou je Konflikt, vojna a mier ((medtop:16000000)), ktorá sa delí na podtémy ako Teroristický čin (medtop:20000053), Ozbrojený konflikt (medtop:20000056), Občianska nepokoj (medtop:20000065), Štátny prevrat (medtop:20000070), Kybernetická vojna (medtop:20001361), Masaker (medtop:20000071), Mierový proces (medtop:20000073), Povojnová obnova (medtop:20000077) a Vojnoví zajatci (medtop:20000080). Ďalšou témou je Zločin,

právo a spravodlivosť (medtop:02000000), ktorá zahŕňa Zločin (medtop:20000082), Súdnictvo (medtop:20000106), Právo (medtop:20000121) a Vymožiteľnosť práva (medtop:20000129). Nasleduje téma Katastrofa, nehoda a mimoriadny incident (medtop:03000000). Ďalej boli zvolené témy Hospodárstvo, podnikanie a financie (medtop:04000000), Životné prostredie (medtop:06000000), Zdravie (medtop:07000000), Ľudský záujem (medtop:08000000), Práca (medtop:09000000) a Politika (medtop:11000000), ktorá sa delí na Voľby (medtop:20000574), Základné práva (medtop:20000587), Vláda (medtop:20000593), Vládna politika (medtop:20000621), Medzinárodné vzťahy (medtop:20000638), Mimovládna organizácia (medtop:20000646), Politická kríza (medtop:20000647), Politický disent medtop:20000648 a Politický proces (medtop:20000649). Ďalšie zvolené témy boli Náboženstvo (medtop:12000000), Veda a technika (medtop:13000000), Spoločnosť (medtop:14000000), Šport (medtop:15000000), Počasie (medtop:17000000).

#### 4.2. Ladenie správnosti modelov pomocou anotátorov

Na klasifikáciu textu z pohľadu sentimentu bol použitý rovnaký predtrénovaný model na ladenie. Cieľom klasifikácie bolo určiť, či daný text vyjadruje pozitívny, negatívny alebo neutrálny postoj autora k diskutovanej téme. Hoci sentiment predstavuje v modeli len tri triedy (pozitívny, negatívny alebo neutrálny), bolo potrebné vytvoriť dodatočné datasety na ladenie správnosti modelov pomocou anotátorov, najmä pre prípady, keď bolo ťažké jednoznačne určiť sentiment, napríklad, ak išlo o nepochopenú iróniu.

Anotátori sa pri určovaní pozitívneho, negatívneho a neutrálneho sentimentu riadili obecným postupom, ktorý bol vytvorený ako súčasť výstupov projektu. Všeobecný postup určovania sentimentu obsahoval všeobecné prípady pozitívnych (tabuľka č. 3), negatívnych (tabuľka č. 4) alebo neutrálnych (tabuľka č. 5) príspevkov a konkrétne rozhodnutia týkajúce sa anotácie v špeciálnych prípadoch.

##### Tabuľka č. 3: Prípady pozitívneho sentimentu v príspevkoch

Prípád	Príklad
Príspevok prejavuje pozitívne nálady, postoj alebo emocionálny stav autora príspevku.	„Joj krásavec krásny.“
Príspevok obsahuje nejaké kladné slová.	„Krásne foto.“
Príspevok obsahuje pozitívny ilokučný akt (zložka rečového aktu, ktorou hovoriaci vyjadruje svoj vzťah k oznamovanému obsahu, napr.: wow, blahoželám, top).	„Amen.“

Zdroj: [2, 18, 25], vlastné spracovanie autorov

##### Tabuľka č. 4: Prípady negatívneho sentimentu v príspevkoch

Prípád	Príklad
Príspevok prejavuje negatívne nálady, postoj alebo emocionálny stav autora príspevku.	„Tvoj čas končí hurá.“
Príspevok obsahuje nejaké negatívne slová.	„To hej to by už vyzerala ozaj jak sliepka“.
Príspevok obsahuje urážlivé výrazy, slová, frázy alebo výrazy, ktoré sú neúctivé alebo škodlivé voči jednotlivcom alebo skupinám. Zahŕňa používanie jazyka, ktorého cieľom je zastrašiť, ponížiť alebo znevážiť ostatných, často s cieľom spôsobiť emocionálnu alebo psychickú ujmu. Urážlivý jazyk môže mať rôzne podoby vrátane urážok, hanlivých výrazov, nadávok, vyhrážok alebo vulgarizmov.	„slnieckar jak vysity-este aj ten ksicht...“

Príspevok obsahuje negáciu, slová alebo frázy, ktoré naznačujú negatívny alebo protichodný význam. Zahŕňa odmietnutie alebo negáciu vyhlásenia, myšlienky alebo návrhu.	„Len to nie.“
---	---------------

