

**Univerzita Hradec Králové**  
**Fakulta informatiky a managementu**  
**Katedra managementu**

**Firemní online komunikace na sociálních sítích**  
**(se zaměřením na analýzu sentimentu)**

Diplomová práce

Autor: Bc. et Bc. Jakub Marek  
Studijní obor: Informační management  
Vedoucí práce: doc. Ing. Pavel Bachmann, Ph.D.

Prohlášení:

Prohlašuji, že jsem diplomovou práci zpracoval samostatně a s použitím uvedené literatury.

V Hradci Králové dne 21. 4. 2020

Jakub Marek

Poděkování:

Tímto bych chtěl poděkovat vedoucímu diplomové práce doc. Ing. Pavlu Bachmannovi, Ph.D. za odbornou pomoc a cenné rady a připomínky, kterých si velmi vážím. Dále bych rád poděkoval paní Ing. Martině Husákové, Ph.D. za poskytnutí odborné literatury z oblasti analýzy sentimentu a cenné rady při práci se softwarem Orange.

## Anotace

Diplomová práce je zaměřena na online komunikaci a sociální CRM bankovních institucí na sociální síti Facebook s kladeným důrazem na analýzu sentimentu. Cílem je charakterizovat komunikaci vybraného sektoru firem a následné reakce uživatelů a také s pomocí analýzy identifikovat vzory v komunikaci mezi firmami a obecně. Na vzorku 20 vybraných bank ze žebříčku S&P Global je analyzována hladina sentimentu v publikovaných příspěvcích na Facebooku za kalendářní rok 2019, výzkumu jsou rovněž podrobeny obsahy komentářů uživatelů a publikované reakce administrátorů stránek. Z výsledků je patrné, že bankovní instituce nejvíce publikují posty s pozitivním sentimentem, přičemž reakce publika je převážně neutrální a polarita sentimentu v komentářích se neliší mezi příspěvky s různým obsahem. Mezi sentimentem příspěvku a sentimentem komentáře se podařilo identifikovat slabý vztah. Administrátoři stránek reagují s neutrálním sentimentem téměř na polovinu komentářů, prokazatelně více reagují na negativní komentáře publika.

## Annotation

**Title: Online business communication on social networks (focused on sentiment analysis)**

This diploma thesis is focused on online communication and social CRM of banking institutions on the social network Facebook with emphasis on sentiment analysis. The aim is to characterize the communication of the selected sector of companies and subsequent reactions of users and also with the help of analysis to identify patterns in communication between companies and the audience. The sample of 20 selected banks from the S&P Global ranking analyzes the level of sentiment in published Facebook posts for the calendar year 2019, the research also includes the contents of user comments and published responses of site administrators. The results show that banking institutions publish most posts with positive sentiment, while the reaction of the audience is mostly neutral and the polarity of sentiment in comments does not differ between posts with different content. A weak relationship was identified between the sentiment of the post and the sentiment of the commentary. Site administrators respond with neutral sentiment to almost half of the comments, proving more responsive to negative audience comments.

## Obsah

Úvod.....	1
<b>Teoretická východiska .....</b>	<b>3</b>
1 Marketing .....	4
1.1 Marketingová komunikace .....	5
1.2 Trendy v marketingové komunikaci .....	6
2 Komunikace bankovních institucí.....	9
2.1 Segmentace trhu.....	9
2.2 Specifika komunikace.....	11
2.3 Současné trendy .....	12
3 CRM.....	14
3.1 Architektura .....	15
3.2 Trendy v CRM .....	16
4 Sociální CRM.....	18
4.1 Sociální sítě a SCRM.....	19
4.2 Lidé a SCRM .....	20
4.3 Měření ukazatelů v oblasti SCRM.....	21
4.4 Porovnání CRM a SCRM .....	22
5 Úvod do text miningu.....	23
5.1 Vztah mezi data miningem, text miningem a analýzou sentimentu .....	23
5.2 Historie a současné členění text miningu .....	23
5.3 Proces text miningu .....	24
5.3.1 Předzpracování dat .....	25
5.3.2 Transformace .....	26
5.3.3 Analýza textu.....	27
5.3.4 Interpretace a vyhodnocení výsledků .....	28
6 Úvod do analýzy sentimentu .....	29
6.1 Vymezení pojmu sentiment a analýza sentimentu.....	29
6.2 Úrovně analýzy sentimentu .....	30
6.3 Formální zápis.....	30
6.4 Proces analýzy sentimentu.....	32
6.5 Přesnost klasifikace.....	34

6.6	Problematika analýzy sentimentu .....	35
6.7	Analýza sentimentu a jiné jazyky .....	36
6.8	Případové studie.....	37
6.8.1	Sentiment analýza médií.....	37
6.8.2	Predikce vývoje na burze na základě analyzovaných tweetů .....	38
	<b>Praktická část</b> .....	40
7	Metodika zpracování .....	41
7.1	Výzkumný vzorek.....	41
7.2	Výzkumné otázky .....	43
7.3	Výzkumné metody .....	43
7.4	Sběr a zpracování dat .....	43
7.4.1	Data pro analýzu sentimentu příspěvků.....	45
7.4.2	Data pro analýzu sentimentu komentářů a reakcí banky .....	47
7.4.3	Data pro analýzu typu příspěvku a typu publikovaného obsahu .....	48
7.4.4	Ostatní data .....	48
8	Výsledky.....	49
8.1	Komunikace bankovních institucí na sociální síti Facebook .....	49
8.2	VO1: Jaký je charakter příspěvků bankovních institucí? .....	55
8.2.1	Jaké typy příspěvků banky prezentují?.....	55
8.2.2	Co je obsahem příspěvků?.....	55
8.2.3	Jaká je hladina sentimentu v příspěvcích?.....	56
8.2.4	Existuje korelace mezi sentimentem příspěvku a interakcemi uživatelů? ....	59
8.3	VO2: Jaký je charakter komentářů uživatelů na příspěvky? .....	60
8.3.1	Jaká je hladina sentimentu v komentářích uživatelů? .....	60
8.3.2	Liší se sentiment komentářů mezi příspěvky s různým obsahem?.....	61
8.3.3	Existuje korelace mezi sentimentem příspěvku a sentimentem komentářů? .....	62
8.3.4	Existuje korelace mezi NPS banky a hladinou sentimentu v komentářích uživatelů? .....	63
8.4	VO3: Jaký je charakter odpovědí bank na komentáře uživatelů?.....	65
8.4.1	Jak často a jak rychle banky reagují na komentář uživatele? .....	65
8.4.2	Jaký sentiment používají banky v komunikaci s uživatelem?.....	67
8.4.3	Existuje závislost mezi sentimentem komentáře a rozhodnutím banky odpovědět na komentář?.....	68
8.4.4	Existuje korelace mezi sentimentem komentáře uživatele a sentimentem odpovědí banky? .....	70

9	Diskuze.....	71
9.1	Hlavní zjištění .....	71
9.1.1	Charakter příspěvků bankovních institucí .....	71
9.1.2	Charakter uživatelských komentářů .....	72
9.1.3	Charakter reakcí bankovních institucí na uživatelské komentáře .....	73
9.2	Doporučení na základě hlavních zjištění .....	74
9.3	Limity práce .....	75
9.4	Další možnosti zkoumání.....	76
10	Závěr.....	77
11	Seznam použitých zdrojů .....	78
12	Seznam tabulek, grafů a obrázků .....	88
13	Seznam zkratk .....	90
14	Přílohy .....	91



## Úvod

V rozmezí 12 posledních měsíců si zřídilo profil na některé sociální síti nových 321 miliónů uživatelů, což znamená meziroční růst téměř o 10 %. Celkem jich je k lednu roku 2020 evidováno již 4,8 miliardy, jedná se prakticky o polovinu světové populace (Kemp, 2020). Tam, kde jsou potenciální zákazníci, nesmějí chybět firmy nabízející své produkty a služby. Enormní růst digitálních uživatelů se tak odráží v sumě vynaložených investic podniků do komunikace v online prostředí. V roce 2018 firmy investovaly do digitální reklamy přes 280 miliard amerických dolarů, v roce 2023 se předpokládají investice téměř dvojnásobné, podíl vynaložených finančních prostředků do online reklamy bude tvořit převážnou většinu všech investic do marketingové komunikace (Enberg, 2019). Aby byly tyto nemalé finanční vklady efektivně využity, musejí firmy znát dobře prostředí sociálních sítí a chování jejich uživatelů, znát jejich potřeby, mínění k dané službě či produktu nebo osobní preference. K těmto účelům slouží informace v nástrojích řízení vztahů se zákazníky – CRM (*Customer Relationship Management*) nebo SCRM (*Social Customer Relationship Management*), nicméně potenciálním zdrojem informací těmto technologickým prostředníkům jsou čím dál více nestrukturovaná data mající pro podnik cenu zlata a jejich využití znamená konkurenční výhodu na trhu. Odhaduje se, že až 80 % všech dat mají nestrukturovanou formu v podobě textových dokumentů (např. komentářů, recenzí nebo emailové korespondence), obrázků, grafů, audiozáznamů nebo videí (Taylor, 2018). K tomu, aby tato data mohla být využita, a tedy převedena do strukturované formy, slouží např. klasifikační nástroje data miningu. V současné době probíhá na poli výzkumu několik významných studií využívající neuronové sítě v oblasti strojového zpracování přirozeného jazyka, příkladem může být práce Tomáše Mikolova, který díky modelům word2vec nebo FastText způsobil revoluci v oblasti vektorové reprezentace textu (Javůrek, 2019). V českém prostředí vznikla rovněž úspěšná firma Semantic Visions, která s pomocí sémantické analýzy zpracovává denně terabajty dat, věnuje se také výzkumu analýzy sentimentu nebo se svými nástroji pomáhá detekovat čím dál častěji generované fake news (Budai, 2020). A právě analýza sentimentu, mající potenciál ve využití SCRM, je předmětem této diplomové práce.

Cílem práce je za pomoci analýzy sentimentu na publikovaném obsahu charakterizovat komunikaci vybraných firem a následné reakce uživatelů na sociální síti Facebook. Cílem je rovněž odhalit, zda existuje souvislost mezi zvoleným sentimentem v příspěvku a polaritou sentimentu v reakcích publika.

Teoretická část tak shrnuje tři základní okruhy témat, která spolu úzce souvisejí a podávají čtenáři potřebný přehled pro praktickou část – jedná se online marketingovou komunikaci a současné trendy, principy CRM včetně sociálního CRM a závěrečnou technicky zaměřenou sekci věnující se data miningu, klasifikačním algoritmům a analýze sentimentu.

V praktické části je na vzorku 20 vybraných bank ze žebříčku S&P Global, který prezentuje 100 největších bankovních institucí světa dle aktiv, analyzována hladina sentimentu v publikovaných příspěvcích na Facebooku za kalendářní rok 2019. Z hlediska polarity sentimentu jsou zkoumány také obsahy komentářů uživatelů a zveřejněné reakce administrátorů stránek. Data jsou z Facebooku získána za pomoci skriptu v jazyce Python, sentiment je hodnocen slovníkovou metodou Liu Hu v softwaru Orange, pro vyhodnocení korelace a jiných výzkumných otázek byl použit statistický nástroj SPSS Statistics.

Výsledkem diplomové práce by měla být identifikace vzorů chování bankovních institucí a jejich zákazníků na Facebooku, které mohou mít reálné uplatnění v řízení vztahu se zákazníkem prostřednictvím sociálních sítí.

# TEORETICKÁ VÝCHODISKA

## 1 Marketing

Americký profesor Philip Kotler ve své knize *Moderní marketing* podává čtenáři dvě definice, které vystihují pojem marketing. První z obecných definic zní: „*Společenský a manažerský proces, jehož prostřednictvím uspokojují jednotlivci a skupiny své potřeby a přání v procesu výroby a směny produktů a hodnot.*“ (Kotler, 2007, s. 39). Ve druhé definici pak vystihuje silné postavení stálého spokojeného zákazníka: „*Marketing je umění a věda o nalezení, udržení a růstu ziskových zákazníků.*“ (Kotler, 2007, s. 67). Náklady na udržení stávajícího zákazníka jsou totiž až 5x nižší než na nalezení nového (Wheelhouse Advisors, 2015a). V marketingu se rovněž uplatňuje tzv. Paretovo pravidlo, jelikož 80 % zisku firmy je zapříčiněno poptávkou 20 % všech kupujících, v tomto případě hovoříme o dlouhodobých zákaznících (Wheelhouse Advisors, 2015b).

Aby podnik co nejefektivněji ovlivnil poptávku po produktu, může k tomuto účelu využít souhrn nástrojů a technik, které jsou součástí konceptu 4P. Jedná se o stanovení produktové strategie a portfolia, k jehož dosažení slouží čtyři základní nástroje, a to výběr nabízeného produktu a zaměření na jeho klíčové vlastnosti, cenová politika, výběr komunikačního média a vyhodnocení efektivnosti komunikace a v neposlední řadě distribuce. Lze se setkat i s rozšířeným marketingovým mixem, který zahrnuje lidi, politiku nebo veřejné mínění. Alternativou k tomuto konceptu je marketingový mix 4C, který koncepci řeší z pohledu zákazníka a zahrnuje jeho potřeby, náklady, dostupnost nabízených produktů a služeb a komunikaci (Kotler, 2007).

Marketing prošel od svého počátku na přelomu 19. a 20. století velikého rozvoje. Kotler (2007) tento progres definoval třemi vývojovými stupni, které se liší svým primárním zaměřením (produkt, zákazník, hodnota). V počátku období tzv. Marketingu 1.0 se prodejci soustředili na vlastnosti produktu a výhody jeho nabízení širokým masám. Centrem uvažování byl tedy produkt a jeho přednosti, který byl určen široké veřejnosti. Marketing 2.0 úzce souvisí s rozvojem informačních technologií v devadesátých letech. Cílem je nabídnout diferencovaný produkt odlišným zákazníkům. V tomto období se mj. začíná projevat výhoda nasazení CRM. Poslední etapou je Marketing 3.0, který je založen na tom, co zákazník k firmě cítí a jak ji vnímá z pohledu prezentovaných hodnot. Pro firmu je proto důležité soustředit se na dialog a své zákazníky naslouchat (Hansen, 2017).

## 1.1 Marketingová komunikace

Marketingová komunikace jakožto jeden z nástrojů představeného marketingového mixu je sled činností, který má za úkol sdělit podstatné vlastnosti produktu klíčovým zákazníkům a přesvědčit je k nákupu. Komunikace, která začíná výběrem cílového publika, přenosového média a stanovením komunikačního cíle, pokračující přenosem sdělení od odesílatele k příjemci skrze vybrané médium a zakončená zpětnou vazbou, musí být, jasná, přesvědčivá a sladěná s ostatními kanály. V opačném případě hrozí ztráta zákazníků.

Komunikaci lze realizovat dvojí formou – osobně a neosobně. Mezi neosobní formy komunikace patří např. reklama, public relations, podpora prodeje, přímý marketing nebo sponzoring (Přikrylová, 2019). Neosobní formu komunikace lze provozovat rovněž v internetovém prostředí (nástroje jako sociální sítě, blogy, emaily a další), kam většina firem stále častěji přeměrovává své komunikační a prezentační aktivity. Jak uvádí výzkum zveřejněný na serveru eMarketer, v roce 2014 investovaly americké firmy největší podíl obnosu do reklamy v televizi. Dle predikce to v roce 2020 nebude televize, ale se 44% podílem internet (eMarketer, 2016). Ten má totiž oproti ostatním médiím výhodu v nepřetržité komunikaci nebo dynamickém obsahu, který je interaktivní a rychlý. V neposlední řadě jsou výhodou nižší vynaložené náklady nebo možnost detailního monitoringu komunikace.

Vybrané komunikační nástroje tvoří tzv. komunikační mix. Volba optimálního komunikačního mixu je ovlivněna faktory jako charakter cílového trhu a nabízeného produktu, svoji roli hraje i stadium životního cyklu produktu. V průběhu zavedení produktu na trh se volí jiné komunikační nástroje s jiným cílem než ve stadiu zralosti produktu. Roli hraje taktéž cena nabízeného produktu nebo služby a disponibilní finanční zdroje podniku (Přikrylová, 2019).

Tabulka č. 1 níže srovnává hlavní současné komunikační média v marketingu hned z několika hledisek. Porovnává se televize a rádio s tištěnými a digitálními médii. Zvlášť jsou pak hodnoceny sociální sítě.

<b>Faktor</b>	<b>TV, rozhlas</b>	<b>Tištěná média</b>	<b>Digitální média</b>	<b>Sociální síť</b>
<b>Rozšíření média</b>	Regionální	Regionální	Regionální až globální	Globální
<b>Směr komunikace</b>	Jednosměrná	Jednosměrná	Obousměrná	Obousměrná
<b>Přenos</b>	Zvuk, (obraz)	Text, obrázky	Zvuk, video, text, obrázky	Zvuk, video, text, obrázky
<b>Zdroj zprávy</b>	Věrohodný	Věrohodný	I nevěrohodný	I nevěrohodný
<b>Možnost individualizace obsahu</b>	Ne	Ne	Ano	Ano
<b>Cena reklamy</b>	Vysoká	Střední	Střední	Nízká
<b>Opětovné zhlédnutí reklamy</b>	Ne	Ne	Ano	Ano
<b>Možnost měřit účinnost reklamního sdělení</b>	Omezená	Velmi omezená	Vysoká	Velmi vysoká
<b>Příklad reklamy</b>	Reklamní spot v průběhu přestávky pořadu	Reklamní sdělení v novinovém článku	Firemní blog, banner, newsletter	Stránky nebo placená reklama na sociální síti Facebook

*Tabulka 1 – Porovnání internetu s ostatními médii (zdroj: Blažková (2005, s. 14) a Belyh (2017))*

## 1.2 Trendy v marketingové komunikaci

V úvodu kapitoly o marketingu je zmíněno významné postavení stávajícího zákazníka. Je zřejmé, v budoucnu se na tom nic nezmění. Správně vložená energie do komunikace s potenciálními a stávajícími zákazníky se firmě jistě vrátí. Vedle toho je potřeba si uvědomit, jak se komunikační prostředí dynamicky mění. Nové technologie a služby znamenají, že lidé postupem času věnují svoji pozornost jiným směrem. Např. mladí lidé daleko více času tráví v online prostředí. Aby byla komunikace pro podnik namířena správným směrem, je žádoucí takové změny sledovat. Proto Příkrylová (2019)

zmiňuje ve své tištěné publikaci několik trendů moderní marketingové komunikace, např. individualizaci komunikace, zapojení influencerů nebo obsahový marketing.

*Individualizace marketingové komunikace.* Lidé jsou přehlčeni všudypřítomnou reklamou. Dle výzkumu společnosti Factum lidem v České republice nejvíce vadí reklama v televizi, v letácích v poštovních schránkách a na venkovních billboardech (Krupka, 2016). Jak zmiňuje Kuchař, lidé se naučili přizpůsobit rostoucímu tlaku marketingu jednoduše – nevšímají si ji. Reklamní slepota se příkladně projevila u bannerů, kde se proklik pohybuje mezi 0,1 až 0,3 % (Kuchař, 2012). Proto je potřeba reklamní sdělení individualizovat a nabídnout ve formě, která nebude příjemci vadit. Pro personalizovanou reklamu se využívají data v CRM systémech (viz kapitola č. 3), ať už se jedná o nákupní preference, historii provedených nákupů, bydliště nebo věk). Zvyšuje se jednak pravděpodobnost udržení pozornosti a přízně klienta, tak jeho budoucí poptávka. Jako komunikační médium je v tomto případě často využíván email s personalizovaným obsahem nebo reklama na sociálních sítích. Využívá se rovněž nástrojů tzv. interaktivního marketingu, kdy je příjemce sdělení aktivně zapojen do komunikačního procesu. Inzerent tak okamžitě obdrží zpětnou vazbu od zákazníka. Výhodou je rovněž vysoká flexibilita komunikace, snadná měřitelnost efektivity nebo nižší náklady. Využívají se kreativní webové prezentace, interaktivní hry nebo kvízy (Galetto, 2016).