**Zdroj: [2, 18, 25], vlastné spracovanie autorov**

**Tabuľka č. 5: Prípady neutrálneho sentimentu v príspevkoch**

Prípado	Príklad
Príspevok neprejavuje pozitívne alebo negatívne nálady, postoj alebo emocionálny stav autora príspevku.	„Ja dávam korenie, soľ a polohrubú muku.“
Príspevok predkladá objektívne informácie, obsahuje len výroky a citácie bez prepojenia na nálady, postoj alebo emocionálny stav autora príspevku.	„Bezplatný zber elektroodpadu aj v septembri.“
Príspevok obsahuje reklamný text, vrátane reklamného textu, ktorý obsahuje pozitívny alebo negatívny sentiment (tzv. clickbait).	„Viac než dve tretiny voličov, ktorí sa zúčastnili na utorňajších voľbách do Kongresu USA, nechcú, aby sa súčasný prezident Spojených štátov Joe Biden v roku 2024 opätovne uchádzal o post šéfa Bieleho domu. #zosveta #webta3“.
Príspevok obsahuje pozitívne aj negatívne slová a zároveň nie je možné jednoznačne určiť pozitívnu alebo negatívnu náladu, postoj alebo emocionálny stav autora príspevku.	„Juraj Blanár si myslí = Fico si myslí... Podľa mňa štandardná debata, každý mlel to svoje. Vráťane Kovačiča.... Takže za mňa ok, nič nové..“

**Zdroj: [2, 18, 25], vlastné spracovanie autorov**

Všeobecný postup určovania sentimentu sa uplatňoval aj pri špeciálnych prípadoch na základe dostupnej literatúry [2, 18, 25], ktoré nie sú inherentné v uvedených tabuľkách. Cieľom nebolo ponúknuť anotátorom podrobné a komplikované pokyny – tie môžu byť dokonca kontraproduktívne, pretože anotátori nemusia rozumieť príslušným jemným odchýlkam alebo nemusia mať sklon pochopiť ich. Všeobecný postup určovania sentimentu sa zhrnul do šiestich bodov A až F:

- A. Emocionálny stav autora príspevku: Emocionálny stav autora môže, ale nemusí mať rovnakú polaritu ako jeho vyjadrený názor. Napríklad príspevok politika môže naznačovať negatívny názor na minulú indiskrétnosť súpera a pozitívny emocionálny stav, pretože správy nepriaznivo ovplyvnia súpera. – Odporúčanie pre anotátora: Ak nie je zřejmý emocionálny stav autora príspevku, hodnotíme príspevok ako neutrálny.
- B. Úspech alebo neúspech jednej strany: Vety často opisujú úspech alebo zlyhanie jednej strany vo vzťahu k druhej. Vnímanie týchto udalostí ako pozitívne alebo negatívne závisí od podpory príslušných zainteresovaných strán. Napríklad, keď Fínsko porazilo Rusko v hokeji, táto udalosť bola prevažne koncipovaná ako „Rusko prehralo s Fínskom“ a nie „Fínsko porazilo Rusko“. Toto rozlíšenie nebolo spôsobené negatívnym názorom na ruský tím, ale skôr preto, že Rusko ako hostiteľský štát získalo väčšiu pozornosť a ich hokejové tímy boli tradične silné. – Odporúčanie pre anotátora: Podobné príspevky hodnotíme ako neutrálne.
- C. Sarkazmus: Sarkazmus môže často sprostredkovať pozitívny emocionálny stav rečníka, odvodený od aktu zosmiešňovania niekoho alebo niečoho. Tento pozitívny emocionálny stav však nemusí nutne znamenať pozitívny postoj k zosmiešňovanému subjektu. – Odporúčanie pre anotátora: Ak zo sarkazmu nie je možné odvodiť emocionálny stav autora (POZ alebo NEG), je potrebné hodnotiť sarkazmus ako neutrálny sentiment.

- D. Prosby a žiadosti: Niektoré príspevky vyjadrujú pozitívne prosby k Bohu alebo pozitívne prosby ľuďom v kontexte (zvyčajne) negatívnej situácie. Napríklad: „Nech Boh pomáha tým, ktorí sú vysídlení vojnou.“ – Odporúčanie pre anotátora: Prosby a žiadosti v kontexte negatívnej situácie hodnotíme ako negatívny sentiment.
- E. Rečnicke otázky: Rétorické otázky často nesú silný emocionálny podtón. Môžu sa použiť na zdôraznenie určitého bodu alebo na vyvolanie emocionálnej reakcie čitateľa alebo poslucháča. Rétorické otázky sa bežne používajú aj na vyjadrenie sarkazmu alebo irónie a vyjadrený sentiment môže byť v rozpore s doslovným významom otázky. – Odporúčanie pre anotátora: S rétorickými otázkami možno zaobchádzať jednoducho ako s otázkami (a teda neutrálne) alebo ako s výrokmi, ktoré prezrádzajú emocionálny stav hovoriaceho.
- F. Emodži: Vplyv emotikonov na vnímaný sentiment je ovplyvnený individuálnou interpretáciou, kultúrnymi normami, kontextovými podnetmi a špecifickou kombináciou emotikonov a textu. Emodži sa niekedy tiež používajú na neutralizáciu alebo zmiernenie sentimentu vyjadreného v texte. Napríklad pridanie emodži žmurkajúcej tváre po potenciálne negatívnom vyhlásení môže zmierniť vnímaný sentiment a naznačiť, že to bolo myslené ako vtip alebo odľahčený komentár, a nie ako vyjadrenie skutočnej negativity. – Odporúčanie pre anotátora: vplyv emodži na celkový sentiment je na posúdenie anotátora. Emodži by nemalo mať väčšiu váhu ako samotný text.