*Influencer marketing.* Zapojení významných osobností daného oboru (celebrity jako herci, sportovci nebo Youtuberi) se stává při budování marketingové strategie firmy daleko větší samozřejmostí. Využitím influencera lze zacílit na relevantní a početnou skupinu potenciálních zákazníků. Dle vypracovaného výzkumu společností Mediakix, který prezentuje Bailis (2019), vykazuje tento komunikační kanál výrazně lepší návratnost investic (tzv. ROI) než jiné způsoby komunikace. Nejvíce jsou využívány sociální sítě, primárně pak Instagram díky velkému počtu uživatelů a prezentaci skrze kvalitní obrazový materiál. Ve velké míře je využíván rovněž Youtube nebo Facebook. Obecně sociální sítě hrají na začátku 21. století prim, co se zaměření komunikace týká. Jen Facebook využívá přes dvě miliardy lidí na celém světě a např. přes 89 % mladých lidí ve věku 16 až 24 let má účet na některé sociální síti (statistika za země OECD) (Ortiz-Ospina, 2019).

*Obsahový marketing.* Jak zmiňují Procházka a Řezníček ve své publikaci o obsahovém marketingu, jedná se nenucenou formu komunikace a prezentace, umění spočívá v tom smyslu, že sdělení mířené na příznivce a zákazníky nic neprodává, ale naopak zvyšuje povědomí a důvěryhodnost značky a rozšiřuje zákaznickou základnu. Prezentovaným obsahem bývají poutavé infografiky, rozhovory se zaměstnanci, firemní

články nebo edukativní videopříspěvky. Nevýhodou obsahového marketingu je časová náročnost na tvorbu kvalitního a poutavého obsahu (Procházka & Řezníček, 2014).

*Emoce ve sdělení.* Emoce se čím dál častěji stávají zbraní, jak na sebe strhnout pozornost. Navíc jsou sdělení s emocionálním nábojem lépe zapamatovatelná. Díky pokročilým nástrojům pro analýzu sentimentu na sociálních sítích lze automaticky detekovat jak sentiment příspěvků konkurence, tak hodnotit reakce uživatelů na vlastní zveřejněné posty.

*Využívání nejnovějších technologií.* V marketingové komunikaci se stále častěji využívají prvky umělé inteligence, jako jsou např. chatboti nebo hlasoví osobní asistenti. Virtuální realita se uplatňuje při prezentaci kuchyní a koupelen nebo zprostředkovává nevšední kulinářský zážitek v restauračním zařízení, jako je tomu např. v japonské restauraci First Airlines. Při výzkumu reakcí uživatelů na vizuální podněty se využívají nástroje eye-trackingu. Obecně lze říci, že vědní obory zkoumající fungování a reakce lidského mozku budou mít do budoucnosti obrovský přínos mimo jiné pro marketingové účely (hovoří se o nově vznikajícím oboru s názvem neuromarketing) (Přikrylová, 2019).

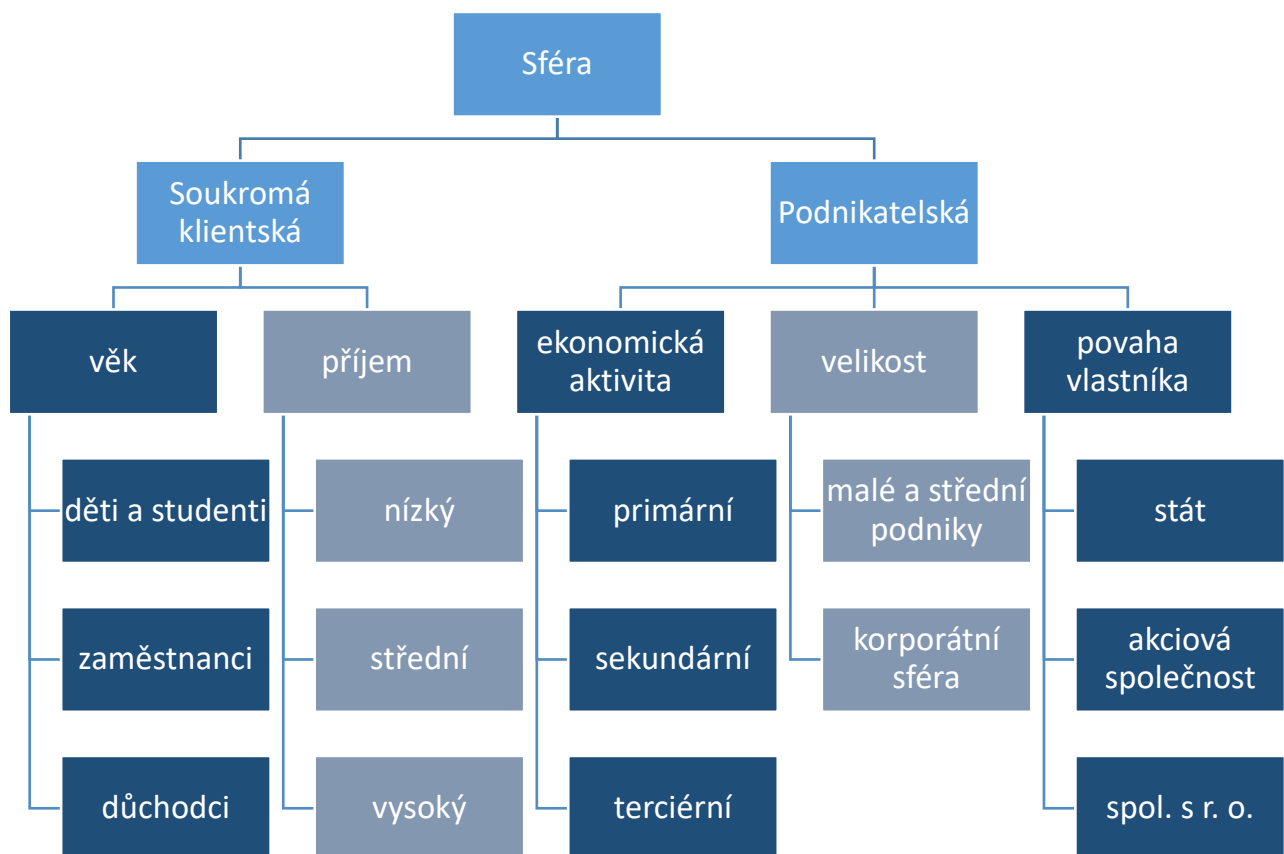


## 2 Komunikace bankovních institucí

Jelikož se práce ve své praktické části zabývá výzkumem komunikace bankovních institucí, je vhodné zmínit její podstatné aspekty a současné trendy. Dříve než bude popsána komunikace, je příhodné čtenáře seznámit se segmentací trhu, na kterém se komerční banky pohybují. Je totiž zřejmé, že se komunikace mj. odvíjí od toho, pro kterou skupinu zákazníků je obsah sdělení určen.

### 2.1 Segmentace trhu

Bankovní instituce nabízejí na trhu různé portfolio služeb a produktů klientům. Toto portfolio může být cílené buď na širokou skupinu zákazníků, nebo na klienty vyznačující se odlišnými vlastnostmi a potřebami. Ve druhém případě hovoříme o segmentaci trhu (nebo tzv. divergentní marketingové strategii), kdy jsou cíloví zákazníci diferencováni ve vztahu k jejich kupnímu chování. Segmentace trhu obecně umožňuje podnikům zaměřit svoji nabídku a komunikaci na menší skupinu kupujících a tím lépe naplnit jejich potřeby a minimalizovat riziko nespokojenosti. Krajíček (2005) definuje čtyři základní typy proměnných segmentace, a to geografický (místo pobytu nebo podnebí), demografický (věk nebo příjem), psychografický (sociální třída nebo životní styl) a behaviorální (žádoucí zisk, loajalita nebo vědomosti). Toto členění je všeobecně platné. V bankovním sektoru se lze setkat s dalšími způsoby formování segmentů, ve kterých jsou klientům nabízeny různé bankovní produkty a služby. Krajíček (2005) uvádí ve své publikaci následující dělení:



Obrázek 1 – Segmentace trhu (zdroj: Krajíček (2005))

Na klienty v soukromé sféře lze nahlížet z několika hledisek. Pro bankovní sektor jsou nejdůležitější životní cyklus klienta (tedy jeho věk) a výše příjmu. Pro každý takový segment jsou nabízeny jiné produkty. Tomu odpovídá i jiný obsah komunikace nebo její způsoby distribuce. Podnikatele lze definovat dle ekonomické činnosti, tj. jiné bankovní služby jsou nabízeny podnikům v zemědělství, zpracovatelském průmyslu, obchodním společnostem nebo jiným bankám na trhu. V rámci segmentace se lze rovněž setkat s pojmem retailové bankovníctví, které cílí na fyzické osoby a v některých případech i drobné podniky (Krajíček, 2005). Na obr. č. 2 lze vidět, jak je členěno retailové bankovníctví v největší české bance co do počtu klientů – České spořitelně.

## Čtyři tváře retailového bankovníctví ČS

<b>Pro koho</b>	Pro všechny	Příjem 30 000+ Kč čistého měsíčně nebo majetek 0,5+ mil. Kč	Příjem 70 000+ Kč čistého měsíčně nebo majetek 4+ mil. Kč	Investice a depozita 10+ mil Kč	Živnostníci
<b>Co</b>	Rodinné finanční poradenství s důrazem na jednoduchost	Poradenství a finanční řešení pro finančně zdatnější klienty	Exkluzivní poradenství a služby pro klienty, kteří chtějí zhodnocovat svůj majetek	Mezinárodní servis a speciální poradenství v oblasti správy celkového majetku pro nejmovitější klienty	Finanční poradenství využívající znalosti specifického předmětu podnikání klienta
<b>Hodnoty</b>	Vstřícnost Nápomocnost Důvěra	Péče Profesionalita Partnerství	Jedinečnost Exkluzivita Prestiž	Odbornost Důvěryhodnost Diskrétnost	Péče Profesionalita Partnerství
<b>Propozice</b>	Moje zdravé finance		Erste Premier	Erste Private Banking	Propozice pro podnikatele

Obrázek 2 – Členění retailového bankovníctví v České spořitelně (zdroj: Česká spořitelna (2019))

### 2.2 Specifika komunikace

Bankovní služby jsou ze samotné povahy specifické, např. jsou nehmotné, což je důsledkem obtížnějšího porovnávání s konkurenčními nabídkami a může vyústit v obavy související s rizikem při samotném nákupu. Proto by se bankovní management měl zaměřit na co nejjednodušší popis nabízené služby. Tento popis by měl jít ruku v ruce s Etickým kodexem České bankovní asociace, který stanovuje rámcová pravidla komunikace a chování bankovních institucí na českém trhu. S tím např. souvisí pravdivost informací (výše bankovních poplatků v inzerci apod.) (Česká bankovní asociace, 2012). Dalším specifíkem je univerzálnost bankovních služeb, což v důsledku znamená, že potenciálním klientem může být prakticky jakýkoliv jedinec nebo firma, jelikož každý může mít s penězi nějaké plány. Jiným znakem je kladený důraz na důvěryhodnost, dlouhodobost a bezpečnost služby. S tím v neposlední řadě souvisí i zvýšená medializace, především pak v kontextu negativních událostí (Nacher, 2005). Bankovní management by proto měl při plánování komunikační strategie respektovat jak výše zmíněná specifika, tak vymezená pravidla etickým kodexem.

Tak jako v jiných odvětvích, tak i v bankovníctví se využívá široká paleta nástrojů marketingové komunikace, jak těch tradičních jako tištěná reklama nebo televizní spot, tak těch novějších digitálních jako cílené reklamy na sociálních sítích nebo využití čím dál více sofistikovanějších chatbotů. Nemalou roli v bankovníctví hraje rovněž osobní prodej v podobě poradců orientující se v různých oblastech finančních služeb. Nejen že musí umět

potenciálního klienta přesvědčit o nákupu nabízeného produktu, ale rovněž musí umět poradit, doporučit nejlepší řešení navržené na základě zjištěných potřeb a přání klienta (Krajíček, 2005).

### 2.3 Současné trendy

Dle výzkumu provedeného na českém trhu je pro klienty bankovních a pojišťovacích institucí důležitá především kvalita a rychlost komunikace (Řeháková, 2017). Bubák a Beran (2020) mezi pilíře moderního bankovníctví zařazují také empatický a proaktivní přístup, skrze který lze ještě lépe pochopit osobní potřeby klienta. Empatický přístup a schopnosti bankéře pak zvyšují důvěryhodnost instituce a loajalitu zákazníka. Dle průzkumu Smart Communications provedeném na vzorku klientů finančních institucí ve Velké Británii a Spojených státech se 63 % respondentů vyjádřilo, že by uvažovalo o změně banky v případě nenaplnění představ plynoucí z komunikace (Smart Communications, 2018). Aby banky naplnily očekávání, musejí jít klientům naproti co se týče využívání požadovaných komunikačních kanálů. 89 % globálních bankovních domů zvýšily v roce 2014 investice do správy existujících a na implementaci zcela nových digitálních sdělovacích prostředků (Stephen, 2015). A v roce 2019 zahájila ČSOB vzdálenou komunikaci i s neslyšícími klienty díky online simultánnímu přepisu. Tímto gestem si zasloužila hodnocení *Handicap Friendly* v projektu *Vstřícná banka* (Bankovní poplatky, 2019). Co se týče obecně marketingové komunikace bank na českém trhu, nutno podotknout, že k jistému profesionálnímu přístupu (např. výrazné zefektivnění finančních prostředků vložených do reklamy a reklamních kampaní) dochází na začátku nového tisíciletí. Jak zmiňuje Nacher ve své analýze, do té doby docházelo spíše k podceňování komunikace s klienty z důvodu neznalosti základních marketingových metod a prostředků, a to především v prvních letech po ekonomické transformaci (Nacher, 2005). Dle Karlička přinesla svěží vítr na český bankovní trh AirBank, která se postavila proti velkým hráčům na trhu. Strategie v podobě jednoduchého a otevřeného bankovníctví bez skrytých poplatků s pozitivním emocemi měla člověka nenásilným způsobem donutit zapřemýšlet o změně. A dle některých výzkumů měla komunikace pozitivní efekt (Karlíček, 2016). Za všechny lze zmínit výzkum Olbrichové, který hovoří ve stejném duchu. Když se řekne banka, respondenti si nejrychleji vybaví právě Air Bank, a to především díky humorné televizní reklamě (Olbrichová, 2015). Jak ale plyne ze šetření Vojtěchové, mladí lidé ve věku 18 až 30 let v 70 % případů nesledují svoji banku na sociálních sítích, které sami využívají. Aby

se situace z pohledu bankovních institucí obrátila k lepšímu, měly by se více zaměřit na novinky z akciových trhů a finanční gramotnost. Naopak prezentace aktivit samotné banky není tak důležitá (myslí si to jen polovina dotázaných) (Vojtěchová, 2017). Šperková ve své práci zkoumá sentiment v komentářích uživatelů, kteří se na sociální síti zmiňují o některé z bank na českém trhu. Nejvíce pozitivních ohlasů získala Fio banka, nejvíce negativních pak Zuno. Dále pak autorka zmiňuje, že uživatelé často využívají sociální sítě jako technickou podporu, pokud jim nebylo z nějakého důvodu pomoci na pobočce (Šperková, 2014). Foxová klade důraz na různorodost příspěvků z hlediska obsahu (např. prezentování aktivit týkající se společenské odpovědnosti, sponzorovaných sportovních aktivit nebo vyhlašování soutěží). Samozřejmostí je pravidelné přispívání obsahu a přítomnost na vícero sociálních sítích (Fox, 2011). Proti proudu se v roce 2019 vydala celá bankovní skupina UniCredit, která se rozhodla ukončit své působení na sociálních sítích (Facebook, Messenger, Instagram) a investovat do vlastních digitálních kanálů, kde chce udržet vysokou úroveň kvality komunikace. Toto rozhodnutí se nesetkalo s pozitivní odezvou klientů, spíše naopak (Kučera, 2019). Jak zmiňuje jiná studie, některé banky na trhu mohou sdílet přesvědčení, že na sociálních sítích ztrácejí dostatečnou kontrolu nad obsahem, který se díky virálnímu efektu rychle a nekontrolovatelně šíří. Např. díky negativním komentářům zákazníků, nezvládnuté komunikaci ze strany banky a enormnímu počtu sdílení mezi uživateli vyskytujících se na sociálních sítích může banka výrazně poškodit svoji reputaci. Nicméně ze strany bank je dle autorů nutná adaptace na podmínky sociálních sítí a s tím spojené nemalé finanční úsilí na přípravu vhodné komunikační strategie, která je v souladu s ostatními komunikačními kanály (Mitic & Kapoulas, 2012). Závěry této práce potvrzuje i Bohlin s kolektivem autorů, který vedle Internet Banking a Mobile Banking definuje Social Networking Banking jako nové digitální spojení mezi bankou a klienty. Dle výsledků výzkumu na vzorku 100 vybraných bankovních institucí po celém světě používají sociální sítě (Facebook, Twitter a YouTube) nejvíce k marketingové komunikaci a digitální reklamě (82 %). Dále pak k finančnímu a produktovému poradenství (81 %) a SCRM (51 %). Nejméně je využívají k inzerci nových pracovních míst (součástí výzkumu nebyla sociální síť LinkedIn) a k výzkumu mezi zákazníky. Do budoucna autoři předpokládají standard v podobě propojení účtu na sociální síti s bankovní identitou, což souvisí s poskytováním uživatelských a bankovních dat aplikacím třetích stran např. na Facebooku. Zde je ale velkou otázkou záruka bezpečnosti a ochrana proti zneužití citlivých dat (Bohlin et al., 2018).

### 3 CRM

Dle Příkrylové (2019) je definice CRM následující: „*Jedná se o řízení vztahů se zákazníky zahrnující sofistikované softwarové a analytické nástroje, které integrují informace o zákaznících z různých zdrojů, provádějí hloubkovou analýzu a výsledky používají pro vybudování silnějších vztahů se zákazníky. Systém CRM je využíván pro stanovení hodnoty jednotlivých zákazníků, identifikaci nejdůležitějších cílových skupin, přizpůsobení produktů firmy požadavkům jednotlivých zákazníků a v neposlední řadě k přesnějšímu cílení firemní komunikace.*“ (Příkrylová, 2019, s. 54).

Dohnal (2002) ve své publikaci definuje řízení vztahů se zákazníky: „*CRM zahrnuje pracovníky, podnikové procesy a technologii IS/ICT s cílem maximalizovat loajalitu zákazníků s v důsledku toho i ziskovost podniku. Je součástí podnikové strategie a podnikové kultury.*“ (Dohnal, 2002, s. 18).

Hommerová (2012) nahlíží na CRM ze dvou různých pohledů. Řízení vztahů se zákazníky definuje jako filozofii založenou na one-to-one marketingu, z úhlu technologického dále zdůrazňuje: „*Systém CRM je soubor hardwarových a softwarových technologií a nástrojů podporující celkovou strategii firmy, vedoucí k poznávání zákazníků, posílení jejich loajality, zvýšení jejich zájmu o další produkty a služby firmy.*“ (Hommerová, 2012, s. 13).

Z výše uvedených definic vyplývá, že CRM není jen informační systém, ale rovněž strategie, filozofie a kultura podniku. Je také zřejmé, že řízení vztahů se zákazníky úzce souvisí s marketingovou komunikací.

Budování, udržování a řízení dobrých vztahů se současnými i budoucími zákazníky je dle Čecha a Bureše tvořeno třemi dimenzemi – technologickou, podnikatelskou a lidskou. Všem třem směrům by měl podnik věnovat stejnou pozornost a zároveň by měly být všechny procesy integrovány (Čech & Bureš, 2009). Hommerová (2012) místo dimenze podnikatelské používá výraz *proces*. Dohnal definuje tři základní procesy v průběhu budování vztahů, a to chronologicky marketingový proces, obchodní proces a proces poskytování služeb. Autor rovněž klade důraz na soulad těchto činností (Dohnal, 2002).

Lehtinen, Shen a Dohnal pak uvádí důvody, proč je důležitý silný s dlouhodobý vztah se zákazníkem. Tak např. dobrá pověst a kladné hodnocení zákazníků přitahuje další zákazníky. Kupující ve velké míře opakovaně poptávají ty samé produkty, rovněž narůstá prodej komplementárních produktů nebo služeb. Podnik díky stálým zákazníkům eviduje redukované náklady, protože zkušený klient se lépe orientuje v nabídce, a vyžaduje tedy

nižší podporu v průběhu nákupního procesu. Silný vztah se zákazníkem činí konkurenci obtížněji tento poměr narušit (Lehtinen, 2007; Shen & Huang, 2011; Dohnal, 2002).

Kotler a Keller zmiňují čtyři důležité kroky, které jsou stěžejní při adaptaci a následném řízení vztahu se zákazníkem. V prvním kroku je důležité detailně identifikovat kupující. Následně je rozdělit do skupin z pohledu dvou parametrů, kterými jsou jejich potřeby a hodnota nebo přínos pro prodávajícího. Důležité je věnovat se pečlivě především těm, které mají pro firmu největší hodnotu. V dalším kroku je nutné navázat individuální komunikaci s každým takovým zákazníkem a ještě více identifikovat jejich přání a potřeby. V poslední fázi by se měl podnik zaměřit na přizpůsobení produktu, služeb a komunikace (Kotler & Keller, 2013). Před samotným nasazením technologie a procesů řízení vztahů s klienty musí mít management jasnou představu o budoucí strategii podniku (Dohnal, 2002).

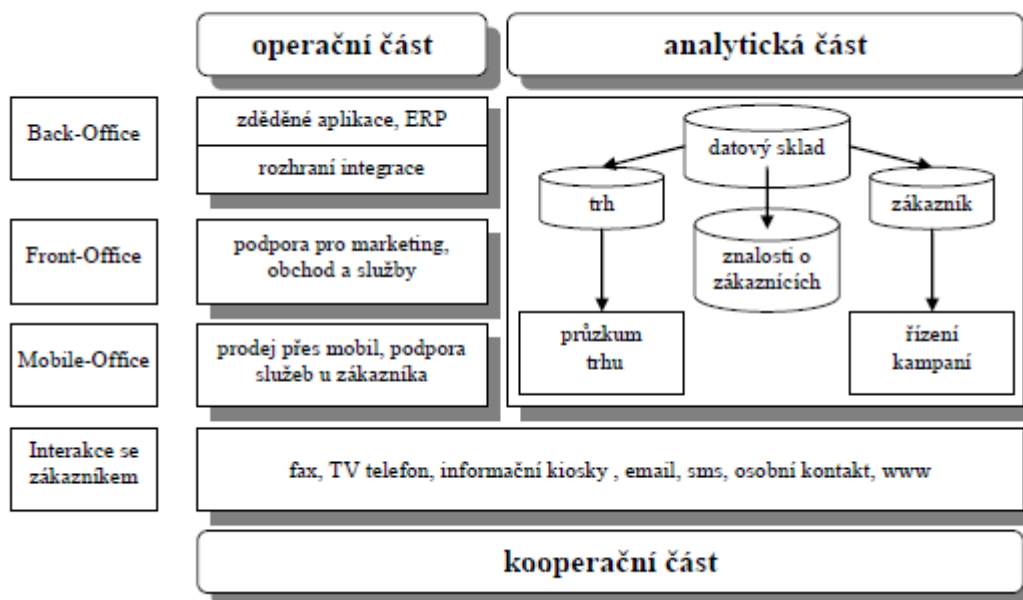
Dle šetření Akyüze a kol., kterého se účastnilo na 344 vedoucích pracovníků různých úrovní managementu v oblasti Istanbulu, 50 % dotázaných absolutně souhlasí s tím, že by produkty a služby měly být přizpůsobené přáním zákazníků, 77 % z nich zcela souhlasí s efektivní podnikovou prezentací a 44 % dotázaných manažerů uvedlo, že jejich podnik sdílí detailní informace o klientech s ostatními zaměstnanci, pro které jsou data relevantní (Akyüz et al., 2017).

### 3.1 Architektura

CRM systémy se skládají ze tří základních funkčních oblastí, které pracují nezávisle na sobě a podnik by měl pro efektivní řízení využívat všechny v plném rozsahu. Jsou to vrstvy operační, analytická a kooperativní (Dohnal, 2002). Na obr. č. 3 se nachází schéma architektury CRM systémů.

Operační část je zaměřena na automatizaci a řízení základních podnikových procesů týkajících se marketingu, obchodu a servisní činnosti. Operační část CRM je propojena s aplikacemi Back-Office, které zahrnují řízení dodavatelských řetězců (tzv. SCM) nebo plánování podnikových zdrojů (tzv. ERP). Analytická část je zaměřena na analýzu dat získaných z interakcí se zákazníkem. Využívají se datové sklady nebo tzv. OLAP (On-Line Analytical Processing) technologie, které umožňují analyzovat získaná data v n-dimenzích. Obecně se v této vrstvě využívají nástroje BI (Business Intelligence), které slouží pro účely analytických a plánovacích činností. Kooperativní část zajišťuje komunikaci se zákazníky. V této oblasti se využívá kontaktních center nebo partnerské sítě (Dohnal, 2002).

Do kooperativní vrstvy lze v současné době zařadit i komunikaci přes sociální sítě. Pro porovnání Hommerová (2012) definuje v architektuře CRM systémů jen dvě vrstvy, a to operační a analytickou. Komunikační kanály jsou součástí Front-Office aplikací v operační vrstvě, kam patří např. call centra nebo elektronický obchod. V Back-Office zmiňuje aplikace logistické, ekonomické nebo personalistické.



Obrázek 3 – Architektura CRM (zdroj: Čech & Bureš (2009, s. 138))

### 3.2 Trendy v CRM

Dle Hanuše (2015) stojí moderní CRM na čtyřech pilířích, kterým je potřeba věnovat v podnikové strategii pozornost do budoucna:

- **Mobilita** – obchodníci tráví většinu času na cestách. Často jsou ale vázáni na kancelář, kde aktualizují data v CRM systémech posbírané z obchodních cest. Aby byla práce obchodníka efektivnější, nabízí se využití tzv. mobilního CRM založeném na cloudovém řešení. Data lze aktualizovat při cestách, a přesto jsou okamžitě sdílená s ostatními členy obchodního týmu.
- **Spolupráce** – z důvodu většího konkurenčního prostředí je cílem optimalizace sdílení informací a firemních procesů, zdůrazněna je spolupráce mezi obchodním a marketingovým oddělením. Do optimalizačních procesů jsou zahrnuty rovněž firemní sociální sítě nebo analytické nástroje.
- **Chování** – pokud podnik pochopí chování svých zákazníků, umožní to maximalizovat efekt marketingových aktivit. Díky nástrojům CRM



a tzv. behaviorálního marketingu lze zvýšit návratnost investic do marketingových kampaní.

- **Sociální CRM** – zákazníci jsou na sociálních sítích a využívají je také proto, aby si u ostatních uživatelů ověřili fakta a informace o nabízených produktech nebo aby sdíleli své zkušenosti s nakoupenou službou či zbožím. Aby podnik na vývoj na sociálních sítích mohl reagovat, potřebuje k tomu informace, na základě kterých se může rozhodnout. K tomu může sloužit analýza sentimentu, která odpovídá na otázky, co si o dotyčné firmě lidé myslí, nebo zda jsou se službou či produktem spokojeni (Hanuš, 2015). Více o sociálním CRM v další kapitole.

## 4 Sociální CRM

Sociální CRM (Social Customer Relationship Management, SCRM) jakožto důležitý nástroj pro interakci se zákazníky v digitálním světě 21. století neoznačuje jen Hanuš (2015), ale již o pár let dříve ve svých studiích také Nadeem (2012), Greenberg (2010), který využívá rovněž označení CRM 2.0, nebo Ang (2011), který však namísto pojmu SCRM upřednostňuje slovní spojení Community Relationship Management (CoRM), které dle autora lépe vystihuje podstatu komunikace na sociálních sítích. Rostoucí trend v oblasti výzkumu dokazuje také vzrůstající počet článků na dané téma. V roce 2006, kdy byl zaznamenán prvotní růst, bylo registrováno asi na 20 článků, v roce 2015 již 175 (Wan & Xie, 2018). Následující odstavce pojem SCRM blíže představí.

Volně přeložená definice Greenberga zní následovně: „*Sociální CRM je filozofie a obchodní strategie podporovaná technologií, jejíž cílem je interakce se zákazníkem, která poskytuje vzájemně výhodnou hodnotu v důvěryhodném a transparentním obchodním prostředí.*“ (Greenberg, 2010, s. 414).

Chaffey pojem sociální CRM definuje jako: „*Proces řízení konverzací mezi zákazníky s pomocí zapojení stávajících zákazníků, který vede ke kvalitnějšímu CRM.*“ (Chaffey, 2013).

Volně přeložená definice Carolyn Baird z IBM je následující: „*Integrace sociálních médií se strategií řízení vztahů se zákazníky (CRM). Jedná se o další milník organizací, které chtějí efektivně využít sílu sociálních interakcí, aby se ještě více přiblížily zákazníkům.*“ (Baird, 2011).

Chaffey definuje prostor sociálního CRM aplikačními oblastmi, který je tvořen marketingem, prodejem, servisem a podporou, inovací, spoluprací (nebo též integrací) celé organizace a zákaznickými zkušenostmi. V průběhu implementace a samotné aplikace SCRM ve firemním prostředí pak předkládá pět důležitých bodů (tzv. 5M) – monitoring sociálních sítí, mapování vztahů mezi podnikem a zákazníky, management, middleware a jeho využití v této oblasti a měření podstatných ukazatelů (Chaffey, 2013).

Z definic výše je patrné, že SCRM je plně integrovanou nadstavbou CRM, která má za úkol ještě bližší interakci se stálými i potenciálními zákazníky, a to za pomoci sociálních sítí, blogů nebo diskuzí. Jak ale někteří autoři článků o sociálním CRM (Ang nebo Morgan) zmiňují, není důležité soustředit se pouze na vazbu mezi firmou a zákazníkem, ale také bedlivě naslouchat to, co si uživatelé sdělují mezi sebou. V tom tkví skutečná výhoda tohoto nástroje a filozofie (Ang, 2011; Morgan, 2010).

## 4.1 Sociální sítě a SCRM

Vztah CRM a sociální sítě je v tomto případě velmi diskutovaný. Morgan zdůrazňuje, že tradiční prostředky řízení vztahů se zákazníky nemají nic společného se sociálními sítěmi. Podle něj se jedná jen o pouhá data a informace, nic sociálního na této vazbě není (Morgan, 2010). Greenberg dodává, že SCRM je doplněk klasického CRM o sociální funkce a procesy, které vedou ke spokojenosti zákazníka a výkonnosti podniku. Sociální sítě, kde se zmíněné procesy odehrávají, jsou pro firmy vítaným prostředníkem, s jehož pomocí mohou ještě více angažovat své fanoušky (Greenberg, 2010). Je potřeba mít na paměti, že samotná přítomnost podniku na sociálních sítích nezaručuje úspěch v marketingu ani ve sběru informací o tamějších zákaznících. Lidé jsou na sociálních sítích především proto, aby se spojili s přáteli a rodinou nebo jako první obdrželi zprávy ze světa. Jen necelá třetina uživatelů navštěvuje sociální sítě, aby sledovali stránky podniků. Důvodem této interakce jsou z pohledu zákazníka především slevy, jen pětina má v úmyslu být v komunitě firmy (Baird & Parasnis, 2011). Pokud jsou sociální sítě náležitě využity, pak mohou přinášet vytyčené cíle. Na základě výzkumů, které ve své práci zmiňují Siriwardana, Ang a Mehelmi využití sociálních sítí v podniku pomáhá zviditelnit firmu díky lépe cíleným marketingovým aktivitám, dlouhodobě vede ke zvýšení poptávky a prodeje, pomáhají při inovaci a vývoji nových produktů (viz projekt Delli dále), snižuje provozní náklady na servis zákazníků nebo stabilizuje retenci a zvyšuje míru loajality zákazníků (Siriwardana & Dissanayake, 2018; Ang, 2011; Mehelmi & Sadek, 2019). Vysokou efektivitu sociálních sítích, které jsou v souladu se CRM, dokazuje výzkum Barryho a kol. Na vzorku více než 3 000 uživatelů demonstruje, že ti, kteří se aktivně zapojují do diskuze s podnikem právě prostřednictvím sociálních sítí, utratí v průměru o 20 až 40 % více než ostatní zákazníci. V důsledku vzrostl i ukazatel NPS o 33 bodů (viz kapitola č. 4.3) (Barry et al., 2011). Jiná studie se zabývala aktivním využitím nástrojů SCRM v případě mobilních operátorů. Poskytovatelé telekomunikačních služeb se shodli, že zavedení sociálního CRM zapříčinilo vzrůst tržeb a pokles v počtu stížností klientů (Mehelmi & Sadek, 2019). V českém prostředí provedli šetření např. Bachmann a Kantorová. Ze vzorku 81 středně velkých a velkých firem vyplynulo, že dvě třetiny z nich vnímají sociální CRM jako důležitou součást firemních procesů. Nicméně 90 % z nich zmiňuje podstatné postavení CRM a 65 % respondentů uvádí tento nástroj jako *velmi důležitý*. Sociální sítě pak využívají spíše k ojedinělé komunikaci se zákazníky než jako marketingový nástroj a zdroj pro data mining (Bachmann & Kantorová, 2016).

## 4.2 Lidé a SCRM

Ang ve svých článcích upřednostňuje pojem Community Relationship Management (CoRM), který dle autora lépe vystihuje to, co lidé běžně dělají v online prostředí. Pro tyto činnosti používá označení 4C, jsou to výrazy – *connectivity* (zapojení, připojení), *conversations* (konverzace), *content creation* (tvorba obsahu) a *collaboration* (spolupráce). Na základě těchto činností (především na sociálních sítích) lze usoudit, že lidé nejsou v pravém slova smyslu skutečnými zákazníky, ale pouze zde komunikují s ostatními a vytvářejí komunity. Organizace podle Anga tak mohou využít této aktivity ve svůj prospěch a soustředit sem své marketingové aktivity (např. buzz marketing), provádět výzkumy veřejného mínění nebo budovat loajalitu (Ang, 2011).

Rovněž Morgan klade důraz na to, že sociální CRM není jen o komunikaci mezi prodejcem a zákazníkem, ale také se odehrává mezi samotnými uživateli na sociálních sítích a jiných online prostředích. Uživatelé si mezi sebou sdělují zkušenosti s výrobky a službami. V praxi se jedná o zamýšlený či nechtěný efekt virálního marketingu firmy. Podle autora je potřeba udržovat vztah se stálými zákazníky, navazovat kontakty s novými uživateli, kteří jsou po podnik z určitého pohledu hodnotní, a v neposlední řadě umět naslouchat hlas internetové veřejnosti (Morgan, 2010).

Hutton a Fosdick si položili otázku, proč chtějí být lidé součástí komunit, které Ang zmiňuje jako stěžejní místo komunikace. V seznamu se objevily odpovědi jako: „*Aktivně podporovat ty produkty a služby, které se mi líbí*“ nebo „*Cítit se jako součást oblíbené komunity*“ (Hutton & Fosdick, 2011).

Barry spolu s kolegy ve svém článku rozdělil uživatele sociálních sítích na základě jejich tamějšího chování a preferencí do 10 segmentů. Příkladem jsou aktivní hráči online her a kvízů (tzv. *Social Gamers*), uživatelé čítající denní tisk z vícero zdrojů projevující se zároveň vysokou aktivitou na diskuzních fórech a recenzích (tzv. *Fact Finders*) nebo jednoduše ti, kteří jsou přítomni na sociálních sítích, ale nikterak se neprojevují (tzv. *Observers*). Podle autorů je důležité brát v potaz každou skupinu uživatelů a tomu přizpůsobit i způsob komunikace (Barry et al., 2011).

Greenberg naproti tomu používá v kontextu sociálního CRM pojem sociální zákazník, když doslova uvádí: „*Ze zákazníka 20. století se stal sociální zákazník jednadvacátého století.*“ (Greenberg, 2010, s. 412). Je to zákazník, který je aktivní, rád sdílí zážitky a zkušenosti s ostatními, především s těmi, kdo mají podobné záliby. Věrný sociální zákazník se rád zapojí do vývoje nového produktu, jak dokazuje projekt Delli s názvem

*IdeaStorm* spuštěný v roce 2007 a pro velký úspěch i v roce 2012. Zákazníci mohli na určené webové stránce předkládat nápady na nový produkt nebo ideu spojenou s vylepšením stávajících produktů. Na 500 nových nápadů bylo implementováno (Israel, 2012). Komunita okolo značky může výrazněji pomoci redukovat firemní náklady, jak dokazuje jiný projekt Dellu. Speciálně vytvořené diskuzní fórum, kde zběhlí zákazníci předávali své zkušenosti a pomáhali těm nastávajícím, zapříčinilo snížení nákladů o 90 % a aplikační podpora tudíž nebyla tolik vytížená (Ang, 2011).

### 4.3 Měření ukazatelů v oblasti SCRM

Jak zmiňuje např. Chaffey (2013), měření podstatných ukazatelů v aplikaci SCRM nástrojů je pro podnik stěžejní. Za základě metrik lze sledovat plnění stanovených cílů nebo predikovat budoucí vývoj. Význam prediktivní analytiky v oboru SCRM vystihuje např. Štanclová (2016). Data, která se vyskytují v prostředí sociálních sítí, mohou být jak strukturovaná (např. pohlaví, věk, bydliště, vzdělání nebo zaměstnání z detailu profilu uživatele), tak nestrukturovaná (např. obsah statusů nebo komentáře) (Greenberg, 2010). Nestrukturovaná data je nutné převést do strukturované podoby, která je pro strojové zpracování velkého množství dat důležitá. Tímto problémem se zabývá textová analytika (jiným názvem text mining, viz kapitola č. 5) (Štanclová, 2016).

Paul Greenberg předkládá metriky, které je vhodné ve fenoménu CRM 2.0 využívat. Nejedná se jen o počet sdílení konkrétního příspěvku, ale také o tón komunikace a odezvu uživatelů (Greenberg, 2010). Nadeem zdůrazňuje měření výkonu a sledování výsledků ve třech rovinách – jednak měření zapojení fanoušků a zákazníků, které je definováno počtem lajků, sdílením článků nebo velikostí fanouškovské základny, dále tzv. zákaznickými metrikami, kam autor zařazuje např. NPS (Net Promoter Score), které slouží k měření míry loajality zákazníků, v poslední řadě jsou zmíněny finanční ukazatele (Nadeem, 2012). Ang ve své práci zmiňuje měření sentimentu s pomocí tzv. Social Influence Marketing Score (SIM). Skóre se spočítá tak, že jsou negativní texty (myšleno na úrovni recenzí, komentářů nebo článků) odečteny od sumy kladných a neutrálních. Tato hodnota je následně vydělena celkovým počtem všech textů, ve kterých je daný podnik zmíněn. Výsledek se v posledním kroku podělí SIM skóre celého odvětví, kam daný podnik spadá (např. automobilový průmysl, finanční sektor atd.). Tento ukazatel tedy slouží k porovnání s přímými konkurenty na trhu a ukazuje, které firmy jsou vnímány pozitivněji s ohledem na publikované články, recenze nebo komentáře (Ang, 2011). Miller kromě měření

sentimentu nebo návratnosti investic v online prostředí zmiňuje tzv. Share of Voice (SOV) ukazatel. Jde prakticky o univerzální SIM skóre, se kterým lze zjistit, jaký podíl (z určitého hlediska, např. zmínky s hashtagem, dosah atd.) připadá dané firmě mezi konkurenty na trhu (Miller, 2012).

Pro měření výše popsaných metrik lze využít různé online nástroje, které jsou integrovány se CRM. Příkladem je Microsoft Social Listening, který umožňuje detailně sledovat rozdílná online prostředí z různých úhlů pohledu (lze tak měřit analýzu sentimentu, sledovat práci smluvených influencerů nebo monitorovat diskuze) (Hanus, 2015).