#### 4.3. Index sociálneho napätia

Kombinácia reálnych a umelo vytvorených dát v slovenskom jazyku spolu s multilingválnymi a spoločne anotovanými údajmi a zahrnutie analýzy emotikonov viedli k vytvoreniu modelu s vysokou úrovňou správnosti (87 %). Prístup neurónovej siete dosahuje na prvý pohľad horšie výsledky ako základný model SVM (87 % verzus 90 %). Avšak takto jednoducho nemožno dva modely porovnávať, pretože neboli vytvorené a aplikované na rovnakom datasete. Aj model založený na neurónovej sieti XLM-RoBERTa-large je schopný rozlišovať aj tretiu kategóriu neutrálneho príspevku, čo je zložitejšie, ako len binárny klasifikátor.

Kombináciou modelu na klasifikáciu príspevkov z pohľadu témy a modelu na klasifikáciu príspevkov z pohľadu sentimentu bol získaný textový dataset obsahujúci príspevky a komentáre v jednotlivých témach prevedené na číselný časový rad, čo dovoľuje vytvoriť index sociálneho napätia nasledujúcim postupom:

– Krok 1: Skóre pravdepodobnosti (prahovú hodnotu) určujúce či sa príspevok týka témy, bolo stanovené na základe pozorovania menšej vzorky referenčných dát na 0,7. Pri všetkých príspevkoch (POST) bol zaznačený zoznam tém ako výstup z klasifikátora za predpokladu, že príspevok patril do vybranej podmnožiny tém a súčasne daná téma dosiahla skóre vyššie ako 0,7. Komentáre (COMMENT) boli priradené do istej témy ako príspevky, ku ktorým patrili. Ostatné príspevky, ktoré boli neisté, sa v ďalších analýzach nepoužili. Jeden príspevok však mohol patriť naraz aj do viacerých tém, pokiaľ splnil podmienky výberu (išlo o „multi-label classification“).

– Krok 2: Pre každú zo zvolených kategórií sa spočítal denný priemer sentimentu. Každému príspevku alebo komentáru sa priradila číselná hodnota na základe sentimentu, ktorý priradil klasifikátor, pričom pozitívny sentiment mal hodnotu 1, negatívny -1 a neutrálny 0. Tieto hodnoty sentimentu sa v každej vybranej kategórii

spočítali za daný deň a vydělili denným počtom príspevkov v danej kategórii. Rovnaký výpočet za každý deň sa potom vykonal celkovo pre všetky príspevky, ktoré boli aspoň v jednej zo zvolených kategórií. Pokiaľ sa príspevok nachádzal vo viacerých zvolených kategóriách, do výpočtu vstupoval iba raz.

Postupom opísaným v uvedených krokoch sa získal celkový číselný denný priemer sentimentu ako aj číselný denný priemer sentimentu vybraných kategórií. Tieto číselné denné priemery sentimentu označujeme ako index sociálneho napätia, ktorý môže dosahovať hodnoty od 1 (dokonalo pozitívne naladená spoločnosť) do -1 (úplne negatívne naladená spoločnosť). Teda ide o číselný časový rad tohto indexu za sledované obdobie od 1. 9. 2022 do 31. 8. 2023, kde premenná času je v rozčlenení na dni s konkrétnym označením dátumu. Pre detekciu náhlych zmien indexu sentimentu, ktoré môžu indikovať významné spoločenské udalosti, bola určená prahová hodnota ako zmena sentimentu v danom dni, ktorá je väčšia ako 25 % 14-dňového plávajúceho priemeru. 14-dňové obdobie priemerovania sa zvolilo ako kompromis. Kratšie obdobie citlivejšie reagovalo na zmeny, no častejšie označovalo „návrat“ do normálu aj ako významnú zmenu. Dlhšie obdobie lepšie eliminovalo „návraty“, ale bolo menej citlivé na drobnejšie výkyvy.