#### 4.4 Porovnání CRM a SCRM

Tabulka č. 2 níže porovnává CRM 1.0 s CRM 2.0 z pohledu několika hledisek. Zároveň shrnuje podstatné informace obsažené v kapitolách výše.

<b>Faktor</b>	<b>CRM</b>	<b>SCRM</b>
<b>Prodej</b>	Zaměřen na prodej stálým poptávajícím s rozdílnými nároky díky shromažďování zákaznických dat.	Zaměřen na konverzaci a kooperaci se zákazníky. Prodej, ať už stálým nebo potenciálním kupujícím, je vedlejším produktem.
<b>Zpětná vazba</b>	Podniky po prodeji kontaktují zákazníka s prosbou vyjádřit se formou zpětné vazby. Zákazníci si předávají zkušenosti většinou ústní formou s menším dosahem sdělení.	Zákazníci sdílejí zkušenosti skrze diskuzní fóra nebo sociální sítě. Např. 53 % uživatelů Twitteru doporučuje produkt nebo službu prostřednictvím tweetu. (Brynley-Jones, 2012)
<b>Servis a podpora</b>	Časově omezená. Technická podpora řešena většinou formou call center.	Ze strany zákazníků je očekávaná okamžitá pomoc skrze různé online nástroje pro podporu a servis.
<b>Marketing</b>	Jednostranná komunikace inicializovaná prodejcem. Jsou využívány tradiční marketingové nástroje. Marketing na sociálních sítích se vyskytuje v menší míře.	Oboustranná komunikace. Kladen důraz na aktivní zapojení zákazníků, např. v průběhu vývoje produktu. Komunikačním médiem jsou ve velké míře sociální sítě.

Tabulka 2 – Porovnání CRM a SCRM (zdroj: Brynley-Jones (2012))

## 5 Úvod do text miningu

### 5.1 Vztah mezi data miningem, text miningem a analýzou sentimentu

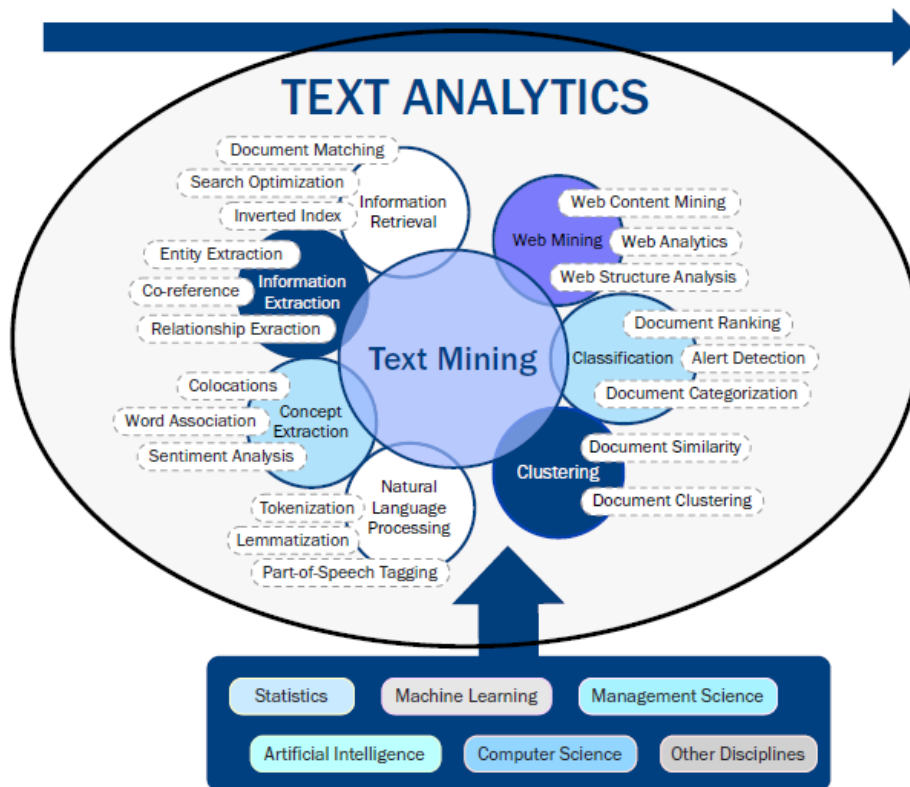
Text mining a analýza sentimentu spolu úzce souvisejí. Co se týče vztahu obou pojmů, analýza sentimentu je (např. spolu s klasifikací) jedna z analytických metod, která je praktickou součástí text miningu, výzkumné a aplikační oblasti dolování znalostí z textových dat. Cílem tohoto procesu je získání relevantních informací často z nestrukturovaných dat, což činí významný rozdíl mezi popisovanou analýzou textu a data miningem, který objevuje nové souvislosti a znalosti ve strukturovaných datech (jedná se např. o databáze nebo metadata) (Feldman & Sanger, 2007).

Aby byl čtenář lépe uveden do kontextu, je v následující kapitole text mining spolu s jeho klíčovými pojmy stručně popsán, především pak samotné metody předzpracování textu, které s analýzou sentimentu sdílí. Krátce je popsán rovněž historický vývoj, který analýze sentimentu logicky předcházel.

### 5.2 Historie a současné členění text miningu

Jedny z prvních pokusů o sumarizaci a klasifikaci textu se objevily na Bodleyově knihovně Oxfordské univerzity již v 17. století. Zásadou Thomase Hydea měla knihovna jeden z nejstarších katalogů na světě. Koncem 19. století vznikají abstrakty rozsáhlých vědeckých článků na londýnských vědeckých institucích a v 60. letech 20. století se objevují prvotní pokusy o strojové zpracování textu sálovými počítači, které generovaly abstrakt na základě frekvence výskytu slov. Hans Peter Luhn tak svoji výzkumnou činností položil základy strojového zpracování textu, na které navazovalo mnoho odborníků z oblasti lingvistiky, matematiky nebo v té době vznikající a rychle se rozvíjející výpočetní techniky (např. Lauren Doyle nebo Claude Shannon). Průnik těchto disciplín dal vzniknout novému výzkumnému odvětví zpracování přirozeného jazyka (tzv. NLP, Natural language processing), které se zabývá otázkami, jak je text nebo lidská řeč zpracováván v digitální podobě. Krom toho vzniká mnoho jiných disciplín, jako je např. web mining, jehož cílem je objevování a extrahování informací z prostředí internetu (Miner, 2012).

Obrázek níže převzatý z publikace Minera (2012) zobrazuje jednotlivé dílčí disciplíny a techniky, které dohromady představuje text mining v současné podobě.

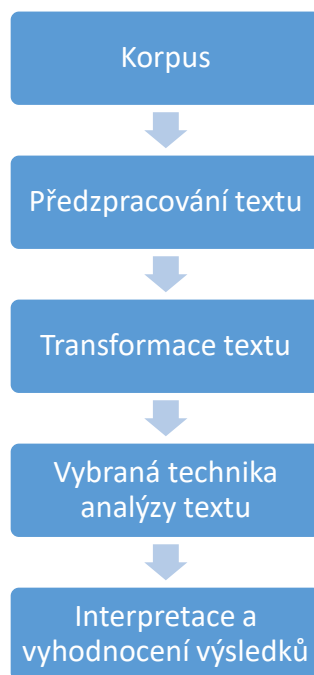


Obrázek 4 – Výzkumné oblasti text miningu (zdroj: Miner (2012))

### 5.3 Proces text miningu

Jak již bylo řečeno, úkolem text miningu je nalézt nové informace z nestrukturovaných dat, tedy textu (psaného, případně přepsaného z mluveného slova), jenž bývá součástí kolekce dokumentů (tzv. korpusu), to znamená dokumentů, které jsou reprezentovány např. skupinou vědeckých či novinových článků, e-mailů, zpráv a podobně a slouží jako vstupní soubor pro níže popsané textové analýzy (viz kapitola č. 5.3.3), nebo tvorbu lingvistických slovníků (Opálková, 2008). Proces takového dolování informací z korpusu obsahuje několik za sebou logicky navazujících kroků, které jsou popsány obrázkem č. 5 a několika odstavci níže.





Obrázek 5 – Proces text miningu (zdroj: Miner (2012))

### 5.3.1 Předzpracování dat

V první fázi je potřeba vstupní data upravit tak, aby mohla být co nejlépe zpracována výpočetním algoritmem, to znamená odstranit z textu obrázky, vzorce, tabulky nebo jiné elementy (např. html či xml tagy). Mezi metody předzpracování dat dle Minera (2012) např. patří:

- **Stematizace** – proces určování základu slova (tzv. stem), který se ve většině případech shoduje s morfologickým kořenem slova. Prakticky se jedná o odstranění předpony a přípony slova, což nečiní problém pro většinu jazyků z indoevropské skupiny. Pro příklad, tvar slova *zatočil* má výsledný stem *toč* (Chmelař et al., 2011).
- **Lematizace** – proces určování základního tvaru slova (tzv. lemma), který se používá ve slovnících. Obě zmíněné metody jsou z důvodu skloňování pro český jazyk velice důležité a užitečné. Prakticky se hojně využívají ve webových vyhledávačích. Ne vždy je ale výsledek algoritmu správný, např. lemma slovního tvaru *tancích* může být tank, či tanec. V tomto případě lematizátor musí posoudit kontext, nebo určit základní tvar na základě frekvence výskytu tohoto slova. Obdobně může nastat problém s mnohoznačností slova. Např. slovo *oko* může znamenat zrakový orgán, nebo

smyčku. Správný význam se v tomto případě získává z kontextu. Problematikou se zabývá tzv. disambiguace (Petkevič, 2017). Z tohoto důvodu vznikají v různých institucích (např. univerzitách) práce věnující se postupnému vylepšování algoritmů, které s oběma metodami pracují. Příkladem práce Chmelaře a kolektivu (2011).

- **Odstranění stopslov** – jedná se o slovní výrazy, která v daném jazyce nemají žádný význam. Typicky se jedná o předložky nebo spojky. Například vyhledávací algoritmy takové výrazy, které jsou uloženy v tzv. negativním slovníku, ignorují (Reitz, 2014).
- **POS tagging** – automatický proces, kdy je každému slovu ze zdrojového dokumentu přiřazen odpovídající slovní druh. Díky tomu, že tato metoda umí pracovat s kontextem daného slova, lze předejít problémům v procesu lematizace (Sychra, 2016).
- **Kontrola pravopisu** – z důvodu překlepů nebo neznalosti gramatických pravidel vznikají v textu chyby. Aby v průběhu předzpracování dat došlo ke správné interpretaci slovního výrazu nebo spojení, využívají se nástroje, které chyby v dokumentu odhalí a automaticky opraví (Kotíková, 2014).
- **Case folding** – proces, v průběhu kterého dochází k převodu celého textu do jednotné podoby z pohledu využívání velké a malé formy písma (minuskule a majuskule). Z důvodu využívání obou forem písma se mohou ve slovnících, které bývají v průběhu transformace využívány, vyskytovat duplicitní záznamy (Miner, 2012).
- **Odstranění slov s nízkou četností** – jedna z volitelných metod v průběhu předzpracování textu, kdy dochází k odstranění těch výrazů v dokumentu, jejichž četnost je nižší než předem definovaná hodnota, tzv. práh. Předpokládá se, že tato slova nemají v celkovém měřítku význam, a dochází tak k rychlejšímu zpracování analýzy (Miner, 2012).

### 5.3.2 Transformace

Transformace, která je další fází procesu dolování informací z textu, zajišťuje převod předzpracovaného korpusu do vhodného modelu reprezentace textového dokumentu tak, aby jej bylo možné strojově zpracovat v dalším procesu. V tomto kroku se pracuje s tzv. termy. Jedná se o elementární prvek transformace, tedy jednotlivá slova, či víceslovná spojení

charakteristická pro danou doménu (např. *rodné číslo*), případně se využívají tzv. n-gramy (n-tice slov) (Kotíková, 2014). Zmíněné elementární prvky pak tvoří jeden z následujících modelů:

- **Model bag-of-words** – tzv. pytel slov či slovník je nejjednodušším modelem reprezentace, kdy je každému termu přiřazena hodnota vyjadřující jeho četnost v dokumentu. Pořadí termů je irelevantní, a tudíž nelze z modelu zpětně obdržet původní podobu dokumentu (Kotíková, 2014).
- **Vektorový model** – vychází z předchozího modelu, přičemž jednotlivé dokumenty studované kolekce jsou vyjádřeny vektory, kde jejich souřadnice vyjadřují četnost výskytu termu v daném dokumentu. Vektorová reprezentace dokumentů zajišťuje snadnější provádění algebraických operací (Kotíková, 2014). Více o vektorových modelech a procesu transformace např. v publikaci Minera (2012).

### 5.3.3 Analýza textu

V tomto stádiu přichází na řadu výběr techniky analýzy textu, která v konečném důsledku zajistí převod z nestrukturovaných dat reprezentovaných modelem do podoby strukturované. Vybrané analýzy jsou dle Minera (2012) následující:

- **Klasifikace** – neboli kategorizace textů znamená automatickou operaci zařazení dokumentu do předem definované množiny tříd. Třídy mohou být specifikovány z hlediska obsahu, autora nebo časového zařazení. Aplikuje se např. při organizaci dokumentů v knihovně nebo jako detektor spamu. Do této kategorie prakticky spadá i analýza sentimentu podrobněji popisovaná v kapitole č. 6 Miner (2012). ale tuto analýzu umisťuje na stejnou úroveň jako klasifikaci nebo shlukování.
- **Shlukování** – proces rozdělení souboru dokumentů do tříd, přičemž dokumenty v každé skupině si jsou v určitém aspektu podobné. Na rozdíl od klasifikace se nejedná o zařazování do předem definovaných kategorií (Sedláček, 2003).
- **Shrnutí (extrakt, abstrakt)** – slouží k vyjmutí nejdůležitější informace ze zdrojového textu. Existují dvě základní formy souhrnu. Zatímco extrakt je tvořený sekvencemi slov, které jsou totožné s původním dokumentem,

vygenerovaný abstrakt je reprezentován zcela originálním textem (Ježek & Steinberger, 2010).

#### 5.3.4 Interpretace a vyhodnocení výsledků

Poslední fází je interpretace a vyhodnocení dosažených výsledků, případně jejich grafické shrnutí. Ne vždy je výsledek uspokojivý, proto se mohou předchozí kroky procesu opakovat, např. v průběhu klasifikace se volí jiný klasifikátor (např. metoda k-nejbližších sousedů, rozhodovací stromy apod.) a dosažené výsledky se statisticky vyhodnocují (Kotíková, 2014).

## 6 Úvod do analýzy sentimentu

### 6.1 Vymezení pojmu sentiment a analýza sentimentu

Pojem sentiment je v mnoha zdrojích definován jako *postoj, názor, emoce* nebo *pocit* člověka vůči určité entitě (např. osobě nebo konkrétní věci) (Dictionary, 2019).

V následujících odstavcích jsou představeny některé definice slovního spojení *analýza sentimentu* (spojení *Sentiment Analysis* v anglickém jazyce bývá do češtiny občas překládáno jako *postojová analýza*, viz např. Veselovská (2017a)).

*„Analýza sentimentu je proces, který určuje, zda je psaný text nebo jeho část míněna pozitivně, negativně, nebo neutrálně. Analýza kombinuje zpracování přirozeného jazyka (tzv. NLP) a techniky strojového učení pro přiřazení hodnoty sentimentu entitám, tématům nebo kategoriím na úrovni vět nebo slovního spojení.“* (Lexalytics, 2019).

Kateřina Veselovská z Ústavu formální a aplikované lingvistiky definuje analýzu sentimentu jako: *„Automatická extrakce subjektivní informace z psaného textu s cílem určit emotivní postoj autora.“* (Veselovská, 2017b, s. 87).

Bing Liu, autor mnoha publikací zabývajících se výzkumem NLP a postojovou analýzou, podává se své knize *Sentiment Analysis* tuto definici: *„Vědní obor, který analyzuje názory lidí, jejich postoje, hodnocení a emoce ve vztahu ke skupinám lidí, jednotlivcům, událostem a jejich atributům.“* (Liu, 2015, s. 1).

Pokud shrneme představené definice výše, cílem analýzy sentimentu je najít v textu subjektivní sdělení a následně určit, zda je takové prohlášení autora pozitivní, negativní či neutrální.

Analýza sentimentu jakožto oblast studia je relativně nová, prvotní vědecké články zabývajících se touto problematikou jsou publikovány na začátku 21. století (např. studie autora J. Wiebe z roku 2000 pojednávající o automatické detekci subjektivních členů v korpusu) (Liu, 2015) a jejich počet rychle roste. Dle rešeršního článku Mäntylä et al. (2018) je patrný strmý nárůst zájmu o tuto problematiku po roce 2004 a v současnosti se jedná o jednu z nejrychleji rostoucích výzkumných oblastí vůbec (Mäntylä et al., 2018). Využití tohoto oboru je totiž velmi praktické, ať už se jedná o výzkumy veřejného mínění např. v průběhu volebního období, monitoring chování uživatelů na sociálních sítích, získávání sentimentu z uživatelských recenzí určitého produktu, monitoring veřejných diskuzí pod zpravodajskými články nebo se uplatňuje v oblasti SCRM. Existují rovněž výzkumy, které využívaly analýzu sentimentu k predikci budoucího vývoje na burze, jiné práce se pokoušejí na základě hodnocení diváků nového filmu předpovědět jeho úspěch

v podobě obdrženího výdělků v kinech, nebo existují snahy detekovat skrze postojovou analýzu fake news v prostředí sociálních sítí. Dvě příkladné studie jsou blíže představeny v kapitole č. 6.8.

## 6.2 Úrovně analýzy sentimentu

Sentiment lze klasifikovat na třech základních úrovních, přičemž pro každou z nich se používají různé techniky klasifikace nebo jiné metody předzpracování textu. Tyto tři základní stupně jsou dle Liu a Zhang (2012) následující:

- **Úroveň dokumentu** (*Document Level Sentiment Classification*) – Hodnotí se celkový sentiment celého dokumentu, prakticky se používá pro analýzu uživatelských recenzí. Podmínkou je hodnocení jedné entity (např. mobilního telefonu). Na této úrovni granularity nelze hodnotit názor uživatele porovnávající různé entity (např. zmíněné mobilní telefony) v rámci jednoho review. V tomto případě je potřeba použít nižší úroveň analýzy. Obdobně se tento problém může týkat diskuzního fóra, kdy různí uživatelé mohou hodnotit různé entity.
- **Úroveň věty** (*Sentence Level Sentiment Classification*) – cílem je určit sentiment na úrovni jednotlivých vět, přičemž analýza věty jednoduché je mnohdy jednodušší nežli v případě souvětí. Na tomto stupni analýzy je rovněž výzvou správné určení subjektivity, kdy se rozlišují věty objektivní a subjektivní, přičemž objektivní věta může vyjadřovat názor a naopak. Podrobněji popsáno v kapitole č. 6.6. Proto se nejdříve hodnotí subjektivita věty a následně její sentiment.
- **Úroveň aspektu** (*Aspect Level Sentiment Classification*) – nejnižší úroveň analýzy má za úkol nalézt a určit sentiment jednotlivých aspektů entity. V případě recenze lze jinak říci, že uživatel může mít zcela rozdílné názory na jednotlivé komponenty (aspekty) jednoho mobilního telefonu (entita).

## 6.3 Formální zápis

Výsledný sentiment lze zapsat ve strukturované maticové podobě následovně:

$$(e, a, s, h, t),$$

kde  $e$  symbolizuje entitu (např. mobilní telefon),  $a$  je aspekt (např. baterie mobilního telefonu),  $s$  je sentiment,  $h$  je původce názoru (*opinion holder*) a  $t$  je čas, kdy byl názor

vyjádřen (Liu, 2015). Sentiment bývá vyjádřen dvěma způsoby. Může se jednat o kategorizaci do dvou, případně tří skupin, kde jsou aspekty nebo dokumenty klasifikovány se sentimentem pozitivním, negativním a případně neutrálním. Jiný přístup kategorizuje sentiment na bodované škále např. od jedné do pěti, kdy jeden nebo dva body symbolizují negativní sentiment, tři neutrální a čtyři až pět pozitivní (Liu, 2015). Aplikaci maticového zápisu na úrovni aspektu lze vidět pod recenzí níže.