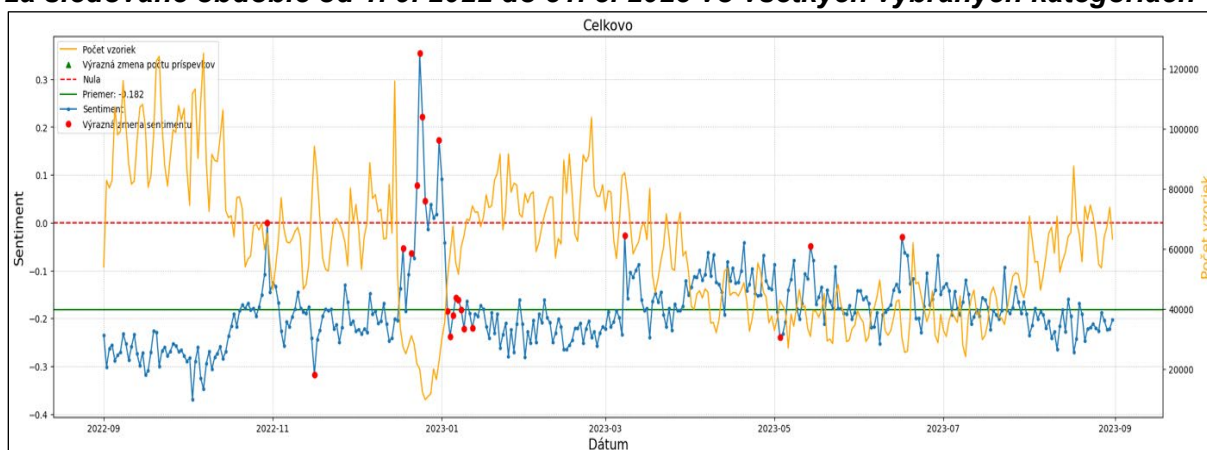
## 5. ANALÝZA VÝSLEDKOV

Obrázok č. 1 znázorňuje priebeh indexu sentimentu a počtu vzoriek (príspevkov a komentárov) za sledované obdobie od 1. 9. 2022 do 31. 8. 2023 vo všetkých vybraných kategóriách. Priemerný počet príspevkov a komentárov, ktoré boli zohľadnené v tejto analýze, je **59 831** za deň. Celkový analyzovaný počet príspevkov a komentárov predstavuje skoro 32 miliónov príspevkov. Na tomto obrázku ako aj na ďalších obrázkoch vidno aj zelenú vodorovnú čiaru znázorňujúcu priemernú hodnotu indexu sociálneho napätia, ako aj červenú prerušovanú vodorovnú čiaru, ktorá znázorňuje neutrálny sentiment. Zelený trojuholník znázorňuje výraznú zmenu počtu príspevkov, červený kruh zas výraznú zmenu v indexe sociálneho napätia. Len obrázok č. 1 zachytáva isté obdobie okolo vianočných sviatkov, keď je index nad nulou, teda pozitívny. Môže k tomu prispievať pozitívna sviatočná nálada, avšak tento vzostup preukazuje aj najviac zastúpená kategória politika (obrázok č. 2). Dňa 23. 12. 2022 skončil minister financií Igor Matovič vo svojej funkcii ministra. Vo všetkých obrázkoch však vidíme výrazný pokles počtu príspevkov vo vianočnom období pred ich výrazným vzostupom 24. 12. 2022.

Obrázok č. 3 ukazuje situáciu zo začiatku októbra 2022, keď sa stala udalosť usmrtenia ľudí na zastávke Zochova vodičom pod vplyvom alkoholu a neskôr nato teroristický čin pred podnikom Tepláreň. Model zachytil výrazné zmeny v počte príspevkov aj poklese indexu sociálneho napätia hlboko pod priemerom.

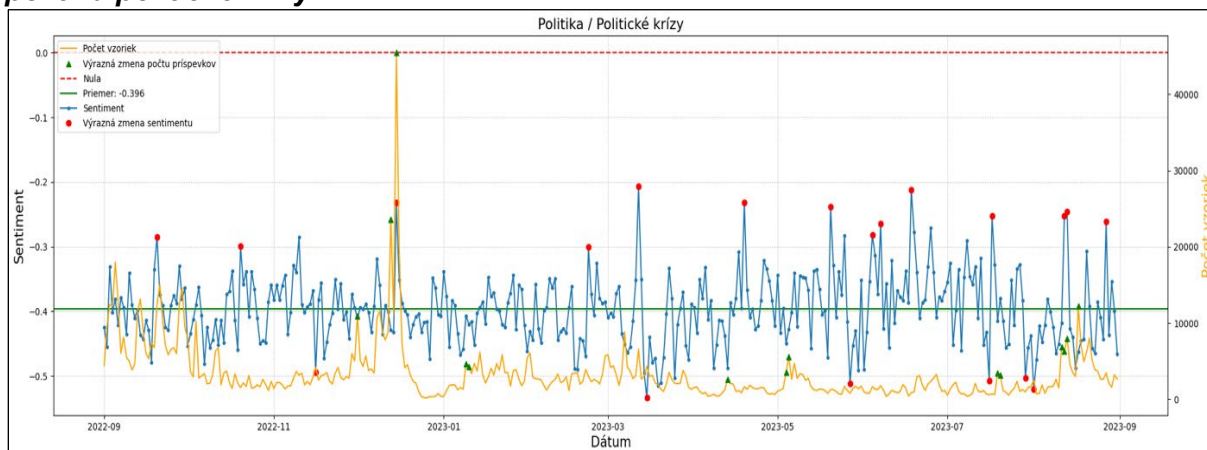
Obrázok č. 4 indikuje výročie vojny na Ukrajine, keď 24. 2. 2023 sledujeme výrazný nárast počtu príspevkov na vyše 13 400, pritom bežne ich je okolo 3- až 5-tisíc. Index sa však už po roku konfliktu drží blízko svojej priemernej hodnoty bez zásadnej zmeny.

**Obrázok č. 1: Priebeh indexu sentimentu a počtu vzoriek (príspevkov a komentárov) za sledované obdobie od 1. 9. 2022 do 31. 8. 2023 vo všetkých vybraných kategóriách**



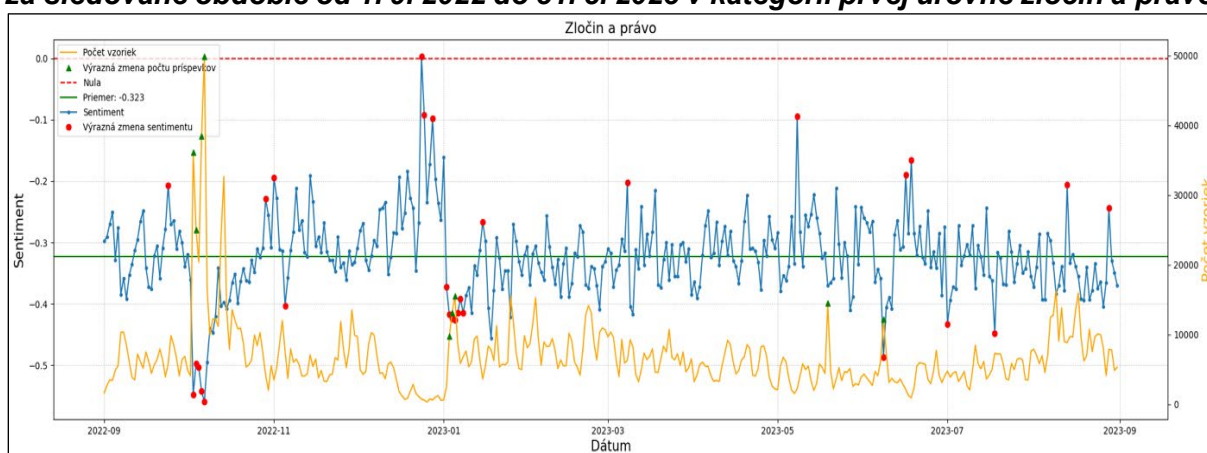
**Zdroj: vlastné spracovanie autorov**

**Obrázok č. 2: Priebeh indexu sentimentu a počtu vzoriek (príspevkov a komentárov) za sledované obdobie od 1. 9. 2022 do 31. 8. 2023 v kategórii druhej úrovne politika/politické krízy**



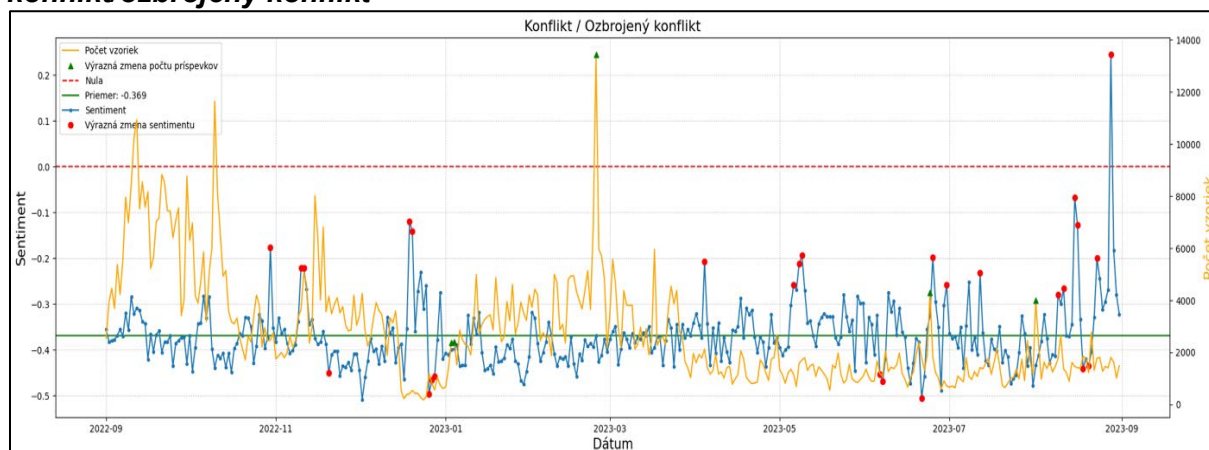
**Zdroj: vlastné spracovanie autorov**

**Obrázok č. 3: Priebeh indexu sentimentu a počtu vzoriek (príspevkov a komentárov) za sledované obdobie od 1. 9. 2022 do 31. 8. 2023 v kategórii prvej úrovne zločin a právo**



**Zdroj: vlastné spracovanie autorov**

**Obrázok č. 4: Priebeh indexu sentimentu a počtu vzoriek (príspevkov a komentárov) za sledované obdobie od 1. 9. 2022 do 31. 8. 2023 v kategórii druhej úrovne konflikt/ozbrojený konflikt**



**zdroj: vlastné spracovanie autorov**

Napriek tomu, že využitý model na klasifikáciu nevieme úplne priamo porovnať s alternatívnymi modelmi v literatúre, je nepísaným konsenzom, že správnosť nad 85 % (v našom prípade 87 %) je veľmi dobrým výsledkom. Jazykové modely založené na transformátoroch s miliónmi parametrov, akým je použitý model XLM-RoBERTa, sú aktuálne štandardom v súkromnej sfére pre spracovanie prirodzeného jazyka vďaka svojej multijazyčnosti a relatívnej jednoduchosti pre ich dotrénovanie na špecializované úlohy.