***Autor recenze: Jan NOVÁK***

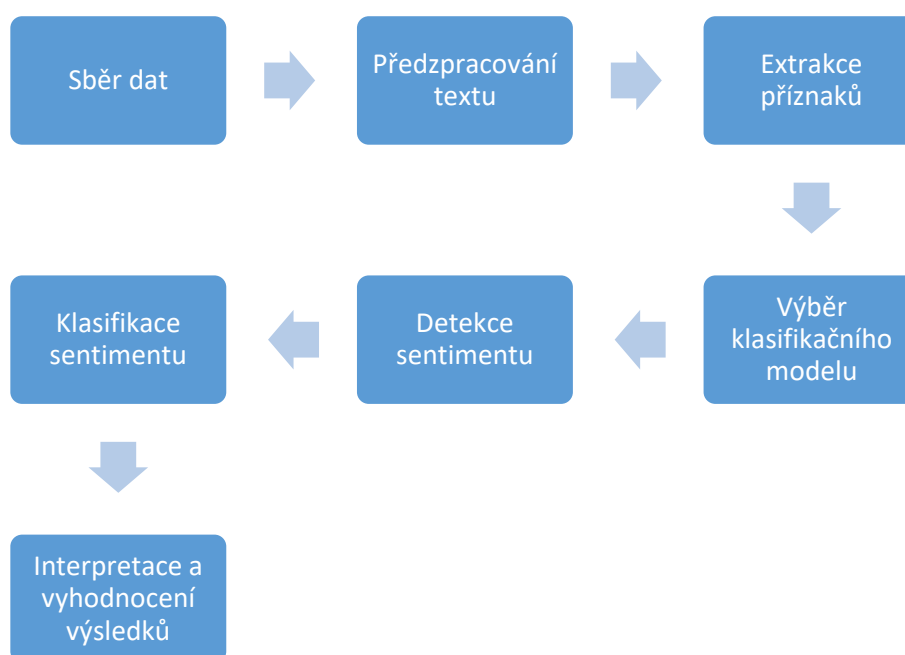
***Datum: 14. října 2018***

*Včera jsem si ve Vašem internetovém obchodě pořídil fotoaparát od výrobce Canon a můj přítel fotoaparát Samsung. Poslední týden jsme spolu pořídili spoustu fotografií, abychom mohli nakoupené zboží porovnat. Fotografie z mého kanonu nejsou za zhoršených světelných podmínek příliš kvalitní (1) a výdrž baterie není tak dlouhá (2), jak jsem si představoval. Kdežto můj přítel je se svým fotoaparátem (3) a kvalitou výsledných snímků velmi spokojen (4). Proto nejsem s výběrem Canonu spokojen (5) a budu ho zítra vracet ve Vaší prodejně.*

1. (Canon, kvalita obrazu, negativní, Jan Novák, 14. října 2018)
2. (Canon, výdrž baterie, negativní, Jan Novák, 14. října 2018)
3. (Samsung, GENERAL, pozitivní, přítel Jana Nováka, 14. října 2018)
4. (Samsung, kvalita obrazu, pozitivní, přítel Jana Nováka, 14. října 2018)
5. (Canon, GENERAL, negativní, Jan Novák, 14. října 2018)

Z matice je patrné, že v průběhu procesu analýzy sentimentu byl výraz *kanon* posouzen jako název fotoaparátu Canon nebo slovní spojení *fotografie za světelných podmínek* jako aspekt kvalita obrazu. Hledání synonym pro použité entity a aspekty je typické pro fázi předzpracování. Aspekt GENERAL v případě třetí a páté matice znamená, že není blíže specifikovaná vlastnost produktu, ale sentiment je přiřazován obecně celému fotoaparátu.

Celý proces analýzy sentimentu, tak jak jej definuje D'Andrea a kol. ve svém článku, znázorňuje obrázek č. 6.



Obrázek 6 – Proces analýzy sentimentu (zdroj: D'Andrea et al. (2015) a Liu (2015))

#### 6.4 Proces analýzy sentimentu

Po sběru dat, ať už se jedná o recenze produktu online obchodu nebo komentáře na sociálních sítích, následuje úprava textu do podoby, se kterými klasifikační modely umějí pracovat, tak jak je zmíněno v části práce věnující se text miningu. Odstraňují se stop slova, s pomocí slovníku se hledají synonyma nebo se jednotlivá slova označují slovním druhem (již zmíněný POS tagging). Některé sekvence slovních druhů totiž mohou naznačovat přítomnost sentimentu (např. kombinace příslovce, přídavné a podstatné jméno). Všechny tyto operace mají za cíl zefektivnit práci vybraného klasifikačního modelu při stejné kvalitě dosažených výsledků.

Do níže zmíněných klasifikačních modelů (především těch, které jsou založeny na strojovém učení) vstupují n-gramy nebo POS taggy formou tzv. příznaků (angl. features), které Vapnik (2006) definuje jako: „*Základní části důkazů, které spojují dokument  $d$  s třídou  $c$ , kterou se snažíme určit.*“ Tyto příznaky jsou reprezentovány vektorem (tzv. vektorová reprezentace textu naznačená v kapitole č. 5.3.2 o transformaci textu), přičemž pro úspěšnou klasifikaci se vychází z předpokladu, že pro každou třídu sentimentu (např. pozitivní) jsou příznakové vektory z určitého úhlu pohledu podobné. Tyto příznakové vektory ale mohou



být příliš velké, což způsobuje vysokou výpočetní náročnost. Proto se před samotnou klasifikací využívají algoritmy selekce příznaků, které mají za úkol redukovat dimenze vektorových prostorů (Sychra, 2016). Algoritmy selekce příznaků blíže popisuje např. Agarwal (2019). Porovnání algoritmů se Agarwal a Mittal (2013) rovněž věnují ve své výzkumné práci.

Klasifikační algoritmy sloužící pro analýzu sentimentu, které rozdělují vstupní data do několika výstupních tříd dle přiřazeného sentimentu, dělí D'Andrea a kol. do tří základních skupin:

- **Algoritmy strojového učení** (*Machine learning algorithms*) – do této skupiny spadají tzv. *algoritmy učení s učitelem (supervised algorithms)*, kdy jsou klasifikátoru předána tzv. anotovaná data (například unigramy s přiřazeným sentimentem). S pomocí dat, která předem určují správný výsledek, se klasifikátor učí zařazovat neanotovaná data do správné třídy. Metodou křížové validace lze určit úspěšnost algoritmu. Do této skupiny algoritmů patří např. Naivní Bayesův klasifikátor, metoda SVM (*Support Vector Machines*) nebo metoda maximální entropie. Výhodou této skupiny algoritmů je doménová nezávislost, to znamená, že jeden a tentýž algoritmus lze použít na dokument obsahující recenze filmů nebo s jeho pomocí detekovat sentiment v politické diskuzi (D'Andrea et al., 2015).
- **Slovníkové metody** (*Lexicon based methods*) – metoda založená na použití klíčových slov, která jsou obsažena ve slovníku spolu s jejich sentimentem a dalšími informacemi (podrobněji obr. č. 7). Algoritmus pak slovo po slově ze zdrojového dokumentu hledá v použitém slovníku a přiřazuje jim sentiment. Výsledný sentiment celého dokumentu je sumou sentimentů dílčích slov (Liu, 2015). Kvalita výsledků je velmi ovlivněna výběrem slovníku, jelikož sentiment jednotlivých slov může z velké části záviset na doméně (např. výraz *tichý* má pozitivní příznak v případě, kdy se hovoří o vysavači, naopak negativní v případě budíku). Proto vedle obecných slovníků jako WordNet, SentiWordNet nebo MPQA existují slovníky se zaměřením např. na finanční odvětví (Loughran and McDonald Financial sentiment dictionary). Pro analýzu sentimentu českých textů lze použít např. Czech SubLex 1.0 od Veselovské a Bojara (2013), který obsahuje 4 626 termů. Vedle použití již existujících slovníků existuje varianta vytvoření vlastního doménového slovníku z již existujícího, kdy se iterativně hledají v textu synonyma a antonyma a s určenou

polaritou sentimentu se ukládají do slovníku. Nově se lze setkat i se slovníky emotikonů (např. práce Kralj-Novak a kol. (2015)) a sarkasmů (např. Joshi a kol. (2017)).

- **Hybridní metody** (*Hybrid methods*) – kombinují oba výše zmíněné přístupy.

	Strength	Length	Word	Part-of-speech	Stemmed	Polarity
1.	type=weaksubj	len=1	word1=abandoned	pos1=adj	stemmed1=n	priorpolarity=negative
2.	type=weaksubj	len=1	word1=abandonment	pos1=noun	stemmed1=n	priorpolarity=negative
3.	type=weaksubj	len=1	word1=abandon	pos1=verb	stemmed1=y	priorpolarity=negative
4.	type=strongsubj	len=1	word1=abase	pos1=verb	stemmed1=y	priorpolarity=negative
5.	type=strongsubj	len=1	word1=abacement	pos1=anypos	stemmed1=y	priorpolarity=negative
6.	type=strongsubj	len=1	word1=abash	pos1=verb	stemmed1=y	priorpolarity=negative
7.	type=weaksubj	len=1	word1=abate	pos1=verb	stemmed1=y	priorpolarity=negative
8.	type=weaksubj	len=1	word1=abdicate	pos1=verb	stemmed1=y	priorpolarity=negative
9.	type=strongsubj	len=1	word1=aberration	pos1=adj	stemmed1=n	priorpolarity=negative
10.	type=strongsubj	len=1	word1=aberration	pos1=noun	stemmed1=n	priorpolarity=negative
...						
8221.	type=strongsubj	len=1	word1=zest	pos1=noun	stemmed1=n	priorpolarity=positive

Obrázek 7 – Fragment MPQA slovníku (zdroj: Potts (2011))

Na obr. č. 7 se nachází fragment MPQA slovníku, který kromě sentimentu nese informaci o slovním druhu, zda je uvedené slovo v základním tvaru (tzv. stem) nebo obsahuje informaci o subjektivitě daného termu (Potts, 2011).

## 6.5 Přesnost klasifikace

Výsledná přesnost klasifikačního algoritmu závisí vedle již zmíněné přesnosti a obsáhlosti slovníku také na využitých metodách předzpracování nebo na kvalitě trénovacích dat a výběru trénovací množiny v případě využití supervizovaných algoritmů strojového učení. Dle shrnutí Petrovského (2016) dosahují algoritmy strojového učení přesnosti přesahující 80% hranici. Patočka (2013) ve své práci zkoumá vliv předzpracování textu na výslednou přesnost klasifikátoru. Pro výsledek jeho klasifikátoru mělo největší vliv odstranění stopslov a slov s nízkou četností. Jako nejpřesnější klasifikátor byl v jeho práci vyhodnocen SVM, nicméně při vyšším množství vstupních dat neúměrně roste jeho výpočetní doba. Z pohledu kvality a časové náročnosti je tak nejlepší použít metodu maximální entropie. Nicméně i zde je potřeba brát v úvahu povahu vstupních dat (ať už jde o hodnocené recenze tak použitou trénovací množinu). Dle Liu (2015) je jednodušší analýza postů na sociální síti Twitter oproti klasifikaci internetových diskuzí, jelikož příspěvky

na sociální síti jsou kratší a lépe vystihují cíl sdělení. Diskuze naproti tomu mohou obsahovat více tzv. informačního šumu.

## 6.6 Problematika analýzy sentimentu

Přesnost klasifikačních algoritmů postojové analýzy není 100%. Důvodem jsou jednak faktory popsané výše, nicméně problematika korektní klasifikace s sebou nese i mnoho dalších řešených otázek. V oblasti strojového učení je pochopení těchto problémů velikou výzvou do budoucna.

Na úrovni vět a entit bývá problematická tzv. klasifikace subjektivity (na obr. č. 6 se jedná o fázi detekce sentimentu). Cílem je určit, zda věta, nebo entita vyjadřuje nějaký sentiment bez ohledu na to, zda je pozitivní nebo negativní. Ve většině případech nejprve dochází k detekci objektivních částí textu a k jejich následnému odstranění. K tomuto účelu se využívají některé algoritmy učení s učitelem. Např. Riloff a kol. (2003) s pomocí Naivního Bayesova klasifikátoru a metody bootstrap klasifikoval subjektivitu 2 200 větných celků s přesností 80 %. Ne vždy ale subjektivní slovní spojení vyjadřuje sentiment a objektivní nikoliv. Příkladem je věta: „*Měl bych si pořídit novou kameru.*“ Prohlášení obsahuje subjektivní dojem autora, nedá se ale s jistotou říci, že vyjadřuje negativní sentiment. Ostatně modální slovesa a podmiňovací způsob činí klasifikačním algoritmům potíže (Liu, 2015).

Negace je v postojové analýze rovněž problematická. S jistými výrazy, jako jsou např. *nikdy*, *nikdo*, *nikoliv*, *nic* umějí slovníkové metody pracovat a spolehlivě detekovat (viz obr. č. 8), existují ale situace, kdy k obratu polarity hodnocení nemusí nutně dojít. Příkladem může být věta: „*To opravdu není špatné.*“ Dvojitá negace může činit potíže i v případě věty: „*Není to žádný luxusní model.*“

Výskyt projevů ironie a sarkasmu, na který lze narazit např. v politických článcích nebo internetových diskuzích, činil klasifikátorům také nemalé potíže. Např. práce González-Ibáñez a kol. (2011), která se zabývala odhalováním sarkasmu na Twitteru, zaznamenala přesnost klasifikace 57 %. Pro porovnání, člověk úspěšně označil jízlivý jev v 68 % případů. S nástupem lexikonů sarkasmu, lepší detekce emotikonů, které mohou ironii rovněž symbolizovat a pokročilejších algoritmů strojového učení lze tyto jevy lépe odhalit. Studie Singha (2019) zaznamenala přesnost téměř 84 % za použití metody lineárních podpůrných vektorů (SVM).

Jinou výzvu představují některé větné členy, jako např. spojka *ale*, která může oddělovat dvě věty v souvětí, které jsou vůči sobě v různém lingvistickém poměru. Příkladem je odporovací poměr ve větě: „*Kvalita fotoaparátu je výborná, ale výdrž baterie je nízká.*“ V jiném případě se může jednat o poměr stupňovací: „*Nejenže je kvalita fotoaparátu výborná, ale dokonce i baterie má dlouhou výdrž.*“ (Liu, 2015).

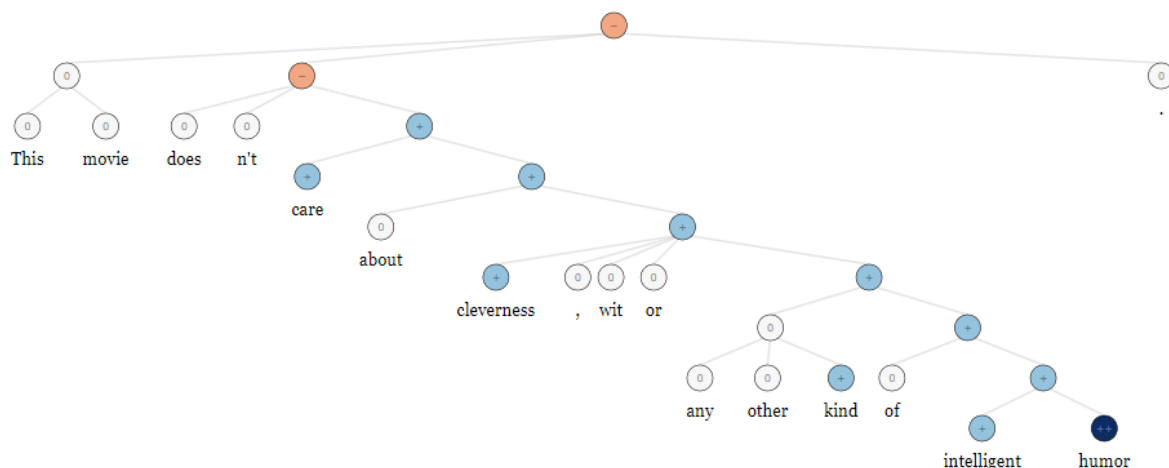
Lingvistické intenzifikátory, tedy prostředky zesilující platnost tvrzení (výrazy jako např. *strašně, hrozně, pěkně*), činí klasifikátorům potíže stejně tak jako idiomy. V případě hledání ustálených výrazů lze využít např. slovník českých idiomů, pro pozdravy (*Dobrý den, S přáním krásného dne*) nebo pojmenované entity se sentimentem (jako např. *Pretty Woman*) lze rovněž využít automatickou detekci za pomoci slovníků (Veselovská, 2017b).

## 6.7 Analýza sentimentu a jiné jazyky

Většina prací zabývající se analýzou sentimentu pracuje s anglickými zdrojovými texty a slovníky. Práce s jinými jazyky tak může být značně omezená. Ať už se jedná o konkrétní jazykovou verzi softwaru zajišťující stematizaci slov nebo dostupné slovníky sentimentu. Překlad z jednoho jazyka do druhého je tak v tomto případě nezbytný. V současné době jsou dle Liu (2015) nejrozšířenější dva přístupy:

- Překlad hrubého zdrojového textu např. do angličtiny a následné předzpracování a klasifikace za použití nástrojů podporující angličtinu.
- Překlad slovníků nebo trénovacích korpusů do požadovaného jazyka (např. za pomoci translátorů) a následná klasifikace (ať už slovníkovou metodou nebo algoritmem strojového učení). Tvorbě slovníků sentimentu napříč různými jazyky se věnuje např. Steinberger a kol. (2012).

Pro práci s českým zdrojovým textem lze využít slovníky a nástroje, které jsou pro práci s tímto jazykem přizpůsobené. Např. již zmíněný slovník od Veselovské a Bojara (2013), který obsahuje více než čtyři a půl tisíce výrazů s přiřazeným sentimentem. V procesu předzpracování českého textu lze využít Czech Model of High Precision Stemmer od autorů Brychcín a Konopík (2015), Veselovská (2017b) zmiňuje využití českého part-of-speech taggeru Morče nebo Pražského závislostního korpusu (PDT 3.0) v procesu lematizace.



Obrázek 8 – Stromová struktura rozboru věty (zdroj: *The Stanford Natural Language Processing Group (2013)*)

Na obr. č. 8 se nachází ukázka rozboru sentimentu vyjádřen ve stromové struktuře za použití slovníkové metody. Celkový sentiment věty je díky přítomnosti záporu negativní. Převzato z The Stanford Natural Language Processing Group (2013).

## 6.8 Případové studie

Dvě případové studie blíže popisují praktické využití analýzy sentimentu. První pochází z českého prostředí a věnuje se mediálnímu obrazu prezidentské volby, druhá pak sleduje vztah sentimentu a nálad příspěvků na sociálních sítích s vývojem na americké burze.

### 6.8.1 Sentiment analýza médií

Autorky Radka Malik a Hana Pavlasová použily slovníkovou metodu, aby analyzovaly sentiment článků týkající se celkem devíti prezidentských kandidátů v období druhé přímé volby prezidenta, tedy na přelomu roku 2017 a 2018. Celkem analyzovaly 1 010 článků z pěti českých zpravodajských serverů, které dle projektu NetMonitoru patří k nejčtenějším (NetMonitor, 2019). Původní záměr počítal rovněž s analýzou diskuzí pod články, z časových důvodů bylo od tohoto cíle opuštěno.

V první fázi projektu byla stažena data a to za pomoci skriptu v jazyce Python. Jako relevantní identifikátor byl využit HTML tag *keywords*, který mj. obsahuje jména prezidentských kandidátů. Ze stažených článků ve formátu *json* byly vybrány titulky, jejichž slova posloužila pro tvorbu vlastního slovníku. Celkem 5 724 slov bylo manuálně ohodnoceno z hlediska sentimentu na škále od -2 (velmi negativní) po +2 (velmi pozitivní). K hodnocení některých výrazů využily autorky Czech Subjectivity Lexicon od Veselovské.

Samotné články pak prošly fází předzpracování. Byly odstraněny spojky a předložky. Stemmer pro český jazyk konvertoval slova do základního tvaru. Skript autorek v Pythonu následně jednotlivým slovům přiřadil sentiment na základě manuálně vytvořeného slovníku z titulků. Pro vizualizaci výsledků byl využit nástroj PowerBI.

Z prezentovaných výsledků lze vyčíst informace o tom, kterému prezidentskému kandidátovi bylo věnováno nejvíce mediálního prostoru, které servery o průběhu kampaně informovaly nejvíce a v jakém sentimentu s ohledem na každého kandidáta. Výsledky tak poukazují na (ne)vyváženost jednotlivých informačních webů co se sentimentu a prezentace kandidátů týká. Lze dodat, že sentiment titulků byl v celkové míře negativní. Autorky se přiklánějí k závěrům, že negativně laděný nadpis článku spíše přiměje čtenáře k jeho přečtení.

Autorky považují cíl práce za splněný, nicméně připouštějí možné alternativy zpracování především z hlediska použitého manuálně vytvořeného slovníku (Malik & Pavlasová, 2018). V tomto případě se nabízí možnost využití již existujících doménových slovníků, nebo jejich dodatečné rozšíření.

#### 6.8.2 Predikce vývoje na burze na základě analyzovaných tweetů

Tým autorů z americké univerzity Bloomington vydal v roce 2010 článek, ve kterém shrnují svoji práci zaměřenou na predikci vývoje na americké burze Dow Jones na základě analyzovaných tweetů ze sociální sítě.

Zdrojem se staly příspěvky na Twitteru, celkem téměř 10 milionů, které po celý rok 2008 publikovalo asi 2,7 milionu uživatelů. K měření nálady použily dva nástroje – OpinionFinder, který s pomocí slovníku obsahující téměř 7 000 termů určí výsledný sentiment tweetu (pozitivní, negativní) a Google-Profile of Mood State (GPOMS), který na základě doménového slovníku obsahujícího téměř 1 000 termů, klasifikuje náladu uživatele do jedné ze 6 tříd (šťastný, znepokojený, sebejistý apod.). Tvorbě druhého použitého nástroje a slovníku pak předcházela celá řada výzkumů v oblasti psychologie.

V první fázi výzkumu se autoři zabývali tím, zda měřený sentiment příspěvků na sociální síti skutečně odráží veřejné události. Tuto hypotézu se podařilo prokázat, např. příspěvky spadající do kategorie šťastný (na základě modelu GPOMS) se daleko častěji vyskytovaly v Den díkůvzdání, naopak příspěvky spadající do třídy neklidných se objevovaly těsně před americkými prezidentskými volbami v listopadu roku 2008.

Za pomoci Grangerova testu kauzality se snažili prokázat korelaci mezi náladou příspěvků a hodnotou indexu Dow Jones. Tento vztah se na určité hladině významnosti

podařilo prokázat pouze pro příspěvky, které byly zařazeny do skupiny *klidných (Calm)*. Jak ostatní kategorie nálad, tak výsledky z nástroje OpinionFinder, neprokázaly signifikantní závislost.

Součástí práce je poslední fáze, která se zabývá tvorbou prediktivního modelu vývoje na americké burze, který vycházel z výše uvedených vstupních dat (sentiment příspěvků spolu s hodnotou indexu v posledních třech dnech). Test na reálných datech poukázal na jistou úspěšnost. Při vhodném nastavení vstupních parametrů dokázal model (tzv. *A SelfOrganizing Fuzzy Neural Network Model*) správně předpovědět hodnotu indexu v 80 % případů (Bollen et al., 2011).

# PRAKTICKÁ ČÁST



## 7 Metodika zpracování

### 7.1 Výzkumný vzorek

Americký podnik S&P Global analyzující globální finanční trh každoročně publikuje žebříček stovky celosvětově největších bankovních institucí z hlediska disponujících aktiv. Tento report, který je součástí přílohy č. 1, se stal hlavním zdrojem pro finální výběr reprezentující výzkumný vzorek. Pro zahrnutí do výzkumu online komunikace bankovních institucí na sociální síti Facebook musela každá banka splňovat následující předpoklady:

- **Ověřený profil na sociální síti Facebook** – banka musí mít pro komunikační aktivity založený oficiální profil na Facebooku, který je ověřený. Štítek s ověřením informuje návštěvu profilu o tom, že Facebook ověřil autentičnost známého člověka, společnosti nebo značky a lze ho tedy považovat za důvěryhodný (Facebook – Centrum nápovědy, 2020). Finančnímu žebříčku dominují čínské banky (celkem 19). Ty však nemohou využívat služeb Facebooku, Instagramu nebo WhatsAppu, jelikož jsou tyto sociální sítě z politických důvodů v pevninské Číně zakázané (Sedlák, 2017). Facebook pro komunikaci rovněž nevyužívají některé japonské či jihokorejské banky. Jak je zmíněno v teoretické části, bankovní skupina UniCredit ukončila své působení na Facebooku v průběhu roku 2019 (Kučera, 2019). Celkem 10 bank pak disponuje založeným profilem, který je neověřený. Ve výsledku tak splňuje první předpoklad 64 finančních institucí, přičemž 39 z nich komunikuje převážně v angličtině.
- **Obsluha retailového segmentu** – aby byla komunikace cílena na relevantní publikum, v tomto případě tedy na samotné uživatele sociální sítě, a nikoliv jen korporáty nebo jiné banky, musí banka obsluhovat retailový segment, který je definován v kapitole 2.1. O tom, zda banka splňuje toto výběrové kritérium, bylo rozhodnuto na základě informací zveřejněných na oficiálních webových stránkách případně pak ve výročních zprávách. Druhý předpoklad splňovalo 62 ze 64 institucí.
- **Minimální počet zveřejněných příspěvků** – aby byl výzkum podložen relevantními daty, bylo nutné vybrat jen ty banky, které v průběhu zkoumaného období, tedy celého roku 2019, publikovaly alespoň 20 příspěvků. Z tohoto důvodu se do finálního výběru nedostaly instituce jako HSBC, OCBC Bank Singapore nebo Barclays.

Ze seznamu bank, které splňují předpoklady výše, byl vybrán výzkumný vzorek reprezentován 20 bankovními institucemi, které disponují největší fanouškovskou základnou. Finální výběr je představen v tabulce č. 3.

Název banky	Sídlo (stát)	Počet fanoušků na Facebooku*	Jazyk stránek
<b>State Bank of India</b>	Indie	18 137	angličtina / hindština
<b>Itaú Unibanco Holding SA</b>	Brazílie	9 287	portugalština
<b>Banco Bilbao Vizcaya Argentaria SA</b>	Španělsko	5 560	španělština / angličtina
<b>Banco Bradesco SA</b>	Brazílie	5 150	portugalština
<b>Capital One Financial Corp.</b>	USA	4 209	angličtina
<b>Caixa Econômica Federal</b>	Brazílie	3 254	portugalština
<b>Banco do Brasil SA</b>	Brazílie	3 029	portugalština
<b>Bank of America Corp.</b>	USA	2 847	angličtina
<b>Citigroup Inc.</b>	USA	1 194	angličtina
<b>Wells Fargo &amp; Co.</b>	USA	1 096	angličtina
<b>Shinhan Financial Group Co. Ltd.</b>	Jižní Korea	1 044	korejština
<b>United Overseas Bank Ltd.</b>	Singapur	941	angličtina
<b>DBS Group Holdings Ltd.</b>	Singapur	915	angličtina
<b>Société Générale SA</b>	Francie	789	angličtina / francouzština
<b>Bank of Nova Scotia</b>	Kanada	786	angličtina
<b>Commonwealth Bank of Australia</b>	Austrálie	759	angličtina
<b>KB Financial Group Inc.</b>	Jižní Korea	608	korejština
<b>Royal Bank of Canada</b>	Kanada	564	angličtina
<b>Intesa Sanpaolo SpA</b>	Itálie	465	angličtina
<b>PAO Sberbank of Russia</b>	Rusko	435	ruština

\*v tisících, aktuální k 1. 2. 2020

*Tabulka 3 – Finální výběr bankovních institucí (zdroj: Oficiální profily na Facebooku)*

## 7.2 Výzkumné otázky

Na základě rešerše z dostupné literatury a praktických potřeb bankovních institucí byly formulovány následující výzkumné otázky:

### **VO1: Jaký je charakter příspěvků bankovních institucí?**

- a) Jaké typy příspěvků banky prezentují?
- b) Co je obsahem příspěvků?
- c) Jaká je hladina sentimentu v příspěvcích?
- d) Existuje korelace mezi sentimentem příspěvku a interakcemi uživatelů?

### **VO2: Jaký je charakter komentářů uživatelů na příspěvky?**

- a) Jaká je hladina sentimentu v komentáři uživatelů?
- b) Liší se sentiment komentářů mezi příspěvky s různým obsahem?
- c) Existuje korelace mezi sentimentem příspěvku a sentimentem komentářů?
- d) Existuje korelace mezi NPS banky a hladinou sentimentu v komentářích uživatelů?

### **VO3: Jaký je charakter odpovědí bank na komentáře uživatelů?**

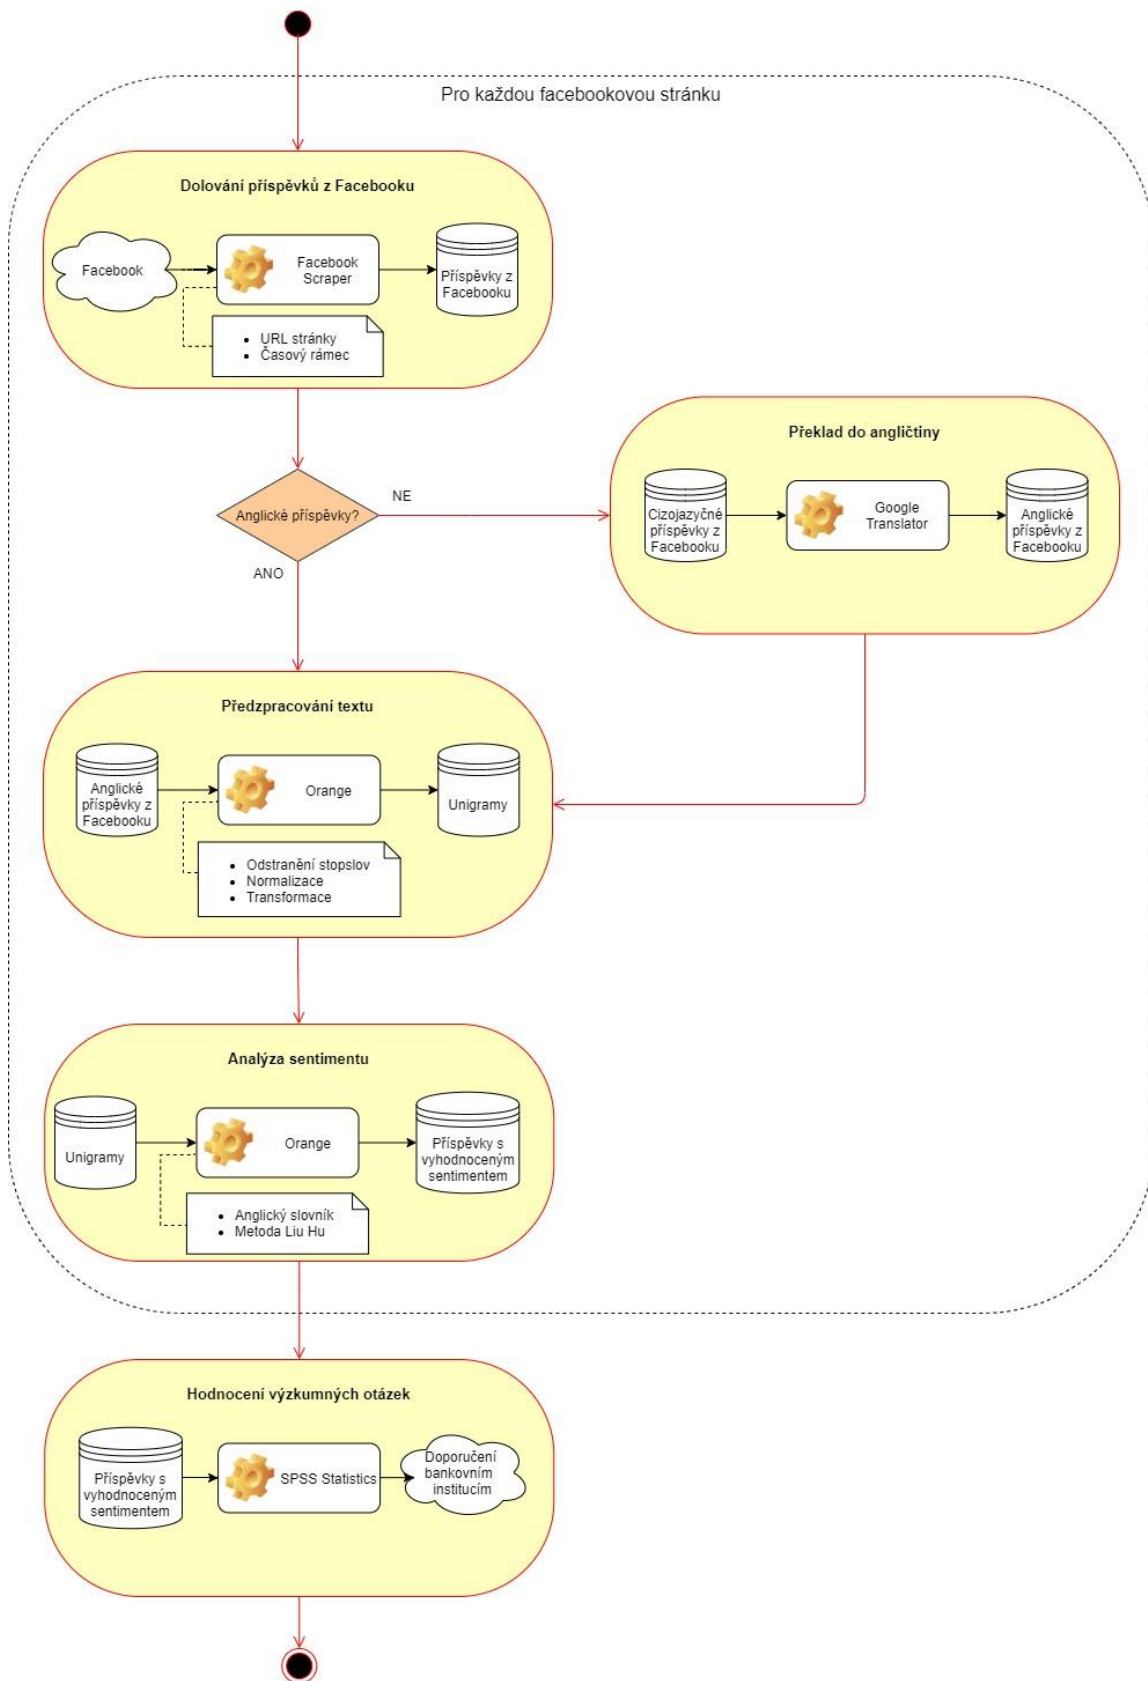
- a) Jak často a jak rychle banky reagují na komentář uživatele?
- b) Jaký sentiment používají banky v komunikaci s uživatelem?
- c) Existuje závislost mezi sentimentem komentáře a rozhodnutím banky odpovědět na komentář?
- d) Existuje korelace mezi sentimentem komentáře uživatele a sentimentem odpovědí banky?

## 7.3 Výzkumné metody

Pro výzkumné otázky je uplatněna jak metoda datové a obsahové analýzy facebookých stránek bankovních institucí, tak metoda analýzy sentimentu, která je blíže specifikována v následující kapitole zaměřené na se sběr a zpracování dat. Teoretickým aspektům postojové analýzy se věnuje kapitola č. 6.

## 7.4 Sběr a zpracování dat

Jelikož byla data získávána a zpracovávána různým způsobem, je tato kapitola rozdělena do několika celků na základě toho, k jakým účelům byla data získávána. Pro lepší pochopení sběru a zpracování dat pro analýzu sentimentu poslouží názorné schéma na obrázku č. 9.



Obrázek 9 – Schéma sběru a zpracování dat pro analýzu sentimentu příspěvků (zdroj: Vlastní zpracování)

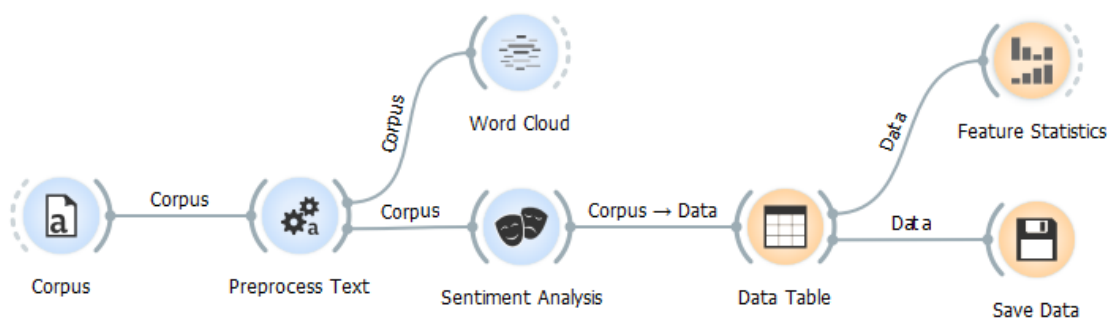
#### 7.4.1 Data pro analýzu sentimentu příspěvků

První částí schématu je **dolování příspěvků z Facebooku**. Data, tedy jednotlivé příspěvky na facebookových stránkách bank, jsou pro vypracování práce naprosto nezbytná. Původní záměr počítal s využitím Graph API, facebookového API, na který se lze napojit a dotazovat se na různá data zahrnující uživatele, stránky nebo příspěvky. Po skandálu Cambridge Analytica v roce 2018 vyšlo najevo, že firma využívala citlivá data desítek miliónů uživatelů sociální sítě Facebook v rámci volebních kampaní po celém světě. Vedení sociální sítě muselo zakročit a zpřísnilo mimo jiné pravidla pro používání facebookových API nástrojů. V souvislosti s těmito opatřeními je potřeba dodržovat mnoho pravidel a vystavit oficiální žádost s odůvodněním a uvedenými úmysly, které jsou spojené s nakládáním uživatelských dat (Hubbel, 2018). Z tohoto důvodu se autor práce rozhodl použít pro získání důležitých dat skript vytvořený v programu Python. Autor práce si skript upravil tak, že na vstupu je uveden seznam URL adres facebookových stránek, ze kterých budou data čerpána a dále je zadáno datum v minulosti, do kterého má algoritmus pro každou stránku na vstupu dohledávat příspěvky. Facebook Scraper, jak zní oficiální název stěžejní knihovny v Pythonu, ve výsledku pro každou stránku banky na sociální síti vytvořil excelovský dokument obsahující všechny zveřejněné příspěvky za rok 2019. Pro každý post banky je tak možné zjistit počet liků, komentářů nebo sdílení. Tato data prakticky reflektují stav produkce k 1. 2. 2020 kdy byla data shromážděna, jelikož k obnově dat automaticky nedochází. Excelovská tabulka dále obsahuje informace o tom, kdy byl příspěvek zveřejněn, jeho celý obsah včetně zachovaných emotikonů a jiných značek a také zaznamenává přesnou URL adresu každého příspěvku. Celkem bylo tímto způsobem získáno 4 814 příspěvků 20 bankovních institucí publikovaných v rozmezí 1. ledna 2019 až 31. prosince 2019, které byly podrobeny další analýze. U 4 666 příspěvků bylo možné určit sentiment. U 148 nikoliv, jelikož posty neobsahovaly žádný text. Extrakt naopak nezahrnuje obsah komentářů uživatelů nebo typ příspěvku, tedy zda se např. jedná o textový příspěvek doplněný videem či fotografií. Detailnější popis extrahování těchto informací je zachycen v dalších odstavcích níže.