Výsledky spracované v tejto kapitole potvrdzujú použiteľnosť verejne dostupných príspevkov na sociálnych sieťach na monitorovanie nálad a názorov na zásadné udalosti v spoločnosti. Aktuálna definícia indexu sociálneho napätia a sledovanie jeho zmeny umožnili identifikovať zásadné udalosti, ktoré vychýlili náladu v spoločnosti z priemeru. Pre hlbšie porozumenie a predpovedanie zintenzívňovania sociálneho napätia a jeho prejavov vo fyzickom svete sú tieto výsledky len prvým, nevyhnutným krokom.

## 6. ZÁVER

Sociálne siete všeobecne poskytujú údaje o pomerne veľkej vzorke obyvateľstva rôznorodej demografie v pomerne širokom geografickom pokrytí takmer v reálnom čase. Analýza sociálneho sentimentu z príspevkov zo sociálnych sietí preto môže pomôcť zachytiť dynamické zmeny, pochopiť rôzne demografické perspektívy a identifikovať regionálne trendy, ktoré môžu byť užitočné napríklad ako dodatočný zdroj informácií pre oficiálnu štatistiku o kvalite života.

Výberom modelu XLM-ROBERTA-large sme získali výhody výkonnejšieho a flexibilnejšieho modelovania, ktoré nám umožnilo úspešne adaptovať model na špecifické úlohy a jazykové nuansy. Multilingválny model, umožnil integráciu a analýzu dát z rôznych jazykových prostredí, čo bolo kľúčové pri začleňovaní multilingválnych datasetov do experimentov. Keďže textov a datasetov v rôznych jazykoch je dostupných viac, je možné týmto multilingválnym prístupom zvyšovať objektivitu modelu. Metódy tréningu zahŕňali použitie reálnych, umelých a multilingválnych datasetov, ktoré umožnili preskúmať a identifikovať optimálne

kombinácie pre tréningový proces. To zase viedlo k vytvoreniu modelu s vysokou úrovňou presnosti a robustnosti.

Aj vzhľadom na výsledky je správnosť výstupov dostatočná – na úrovni 87 percent. Je však ešte možné ju ďalej ladiť a vylepšovať cez lepšie nastavenie prahových hodnôt na priradenie daného textu do vybranej triedy, a to postupom cez ROC krivku a metriku AUC. Priestor na zlepšenia tiež ostáva v otázke, ako interpretovať populáciu, ktorej sa daný štatistický produkt týka, a ako ho využívať v praxi.

Projekt overil, že modely založené na modeli RoBERTa vynikajú v úlohách vyžadujúcich hlboké porozumenie kontextu, ako je analýza sentimentu, odpovedanie na otázky a rozpoznávanie pomenovaných entít. Ide o predtrénovaný model s otvoreným zdrojovým kódom, ktorý by sa dal nasadiť a ladiť aj v prostredí Štatistického úradu SR alebo štátnej správy. Model XLM-ROBERTA-large preukázal schopnosť zachytiť jemné jazykové nuansy, najmä pri analýze sentimentu, kde je identifikácia sarkazmu a komplexných emócií kritická.

Na druhej strane monitorovanie sentimentu verejnosti na sociálnych médiách pomocou algoritmov strojového učenia predstavuje niekoľko rizík. Trottier [24] argumentuje, že vznikajú obavy o súkromie, pretože jednotlivci môžu mať pocit, že ich sloboda prejavu a právo na súkromie sa porušujú, keď vládne inštitúcie a úrady monitorujú ich aktivity na sociálnych sieťach. To môže viesť k autocenzúre a negatívnemu vplyvu na slobodu prejavu. Nesprávna interpretácia sentimentu je ďalším rizikom, pretože algoritmy môžu mať problémy s určením sentimentu niektorých typov príspevkov, ako napríklad sarkazmus, rečnicke otázky a emodži [12], čo môže viesť ku skreslenej interpretácii a nesprávnym rozhodnutiam. Zaujaté rozhodovanie v oblasti algoritmov sa navyše môže neprimerane zameriavať na určité skupiny alebo komunity [29], čím sa udržiava diskriminácia a prehlbujú sa sociálne nerovnosti. Nedostatočná transparentnosť tieto riziká ešte viac znásobuje, keďže vlády nemusia zverejniť rozsah a účel monitorovacích aktivít, čo sťažuje posúdenie spravodlivosti a etiky.

## LITERATÚRA

- [1] ANTELMÍ, A. Towards an exhaustive framework for online social networks user behaviour modelling. In: Proceedings of the 27th ACM Conference on User Modeling, Adaptation and Personalization. 2019, s. 349 – 352.
- [2] BAI, Q. – DAN, Q. – MU, Z. – YANG, M.: A Systematic Review of Emoji: Current Research and Future Perspectives. In: Frontiers in Psychology. 2019, č. 10.
- [3] BAO, H. – DONG, L. – WANG, W. et al.: Fine-tuning pretrained transformer encoders for sequence-to-sequence learning. In: International Journal of Machine Learning and Cybernetics. 2023, č. 11.
- [4] CONNEAU, A. – KHANDELWAL, K. – GOYAL, N. – CHAUDHARY, V. – WENZEK, G., GUZMÁN, F. et al.: Unsupervised cross-lingual representation learning at scale. In: Annual Meeting of the Association for Computational Linguistics, 2019.
- [5] DAHRENDORF, R.: Toward a theory of social conflict. In: Journal of Conflict Resolution. 1958, č. 2. s. 170 – 183.
- [6] EO, S. – PARK, C. – MOON, H. – SEO, J. – LIM, H.: Comparative Analysis of Current Approaches to Quality Estimation for Neural Machine Translation. In: Applied Sciences. 2021, č. 14.