Po získání dat následoval **překlad do angličtiny**. Z tabulky č. 3 je patrné, že jihokorejské nebo brazilské banky nepublikují obsah v anglickém jazyce a jiné finanční instituce komunikují i dvoujazyčně. Jelikož ale byla provedena analýza sentimentu založená na anglickém slovníku, bylo nutné všechny tyto příspěvky přeložit do angličtiny. K tomuto účelu byl využit překladač od Googlu, který od roku 2017 překládá texty výrazně lépe díky

využívání neuronových sítí. S jistou chybovostí je ale potřeba nadále počítat (Kasík & Lázňovský, 2017). Výhodou Google překladače je také možnost překladu celého souboru např. ve formátu pdf nebo xlsx. Celkem byla tímto způsobem přeložena polovina facebookových stránek.

Pro fázi **předzpracování textu** a analýzy sentimentu posloužil open-source software Orange vyvíjený na univerzitě ve slovinské Lublani. Pro účely diplomové práce bylo nutné doinstalovat extenzi pro textovou analýzu. Programové rozšíření bohužel z technických důvodů nebylo možné nainstalovat na nejnovější verzi programu (3.24), proto byly všechny analýzy provedeny v Orange verze 3.21. Na obr. č. 10 se nachází workflow sestavené v programu, které schematicky popisuje postup práce a zobrazuje jednotlivé použité komponenty.



Obrázek 10 – Schéma využitých komponent v programu Orange (zdroj: Vlastní zpracování)

Komponenta *Corpus* slouží k nahrání textového dokumentu (v tomto případě excelovské tabulky), kde se vybírají relevantní data pro následující zpracování. Text komentářů byl následně předzpracován, konkrétně jednotně transformován do minuskule, proběhla stematizace a byla odfiltrována anglická stopslova. Komponenta *Word Cloud* vizualizuje četnost unigramů v dokumentu. Vizualizace komponenty je vidět na obr. níže.



Obrázek 11 – Ukázka komponenty Word Cloud v programu Orange (zdroj: Vlastní zpracování)

Pro **analýzu sentimentu** lze vybrat ze dvou slovníkových modelů pracujících s anglickým jazykem – Liu Hu nebo Vader. První zmíněná metoda spočítá normalizovanou hodnotu sentimentu, přičemž pro kladné hodnoty je sentiment pozitivní, pro nulové výsledky je sentiment neutrální a pro záporné hodnoty záporný. Druhá technika hodnotí skóre pro všechny kategorie (pozitivní, neutrální, negativní) a navíc přidává i výslednou hodnotu (Pretnar, 2017). Pro potřeby analýzy sentimentu komunikace bankovních institucí byl nakonec vybrán první model. Sentiment byl tedy analyzován na úrovni celých příspěvků. Aby bylo možné zjistit průměrnou hodnotu sentimentu za celý dokument reprezentující komunikaci jedné banky, byla využita komponenta *Feature Statistics*. Data byla následně uložena do excelovské tabulky.

#### 7.4.2 Data pro analýzu sentimentu komentářů a reakcí banky

Jak je zmíněno v kapitole výše, skript pro automatické ukládání příspěvků nevrací obsah komentářů uživatelů a reakce banky. Nabízela se tedy možnost využití webových nástrojů pro dolování informací (tzv. Scraping Tools). Pro tento účel byl otestován volně dostupný ParseHub, který ovšem nespĺňoval autora očekávání. Navíc nástroje pro efektivní fungování potřebují vyšší výpočetní výkon. Z tohoto důvodu bylo nutné komentáře extrahovat ručně. Za každou banku bylo náhodně vybráno 5 příspěvků, kde se vyskytovalo alespoň 10 komentářů uživatelů. Pokud tedy data byla dostupná v požadované kvantitě, bylo za každou banku uloženo celkem 50 uživatelských komentářů první (nejvyšší) úrovně, což značí přímou reakci na publikovaný příspěvek, a nikoliv na jiný komentář. Na uživatelské komentáře byly ve vláknech hledány prvotní reakce banky. Pokud banka zareagovala, byl uložen obsah odpovědi a vypočtena celková doba, za jak dlouho banka

stihla odpovědět. Reakce uživatelů a banky byly následně analyzovány obdobně jako příspěvky na sociální síti (viz výše). Pokud se jednalo o jiný než anglický text, byl za pomoci Google překladače přeložen. Data tedy slouží pro zjištění sentimentu komentářů a výpočtu míry reakce banky na příspěvky uživatelů spolu s časovou prodlevou. Celkem bylo touto cestou extrahováno 751 uživatelských komentářů a 357 reakcí banky. 751 komentářů je součástí 85 vybraných příspěvků napříč všemi bankami. Hladina sentimentu uživatelských komentářů za jeden příspěvek byla tedy průměrována.

#### 7.4.3 Data pro analýzu typu příspěvku a typu publikovaného obsahu

Ručně byl rovněž určen typ příspěvku a typ publikovaného obsahu. Typem příspěvku na Facebooku se rozumí textový příspěvek, fotografie, video, odkaz, událost nebo anketa. Fotografie nebo např. anketa bývá doplněna samotným textovým sdělením. Publikovaný obsah lze rozřadit do jedné z pěti kategorií na základě jeho typu. Tím může být obsah zaměřený na komunikaci a marketing, příspěvky vyzývající ke spolupráci uživatele sociální sítě, vzdělávací příspěvky, zábavné příspěvky a příspěvky prezentující společenskou odpovědnost firmy (CSR). Tyto kategorie definují ve své publikaci např. Safko & Brake (2009) a nazývají je pilíři komunikace na sociálních sítích. Podle autorů je důležité věnovat pozornost všem pilířům bez rozdílu. Jelikož jsou tato data extrahována ručně, byl pro každou banku vybrán vzorek 10 % publikovaných příspěvků v roce 2019. Pokud instituce v daném roce zveřejnila méně než 200 postů, pak jich bylo vybráno 20 z důvodu zachování relevance výsledků. Celkem bylo do dvou kategorií rozřazeno 586 náhodně vybraných příspěvků.

#### 7.4.4 Ostatní data

Pro zjištění NPS banky byly využity oficiální stránky finanční instituce, případně pak výroční zprávy s novějším datem publikování.

Pro každou facebookovou stránku byly rovněž spočteny statistiky jako průměrný počet *To se mi líbí* na příspěvek, počet uživatelských komentářů na příspěvek nebo jsou pro každou banku uvedeny tři nejčastěji používaná slova v příspěvcích, která byla zjištěna za pomoci programu Orange.

Pro statistické vyhodnocení byl využit program SPSS Statistics verze 26 v kooperaci s programem Statistica. Jiné operace nad daty probíhaly v MS Excel.



## 8 Výsledky

Výsledky jsou členěny do dvou částí. V první je ve stručnosti slovně popsána marketingová online komunikace všech zkoumaných bank na sociální síti Facebook. Ve druhé části jsou prezentovány výsledky výzkumných otázek. Podrobnější výsledky v tabulkové podobě jsou sumarizovány v příloze práce.

### 8.1 Komunikace bankovních institucí na sociální síti Facebook

Bankou s největší základnou fanoušků ve výběru je **State Bank of India**, která jich k začátku února 2020 evidovala přes 18 milionů. Správci komunikace zároveň publikovaly nejvíce příspěvků za rok 2019 – celkem 687. Banka, komunikující na oficiálním kanálu v angličtině a výjimečně i v hindštině, se zaměřuje především na prezentaci bankovních produktů přes nápadité infografiky. Banka také prostřednictvím kampaně s názvem *Breathe Clean With SBI* klade důraz na zdravé životní prostředí v Indii a sponzoruje výzkum a vývoj v tomto odvětví. Celkem je tak evidováno 10 příspěvků v kategorii společenské odpovědnosti. Administrátoři reagovali jen ve 12 % případů, navíc s velkou prodlevou – průměrná doba odpovědi je 53 hodin.

Brazilská banka **Itaú Unibanco** ve svých příspěvcích požívá funkci #PraCegoVer, která slouží k textovému popisu fotografie nebo popisuje dění na videu. Funkce slouží především pro nevidomé, kteří si popis mohou přehrát v audio podobě. Banka skrze videa představuje transparentní bankovníctví bez byrokracie, připomíná prevenci v oblasti zacházení s citlivými údaji (PIN, údaje karty apod.) nebo propaguje brazilské kulturní akce, které hojně sponzoruje. 67 % příspěvků bylo vyhodnoceno jako pozitivních, ve 42 % případů uživatelé reagovali kladně. Banka na komentáře uživatelů Facebooku odpovídala výrazně častěji a rychleji než indický konkurent.

Druhá největší španělská finanční instituce dle aktiv **Banco Bilbao Vizcaya Argentaria** (BBVA) se hojně prezentuje videopříspěvků s vrcholnými představiteli banky a angažovanými influencery. Dle komunikace klade důraz rovněž na finanční gramotnost a prezentuje své investiční aktivity v rozvojových zemích. Banka, která v období roku publikovala druhý nejvyšší počet příspěvků ze sledovaných stránek (celkem 645), se i přes své aktivity na Facebooku potýká s nízkou reakcí obecnstva. Průměrný počet *To se mi líbí* na publikovaný post je 12, průměrný počet komentářů je 2,2. V porovnání s konkurenty se jedná o podprůměrný výsledek. Z tohoto důvodu nejsou známy informace o zapojení správců stránek do diskuze v komentářích. Podrobnější data jsou v přílohách.

Brazilská banka **Bradesco** v roce 2019 publikovala jen 59 příspěvků, většina z nich byla doplněna videem a funkcí #PraCegoVer. Na oficiálních facebookových stránkách prakticky nepropagují žádné bankovní produkty. Komunikační kanál využívá k propagaci karnevalu nebo jiných kulturních a sportovních akcí, které jsou v Brazílii populární. Na první pohled je patrný více uvolněný styl komunikace, na sociální síti díky hudebním videoklipům nebo influencerům vládne přátelská atmosféra, kterou potvrzují hodnoty sentimentu. 87 % příspěvků banky a více jak 50 % komentářů uživatelů bylo vyhodnoceno jako pozitivních, což jsou ze zkoumaného souboru nejvyšší hodnoty. Příspěvky brazilské banky byly také nejvíce sdíleny publikem, v průměru vychází 434 sdílení na jeden post. Vysoký podíl liků a komentářů rovněž přispívá k vysoké míře virálního šíření obsahu.

Americká banka **Capital One** s NPS hodnotou 18 ve svých příspěvcích, kterých bylo celkem 134, nejvíce zmiňovala výrazy jako *reward*, *card* nebo *earn*, které indikují propagaci finančních služeb. Opak je ale pravdou. Správci stránek se zaměřují na propagaci sportovních akcí jako je baseball nebo hokej. Četná jsou rovněž krátká vtipná videa s označením #WhatIsYourWallet? Oficiální facebookový kanál tak slouží spíše pro zábavu než pro oficiální komunikaci s bankou. To dokazuje také podíl reakcí banky na uživatelské dotazy. Administrátoři stránek odpověděli pouze v 18 % případů.

Finanční instituce **Caixa Econômica Federal** na Facebooku sdružuje více než tři miliony fanoušků, kteří za rok 2019 mohli zaregistrovat přes 200 postů, ve většině případech doplněných o fotografii nebo video. Skrze tato média banka nejčastěji prezentuje své produkty a služby. Video zachycují skutečné příběhy klientů, kteří nabízené produkty chválí nebo děkují bance za podporu v těžkých obdobích. Banka se aktivně zapojuje v oblasti investic, které jsou směřovány do chudších oblastí země. Administrátoři facebookových stránek aktivně reagují na dotazy klientů, většinou se tak děje informativní zprávou pod komentářem a zaslou soukromou zprávou.

**Banco do Brasil** se na svém komunikačním kanálu vyznačuje vyváženými příspěvky co se jejich obsahu týká – skrze různé soutěže a ankety vyzývá obecnost k aktivní spolupráci, sdílí edukační videa z oblasti financí a prevence bezpečnosti v internetovém prostředí, nechybí rovněž zábavné příspěvky nebo organizace dobročinných a charitativních akcí. Jednotný grafický styl používaný na fotografiích a videích působí vkusně. Komunikace je velmi pozitivní, ať už ze strany banky, tak ze strany fanoušků a uživatelů sociální sítě. Administrátoři ve zkoumaném vzorku reagovali na všechny komentáře, ať už se jednalo o dotaz, vznesenou kritiku nebo pochvalu. Editoři v reakcích hojně využívají emotikony a krátké animace (gify), které sklízí pozitivní ohlas fanoušků.

**Bank of America** je největší bankou ve zkoumaném výběru z hlediska aktiv a na svém facebookovém profilu publikovala v roce 2019 celkem 470 postů. Na rozdíl od jihoamerických bank se vyznačuje konzervativnějším stylem komunikace. Banka publikuje videa s nabídkou produktů nebo s pomocí anket dávají fanouškům na výběr ze tří poskytovaných služeb. Z obsahu komunikace je patrné zacílení na mladší věkovou kategorii, především studenty vysokých škol, kteří jsou ve videích často prezentováni. Skrze odkazy na své oficiální internetové stránky s popisem #BetterMoneyHabits nabádá ke vzdělání v oblasti financí a pojišťovnictví. Komentáře uživatelů byly často negativně laděné, často odkazují na špatnou zkušenost s institucí nebo si stěžují na nedostupnost online služeb. Průměrná hladina sentimentu komentářů uživatelů byla jako jedna z mála ze zkoumaného vzorku negativní.

Americká banka **Citigroup** se vyznačuje nejnižší hodnotou NPS z výběru, která je -8. Ve svých příspěvcích se věnuje edukaci v oblasti investic nebo sdílí nejnovější novinové články z renomovaných deníků týkající se např. Brexitu, vývoje burzy a jiných událostí mající globální dopad. Uživatelské komentáře jsou téměř z poloviny vedeny v negativním světle. Často jsou evidovány nedostupné bankovní služby, což se na náladě klientů projevuje. Banka tak musí často reagovat v soukromých zprávách, nevyhýbá se ani reakcím na velmi nepříjemné komentáře. Banka v průměru odpovídá do čtyř a půl hodiny.

Poslední americká banka ve výběru **Wells Fargo** eviduje hned několik oficiálních facebookových stránek. Vedle té hlavní také např. náborovou, kde jsou sdíleny pracovní příležitosti. Ve vyhledávači na sociální síti lze narazit rovněž na spoustu stránek obsahující název americké instituce v negativním kontextu, jako např. *I hate Wells Fargo* apod. Oficiální stránka má přes milion facebookových fanoušků, kterým se nebojí pomoci. Ve svých postech totiž nejčastěji zmiňuje slovo *help*. Na podněty uživatelů reaguje v průměru do hodiny a čtvrt, což je jedna z nejnižších hodnot. Příspěvky se kromě promo akcí věnují např. problematice klimatu a genderovým otázkám. Evidentní je spolupráce se známými herci a sportovci, např. golfisty, kteří v publikovaných videích propagují bankovní služby.

Jihokorejská finanční instituce **Shinhan Financial Group** pořádá na svém facebookovém kanálu spoustu soutěží doplněných fotografií s jednoduchou grafikou. Často na svých oficiálních webových stránkách pořádá online vzdělávací kurzy, na které láká fanoušky na sociální síti. Pokud zrovna banka nepořádá soutěž, informuje klienty o změnách na pobočkách nebo nabádá ke stažení nové mobilní aplikace. Stránka za rok 2019 eviduje v průměru 340 komentářů na příspěvek, což je nadprůměrná hodnota. Přesto na uživatelský

komentář ze zkoumaného vzorku dat nereagovala ani jednou. Je pravděpodobné, že správci automaticky odpovídají skrze soukromou zprávu.

Singapurská **United Overseas Bank** (UOB) na svém profilu komunikuje především v angličtině. V 90 příspěvcích poukazuje na bohatý sponzoring kulturních akcí. Slovo *art* patří k nejčastěji používaným. Banka rovněž investuje čas a peníze do boje proti klimatickým změnám, ve sdílených videích poukazuje pro problematiku znečištění životního prostředí. UOB má na Facebooku téměř milion fanoušků a publikuje příspěvky s nadprůměrnou hodnotou pozitivního sentimentu. Uživatelé přesto na aktivitu banky příliš nereagují. Průměrný počet komentářů na příspěvek je tři.

Druhá singapurská banka ve výběru **DBS** zveřejnila za celý rok jen 45 postů, na které uživatelé prakticky nereagovali. Komunikační kanál na Facebooku nepoužívá k propagaci vlastních produktů, ale spíše k otázkám společenské odpovědnosti. Prezentuje aktivity DBS Foundation Social Enterprise Grant, který se věnuje otázkám znečištění životního prostředí, ekonomickým nerovnostem nebo hladomoru a plýtvání potravinami. Běžným komunikačním prostředníkem je video.

Obdobně jako výše zmíněná singapurská instituce ani **Société Générale** není příliš aktivní v publikování nového obsahu pro bohatou základnu fanoušků. Francouzský majitel Komerční banky využívá Facebook především k propagaci sponzorovaného rugby a proběhlého mistrovství světa. Prakticky žádný příspěvek se netýká předmětu podnikání, nicméně je pravděpodobné, že lokální stránky pro evropské země, kde banka působí, přistupují k propagaci odlišným způsobem. Administrátoři stránek reagují na komentáře uživatelů, které byly v nadpoloviční většině vyhodnoceny jako neutrální, téměř vždy a v průměru do osmé hodiny od zveřejnění.

Kanadská finanční instituce **Bank of Nova Scotia** s hodnotou NPS 20 nejčastěji zveřejňuje příspěvky formou videí, které mají za cíl vzdělání v oblasti investic nebo podnikání. Jiné posty jsou zaměřeny na kanadskoamerickou NHL, kterou banka sponzoruje. V některých případech se rovněž formou videí vyjadřuje k ochraně klimatu nebo znečištění vodních zdrojů. Uživatelé příspěvky, které byly z více než poloviny případů pozitivní, příliš nekomentují. Pokud je vznešen dotaz z publika, je na něj do jedné hodiny zareagováno. Žádný z komentářů fanoušků nebyl z hlediska sentimentu vyhodnocen jako negativní.

**Commonwealth Bank of Australia** nabízí na svých facebookových stránkách vyvážený obsah. Skrze fotografie s jednotnou infografikou upozorňuje uživatele na možná rizika v internetovém bankovníctví (např. phishing), v krátkých videích prezentuje mobilní aplikace, dle reakcí baví publikum vzdělávací formou. Stránky australské banky se těší

velkému zájmu uživatelů. Jeden příspěvek obsahuje v průměru 335 reakcí publika ve formě komentářů, což ještě více slouží k virálnímu šíření obsahu. Banka reaguje v 60 % případů v průměru do dvou hodin a to přímo ve vlákně pod příspěvkem, nikoliv soukromou zprávou.

Jihokorejská **KB Financial Group** využívá facebookovou stránku především k zábavě a hojně vyzývá publikum ke spolupráci, k čemuž používá velké množství anket nebo drobných soutěží a kvízů. Díky osobním fotografií uživatelů, kteří materiál sdílí na základě různých výzev administrátorů, vládne na stránce rodinná atmosféra. Vysoká loajalita fanoušků je evidentní. V komentářích publika nebyla nalezena žádná stížnost. Banka na komentáře vůbec nereaguje. Styl komunikace a chování uživatelů na sociálních sítích ve východní Asii je zcela odlišný od západních zvyklostí a kultury.

**Royal Bank of Canada** (RBC) publikovala za rok 212 postů. Náhodný výběr z nich se setkal s pozitivním nebo neutrálním ohlasem. Hladina sentimentu je v tomto případě nadprůměrná. Banka v roce 2019 oslavila 150 let od svého založení, což se na oboustranné komunikaci a výsledcích jistě projevilo. V některých komentářích uživatelé dokonce poptávají zaměstnání, s čímž se autor jinde nesešel (nejspíše z důvodu stránek na Facebooku určených k náboru). NPS je ze sledovaných bank jedno z nejvyšších (27). Obsah komunikace je rozložený mezi marketingovou komunikaci a nabídku bankovních služeb a produktů, vzdělání a zábavu.