- [7] FEIZOLLAH, A. et al.: Halal products on Twitter: Data extraction and sentiment analysis using stack of deep learning algorithms. In: IEEE Access. 2019, č. 7. s. 83354 – 83362.
- [8] GAZZAH, S. – ESSOUKRI BEN AMARA, N. Neural Networks and Support Vector Machines Classifiers for Writer Identification Using Arabic Script. In: International Arab Journal of Information Technology. 2008, č. 1, s. 92 – 101.
- [9] Go4insight: Koľko Slovákov je na sociálnych sieťach v roku 2022? [online]. [cit. 7-11-2023]. Dostupné na: <https://www.go4insight.com/post/ko%C4%Beko-slov%C3%A1kov-je-na-soci%C3%A1lnych-sie%C5%A5ach-v-roku-2022>
- [10] HARTL, P.: Psychologický slovník. Jiří Budka, Praha 1993, ISBN 80-90 15 49-0-5.
- [11] CHAMLERTWAT, W. et al.: Discovering Consumer Insight from Twitter via Sentiment Analysis. In: Journal of Universal Computer Science. 2012, č. 18. s. 973 – 992.
- [12] SINGH, K. – DEEPAK T. – ARUN S. Sentiment analysis: a review and comparative analysis over social media. In: Journal of Ambient Intelligence and Humanized Computing. 2020, č. 11. s. 97 – 117.
- [13] KORA, R. – MOHAMMED, A.: An enhanced approach for sentiment analysis based on meta-ensemble deep learning. In: Social Network Analysis and Mining. 2023, č. 38.
- [14] LAURA, A. – MORO, R. A., Support Vector Machines (SVM) as a Technique for Solvency Analysis. In: DIW Berlin Discussion Paper. 2008, č. 811, s. 2.
- [15] LEE, J. et al.: Sentiment analysis of Twitter users over time: the case of the Boston bombing tragedy. In: E-Life: Web-Enabled Convergence of Commerce, Work, and Social Life: 15th Workshop on e-Business, WEB 2015, Fort Worth, Texas, USA, December 12, 2015, Revised Selected Papers. 2015.
- [16] LIU, B.: Sentiment analysis: Mining Opinions, Sentiments, and Emotions. Cambridge University Press, 2015.
- [17] MAHMUD, J. et al.: Predicting attitude and actions of Twitter users. In: Proceedings of the 21st International Conference on Intelligent User Interfaces. 2016, s. 2 – 6.
- [18] MOHAMMAD, S.: A Practical Guide to Sentiment Analysis. In: Socio-Affective Computing. 2017, č. 5.
- [19] NAKONEČNÝ, M.: Emoce. Praha: Triton, 2012. ISBN: 978-80-7387-614-2.
- [20] NASEER, K. et al. Travel behaviour prediction amid covid-19 underlying situational awareness theory and health belief model. In: Behaviour & Information Technology. 2022, č. 15. s. 3318 – 3328.
- [21] NEPPALLI, K. et al.: Sentiment analysis during Hurricane Sandy in emergency response. In: International journal of disaster risk reduction. 2017, č. 21. s. 213 – 222.
- [22] PIKULIAK, M. – GRIVALSKÝ, Š. – KONÔPKA, M. – BLŠTÁK, M. – TAMAJKA, M. – BACHRATÝ, V. – UHLÁRIK, F. et al.: SlovakBERT: Slovak Masked Language Model. In: Findings of the Association for Computational Linguistics: EMNLP 2022. 2022. s. 7156 – 7168.
- [23] PLUTCHIK, R. - KELLERMAN, H. (ed.): Theories of emotion. Academic press, 2013.
- [24] TROTTIER, D.: Social media as surveillance: Rethinking visibility in a converging world. Routledge, 2016.
- [25] QURESHI, M. – ASIF, M. – HASSAN, M. et al.: A Novel Auto-Annotation Technique for Aspect Level Sentiment Analysis. In: Computers, Materials & Continua. 2022, č. 3. s. 4987-5004.

- [26] RADICIONI, T. – SARACCO, F. – PAVAN, E. et al.: Analysing Twitter semantic networks: the case of 2018 Italian elections. In: Scientific Reports. 2021, č. 11.
- [27] SMELSER, N.J.: The Theory of Collective Behavior. New York: Free Press, 1962. ISBN 9781136277900.
- [28] YAVARI, A. et al. Election prediction based on sentiment analysis using twitter data. In: International Journal of Engineering. 2022, č. 2. s. 372 – 379.
- [29] ZEITZOFF, T.: How social media is changing conflict. In: Journal of Conflict Resolution. 2017, č. 9. s. 1970 – 1991.

## RESUMÉ

V dnešnej dobe sú sociálne siete čoraz populárnejšie pri vyjadrovaní názorov a emócií ľudí, ktorí často verejne zdieľajú svoje pocity a názory na rôzne udalosti a tematicky súvisiace správy. Táto popularita sociálnych médií ako miesta, kde sa ľudia vyjadrujú, vytvára veľké množstvo dát týkajúcich sa nálady ľudí a sociálneho napätia. Cieľom tohto experimentu bola práca s verejnými príspevkami v slovenčine na sociálnej sieti Facebook a analýza sentimentu týchto príspevkov k rôznym témam. Sledovanie sentimentu môže poskytnúť základné pochopenie emocionálneho stavu ľudí, čo sa môže ďalej použiť v rôznych oblastiach, vrátane štatistiky o kvalite života. Použitá metóda analýzy príspevkov s cieľom identifikovať ich kategóriu a získať kvantitatívnu hodnotu sentimentu obsiahnutého v textoch využíva multilingválny model XLM-ROBERTA-large pre spracovanie prirodzeného jazyka. Vytvorený model dovoľuje korelovať identifikované sociálne napätie s udalosťami zo skutočného sveta. Napríklad po teroristickom útoku na Zámockej ulici v Bratislave sa v komentároch objavuje zvýšený negatívny sentiment, ktorý signalizuje zvýšenie napätia. Analýza sentimentu príspevkov na sociálnych sieťach poskytuje dodatočné a rýchle zdroje informácií o sociálnom napätí verejnosti, čo môže mať význam napríklad pre tvorcov politik a sociológov. Potenciál pre budúci výskum zahŕňa možnosť rozšírenia tejto analýzy sentimentu na iné platformy a na iné jazyky.

## RESUME

Nowadays, social networks are increasingly popular for expressing the opinions and emotions of people, who often publicly share their feelings and opinions about various events and thematically related news. This popularity of social media as a place for people to express themselves creates a large amount of data regarding people's moods and social tensions. The aim of this experiment was to deal with the public posts in Slovak on the social networking website Facebook and to analyze the sentiment of these posts on various topics. Sentiment monitoring can provide a basic understanding of people's emotional state, which can be further used in various fields, including quality of life statistics. The method applied for analyzing the posts in order to identify their category and obtain a quantitative value of the sentiment in the texts uses the XLM-ROBERTA-large multilingual model for natural language processing. The created model allows to correlate the identified social tension with real-life events. For example, after the terrorist attack on Zámocká street in Bratislava, an increased negative sentiment appears in the comments, indicating a higher social tension. The sentiment analysis of social media posts provides additional and rapid sources of information about public social tensions, which may be relevant to policymakers and sociologists, for example. Potential for a future research includes broadening this sentiment analysis to other platforms and languages.

## **PROFESIJNÝ ŽIVOTOPIS**

**Dipl. Ing. Dagmar Celuchová Bošanská** je zakladateľkou spoločnosti Alistiq s. r. o. a expertkou na inovácie a digitálnu transformáciu s dlhoročnými skúsenosťami. V roku 2008 absolvovala inžinierske štúdium pre informačné technológie, mobilné komunikácie a štatistické spracovanie signálov na Viedenskej technickej univerzite, kde pôsobila aj vo vedeckom tíme na vývoji simulátorov technológií pre bezdrôtové siete štvrtej generácie. Od roku 2015 sa venuje vývoju riešenia a návrhu opatrení na zvyšovanie kvality a efektivity využívania údajov vrátane Big Data na sekundárne účely, predovšetkým vo verejnej správe. Aktuálne od roku 2020 pôsobí ako doktorand na Českom vysokom učení technickom v Prahe, kde sa venuje výskumu grafových údajov generovaných z elektronických zdravotných záznamov a ich analýze s využitím strojového učenia a veľkých jazykových modelov.

**Ing. Martin Janík** absolvoval inžinierske štúdium na Fakulte elektrotechniky a informatiky Slovenskej technickej univerzity v Bratislave v odbore telekomunikácie, špecializácia bezpečnosť (2008). Už počas štúdia na vysokej škole začal pracovať v súkromnom sektore v oblasti IT, spočiatku v oblasti webových, neskôr mobilných technológií ako programátor, analytik a následne softvérový architekt softvérových produktov v oblasti mobilných technológií. Od roku 2022 sa venuje dátovej vede so zameraním na analýzu a návrh grafových dátových štruktúr vo verejnom sektore. Spolupracuje na centrálnom modeli údajov SR a na analýze a spracovaní Big Data.

**Mgr. Filip Nguyen** absolvoval magisterské štúdium v Ústave pedagogiky a sociálnych štúdií Univerzity Palackého v Olomouci v odbore pedagogika – verejná správa (2019). Od roku 2018 pôsobí v poradenskej spoločnosti Alistiq, s. r. o. ako poradca v oblasti verejného obstarávania a verejných inovačných projektov. Jeho práca sa zameriava na návrh digitálnych služieb štátnej správy a aplikáciu osvedčených postupov PRINCE2 a Agile metodík v projektoch.

## **KONTAKT**

[dagmar.bosanska@alistic.com](mailto:dagmar.bosanska@alistic.com)

[martin.janik@alistic.com](mailto:martin.janik@alistic.com)

[filip.nguyen@alistic.com](mailto:filip.nguyen@alistic.com)