Italská **Intesa Sanpaolo** publikovala za rok nejméně příspěvků (34). Téměř půl milionu fanoušků na publikovaný obsah nikterak nereaguje, čísla z hlediska komentářů nebo sdílení patří k nejnižším z výběru. Banka prakticky publikuje jen odkazy na své oficiální webové stránky, na kterých se nachází podcasty se známými osobnostmi, články s kulturními událostmi v Itálii nebo např. prezentace hospodářských výsledků v uplynulém kalendářním roce. Často také věnují prostor cirkulární ekonomice a vzdělávacímu obsahu. Z důvodu nízkého počtu komentářů nebyly reakce hodnoceny.

Poslední sledovanou bankou ve výběru je ruská **Sberbank**, která se ve vyšší míře zaměřuje na prezentaci bankovních služeb, které se týkají především nového internetového bankovníctví nebo pojišťovnictví. Z proběhlého hlasování na síti, kterého se účastnilo přes 600 uživatelů, se většině (84 %) nové prostředí bankovníctví, které je přizpůsobeno rovněž pro nevidomé, líbí. Obsah vyvažují edukační videa nebo rozhovory s odborníky komentující globální změny a nutnou ochranu klimatu. Po grafické stránce je prezentace jednotná a vizuálně přívětivá. Téměř 70 % publikovaného obsahu bylo vyhodnoceno s pozitivním sentimentem. Administrátoři reagují na dotazy publika rychle, v průměru do 45 minut.

**Сбербанк** vytvořil(a) anketu.  
7. srpna 2019 · 🌐

Как вам последнее обновление Сбербанк Онлайн?  
How do you like the latest update of Sberbank Online?  
⚙️ · Ohodnotte tento překlad

Нравится 606 hlasů

Не нравится

Anketa skončila. 65 komentářů 3 sdílení

👍👎 84

**Commonwealth Bank**  
11. dubna 2019 · 🌐

Pro tip: every time you treat yourself, treat your savings account too.

## Me before payday vs. Me after payday

👍👎 432 333 komentářů 32 sdílení

**SBI State Bank of India**  
17. srpna 2019 · 🌐

The time to change the way we use water is now! Participate in this conversation about water conservation and comment with your answers below. #BetterLiving4ABetterPlanet  
#SBI #StateBankofIndia #Sustainability

**SBI**

CONVERSATION ABOUT WATER CONSERVATION

The best way to save water at home is?

- a) Check the toilet valve for leaks and fix them
- b) Turning off the tap when you brush
- c) Rinse vegetables in a pan of water instead of under a tap

**#BetterLiving4ABetterPlanet**

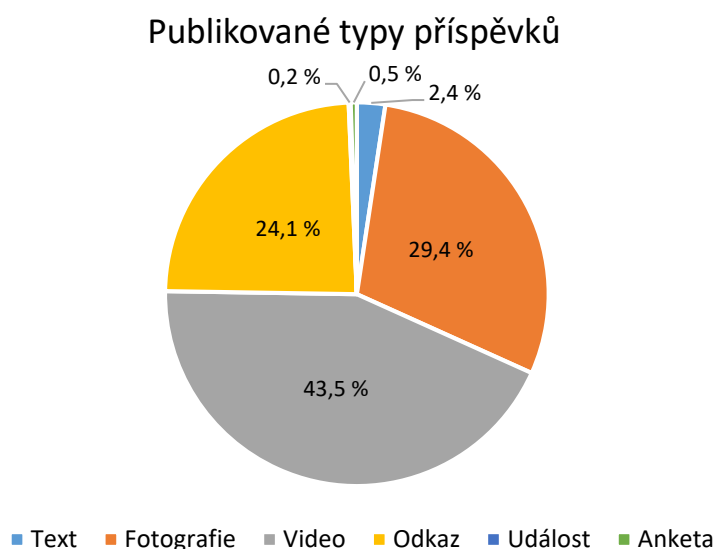
👍 97 tis. 490 komentářů 1,3 tis. sdílení

Obrázek 12 – Vybrané příspěvky pro ukázkou. Vlevo nahoře anketa Sberbank, vpravo nahoře zábavná koláž australské banky, dole příspěvek podněcující k diskusi týkající se šetření s vodou. (Zdroj: Oficiální profily na Facebooku)

## 8.2 VO1: Jaký je charakter příspěvků bankovních institucí?

### 8.2.1 Jaké typy příspěvků banky prezentují?

Napříč všemi bankami bylo náhodně vybráno celkem 586 příspěvků, u kterých byl určen typ postu. Jak je patrné z grafu č. 1, banky nejvíce publikovaly příspěvky s videem nebo fotografií. Banky jako Intesa Sanpaolo nebo Royal Bank of Canada ve vyšší míře zveřejňovaly odkazy. V případě italské banky šlo o firemní stránky, v případě kanadské pak o odkazy na zpravodajské servery. Prostý text, anketa nebo událost byly ve vybraných postech publikovány minimálně. Administrátoři oficiálních stránek Banco do Brasil nebo jihokorejské finanční skupiny KB se snaží obsah rovnoměrně rozdělit mezi všechny typy postů.




*Graf 1 – Publikované typy příspěvků (Zdroj: Vlastní zpracování)*

### 8.2.2 Co je obsahem příspěvků?

Téměř polovina z vybraného vzorku příspěvků je zaměřena na obecnou a marketingovou komunikaci, kdy banky upozorňují na změnu otevírací doby svých poboček, nebo propagují bankovní služby a produkty. V marketingovém sdělení je patrné především zaměření na online produkty spravované odkudkoliv několika kliknutím myši. S tím souvisí i kladený důraz na prevenci v oblasti zacházení s citlivými údaji v online prostředí. 89 postů z výběru bylo vzdělávacího charakteru zveřejněných především kanadskou královskou bankou nebo španělskou BBVA. Naopak tři banky nepublikovaly z této kategorie žádný příspěvek. V oblasti společenské odpovědnosti se nejvíce angažovala indická State Bank. Nejmenší podíl připadá na posty, které mají za úkol aktivně angažovat

uživatelé sociální sítě (celkem 64). V tomto případě výrazně vyčnívají obě jihokorejské finanční instituce, které své fanoušky zapojují do komunikace skrze pořádané soutěže. U ostatních bank jde spíše o sporadický obsah.

Publikované obsahy příspěvků



Graf 2 – Publikované obsahy příspěvků (zdroj: Vlastní zpracování)

### 8.2.3 Jaká je hladina sentimentu v příspěvcích?

V období roku 2019 publikovalo 20 zkoumaných institucí celkem 4 814 příspěvků, u 148 z nich nebyla určena hladina sentimentu, jelikož post neobsahoval žádný text. Průměrná hladina sentimentu všech relevantních příspěvků je 2,08 – banky tedy upřednostňují pozitivní tón komunikace.

	Zkoumaný vzorek bank	Société Générale	KB Financial Group
Počet příspěvků	4 666	46	225
Průměrná hladina sentimentu	2,08	3,55	1,02
Medián	1,82	2,45	0,88
Modus	0	0	0
Rozptyl výběru	9,80	12,42	7,20
Směrodatná odchylka	3,13	3,52	2,68
Minimum	-12,24	0	-10,53
Maximum	23,08	11,76	14,29
Rozdíl max-min	35,32	11,76	24,81


Tabulka 4 – Popisná statistika sentimentu příspěvků (zdroj: Vlastní zpracování)



Jak lze vidět v tabulce č. 4, nejvyšší hodnotu sentimentu lze zaregistrovat v postech francouzské Sociétés Générale (3,55), která ve 46 případech ani jednou nezveřejnila text s negativním míněním. Nejnižší hladinu lze naopak pozorovat u KB Financial Group (1,02). Popisná statistika sentimentu postu všech 20 bank je umístěna v příloze práce.

Necelých 10 % příspěvků (celkem 433) obsahovalo negativní sentiment, v součtu 1 241 jich bylo neutrálních, více jak 64 % pozitivních. Nejvyšší podíl pozitivních příspěvků lze registrovat u Banco Bradesco (87 %), naopak nejvyšší podíl negativních u singapurské DBS (20 %). Nejvíce neutrálně laděných postů bylo vyhodnoceno u RBC (téměř 36 %). Podrobnější data jsou k nahlédnutí v příloze (příloha č. 4 a 5).

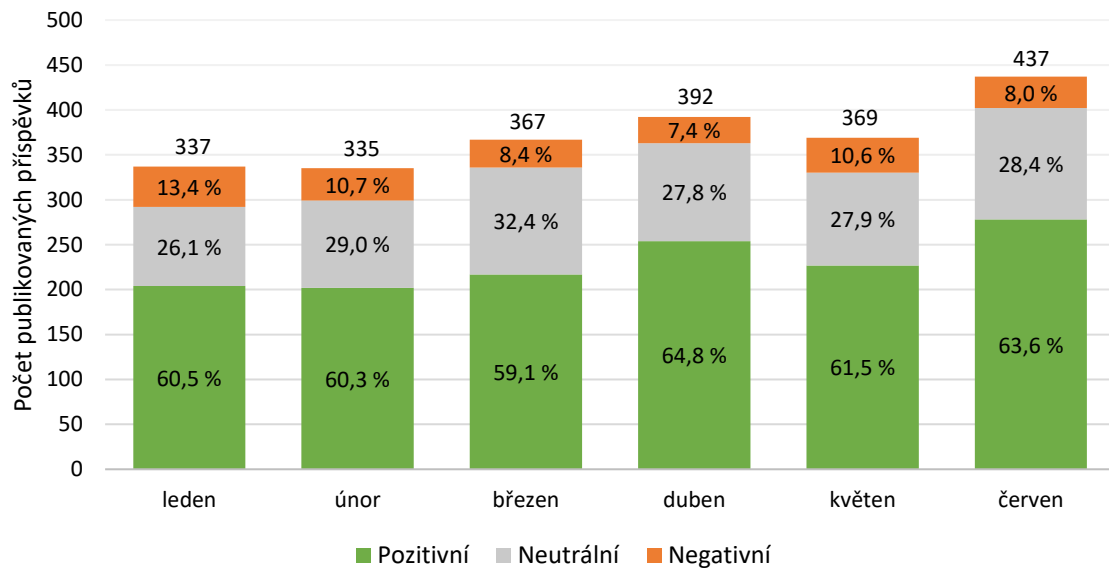
Sentiment v příspěvcích bank



Graf 3 – Podíly polarity sentimentu v příspěvcích bank (zdroj: Vlastní zpracování)


Sloupcové grafy č. 4 a 5 zachycují sentiment zveřejněného obsahu v čase (rok 2019). Relativně nejvyšší podíl pozitivních postů je zaznamenán v září (70 %). Tento měsíc bylo rovněž publikováno absolutně nejméně negativního textového obsahu (celkem 21 postů) – hned 11 bank v tomto období nesdílelo žádný negativně laděný obsah. V průběhu ledna bylo publikováno přes 13 % negativních příspěvků. Publikačně nejaktivnější byly banky v říjnu (celkem 461 příspěvků), nejméně naopak v nejkratším měsíci únoru (335).

### Sentiment v příspěvcích bank v první polovině roku 2019



Graf 4 – Podíly polarity sentimentu v příspěvcích bank v první polovině roku 2019 (zdroj: Vlastní zpracování)

### Sentiment v příspěvcích bank ve druhé polovině roku 2019



Graf 5 – Podíly polarity sentimentu v příspěvcích bank ve druhé polovině roku 2019 (zdroj: Vlastní zpracování)

#### 8.2.4 Existuje korelace mezi sentimentem příspěvku a interakcemi uživatelů?

Otázka zkoumá vztah mezi sentimentem příspěvku publikovaný bankou a interakcemi uživatelů vyjádřené počtem liků, komentářů nebo sdílení. Pro zajímavost byla rovněž zkoumána souvislost mezi samotnými interakcemi.

Za pomoci Shapirova-Wilkova testu normality se neprokázalo normální rozdělení hodnot sentimentu a interakcí uživatelů. Z tohoto důvodu byl pro popis vztahu použit Spearmanův neparametrický korelační koeficient. Hypotézy jsou následující:

$$H_0: \rho = 0$$

$$H_1: \rho \neq 0$$

Dle korelační tabulky č. 5 na hladině významnosti  $\alpha$  (0,05) nezamítáme hypotézu o nulové hodnotě korelačního koeficientu, jelikož p-hodnota je vyšší než  $\alpha$ . Mezi sentimentem příspěvku a interakcemi uživatelů neexistuje statisticky významná korelace.

		Sentiment publikovaného příspěvku	Počet liků	Počet komentářů	Počet sdílení
Sentiment publikovaného příspěvku	Spearmanův koeficient pořadové korelace	1,00	0,008	-0,022	-0,014
	p-hodnota	-	0,596	0,140	0,327
	N	4 666	4 666	4 666	4 666
Počet liků	Spearmanův koeficient pořadové korelace	0,008	1,00	0,803	-0,170
	p-hodnota	0,596	-	0,00	0,00
	N	4 666	4 666	4 666	4 666
Počet komentářů	Spearmanův koeficient pořadové korelace	-0,022	0,803	1,00	-0,216
	p-hodnota	0,140	0,00	-	0,00
	N	4 666	4 666	4 666	4 666
Počet sdílení	Spearmanův koeficient pořadové korelace	-0,014	-0,170	-0,216	1,00
	p-hodnota	0,327	0,00	0,00	-
	N	4 666	4 666	4 666	4 666

Tabulka 5 – Korelační tabulka mezi sentimentem příspěvku a interakcemi uživatelů (zdroj: Vlastní zpracování)

Z tabulky lze dále vyčíst, že existuje silná korelace mezi počtem komentářů a počtem liků. Formálně v tomto případě zamítáme  $H_0$  a přijímáme alternativní hypotézu o nenulovém koeficientu korelace, jelikož p-hodnota je nižší než hladina významnosti  $\alpha$ .

### 8.3 VO2: Jaký je charakter komentářů uživatelů na příspěvky?

#### 8.3.1 Jaká je hladina sentimentu v komentářích uživatelů?

Byly zkoumány reakce uživatelů na 85 náhodně vybraných bankovních příspěvků. Celkem byl určen sentiment u 751 komentářů první úrovně, která odpovídá přímé reakci na post. Z důvodu nedostatku komentářů nebyly do výsledků zahrnuty tři banky (BBVA, DBS a Intesa Sanpaolo). Jak znázorňuje tabulka níže, průměrná hodnota sentimentu uživatelských reakcí je téměř identická s průměrnou hladinou sentimentu všech zkoumaných příspěvků. Bank of Nova Scotia ve výsledku disponovala nejpozitivnějšími reakcemi, žádná z nich nebyla s negativním obsahem. Velmi pozitivní komentáře byly rovněž zaznamenány u KB, UOB nebo Bradesca. Naopak v průměru negativní hladinu sentimentu lze zaznamenat u americké Capital One nebo australské Commonwealth Bank. V obou případech jsou příčinou nespokojené reakce uživatelů s nabízenými bankovními službami.


	Zkoumaný vzorek bank	Bank of Nova Scotia	Commonwealth Bank of Australia
Počet komentářů	751	26	50
Průměrná hladina sentimentu	2,06	11,01	-1,64
Medián	0	0	0
Modus	0	0	0
Rozptyl výběru	77,17	342,10	33,54
Směrodatná odchylka	8,78	18,50	5,79
Minimum	-50	0	-25
Maximum	50	50	18,18
Rozdíl max-min	100	50	43,18

Tabulka 6 – Popisná statistika sentimentu uživatelských komentářů (zdroj: Vlastní zpracování)

Graf č. 6 znázorňuje podíly pozitivních, neutrálních a negativních uživatelských reakcí. Nejvíce komentářů je vyhodnoceno s neutrálním obsahem (celkem 328). Nejvyšší podíl pozitivních komentářů byl zaznamenán u Bradesca (26 pozitivních z celkových 50 hodnocených komentářů). Naopak nejvyšší podíl negativních komentářů (41,7 %) byl

vyhodnocen u americké Citigroup. Z důvodu nízkého počtu zkoumaných postů a jejich reakcí není vyhodnocena analýza sentimentu v čase.

### Sentiment v komentářích uživatelů



Graf 6 – Podíly polarity sentimentu v komentářích uživatelů (zdroj: Vlastní zpracování)

#### 8.3.2 Liší se sentiment komentářů mezi příspěvky s různým obsahem?

Byla testována hypotéza o shodě rozdělení sentimentu komentářů napříč kategoriemi příspěvků s různým obsahem. Do testu vstupovalo celkem 751 komentářů z 85 příspěvků s přiřazenou hladinou sentimentu komentáře a typem obsahu příspěvku. Jak je zmíněno výše, test neprokázal normální rozdělení hladiny sentimentu. Z tohoto důvodu je zvolen neparametrický Kruskalův–Wallisův test nazývaný také vícevýběrovým testem shody mediánů.

$H_0$ : mezi kategoriemi obsahu neexistují významné rozdíly v rozdělení sentimentu

$H_1$ : mezi kategoriemi obsahu existují významné rozdíly v rozdělení sentimentu

Na hladině významnosti  $\alpha$  (0,05) nezamítáme  $H_0$ , jelikož p-hodnota (0,081) je vyšší než  $\alpha$ . Mezi různými typy příspěvků není statisticky významný rozdíl v sentimentu uživatelských komentářů.

Jak ukazuje tabulka níže s popisnou statistikou, nejvyšší průměrná hladina sentimentu se vyskytuje u vzdělávacích příspěvků, nejnižší pak u příspěvků zaměřených na komunikaci. Nejvyšší podíl neutrálních komentářů zauímají posty se zábavnou tematikou, příspěvky zaměřené na společenskou odpovědnost banky disponují komentáři, které jsou téměř rovnoměrně distribuovány do tří sledovaných kategorií sentimentu.

	Zkoumaný vzorek	Komunikace	Výzva ke spolupráci	Vzdělávání	Zábava	CSR
Počet komentářů	751	364	109	52	147	79
Počet příspěvků	85	41	12	7	16	9
Průměrná hladina sentimentu	2,06	1,47	2,08	4,76	1,91	3,24
Medián	0	0	0	0	0	0
Modus	0	0	0	0	0	0
Rozptyl výběru	77,17	76,14	51,38	94,44	62,15	130,49
Směrodatná odchylka	8,78	8,73	7,17	9,72	7,88	11,42
Minimum	-50,00	-50,00	-20,00	-8,69	-25,00	-20,00
Maximum	50,00	40,00	33,33	50,00	50,00	50,00
Rozdíl max-min	100,00	90,00	53,33	58,69	75,00	70,00
Podíl pozitivních komentářů	33,9 %	33,0 %	36,7 %	40,4 %	30,6 %	36,7 %
Podíl neutrálních komentářů	43,7 %	40,7 %	42,2 %	51,9 %	56,5 %	30,4 %
Podíl negativních komentářů	22,4 %	26,4 %	21,1 %	7,7 %	12,9 %	32,9 %

Tabulka 7 – Popisná statistika sentimentu uživatelských komentářů v závislosti na obsahu příspěvku (zdroj: Vlastní zpracování)

### 8.3.3 Existuje korelace mezi sentimentem příspěvku a sentimentem komentářů?

Otázka zkoumá vztah mezi sentimentem příspěvku publikovaný bankou a sentimentem uživatelského komentáře. Hladina sentimentu 751 reakcí byla zprůměrována a přiřazena k 85 publikovaným příspěvkům 17 různých bank.

Pro popis vztahu byl použit Spearmanův neparametrický korelační koeficient. Hypotézy jsou následující:

$$H_0: \rho = 0$$

$$H_1: \rho \neq 0$$

Dle korelační tabulky č. 8 na hladině významnosti  $\alpha$  (0,05) zamítáme hypotézu  $H_0$  a přijímáme alternativní hypotézu o nenulové hodnotě korelačního koeficientu, jelikož p-hodnota je nižší než  $\alpha$ . Mezi sentimentem příspěvku a sentimentem komentářů existuje statisticky významná závislost, která je slabá.

		Sentiment publikovaného příspěvku	Sentiment uživatelského komentáře
Sentiment publikovaného příspěvku	Spearmanův koeficient pořadové korelace	1,00	0,22
	p-hodnota	-	0,044
	N	85	85
Sentiment uživatelského komentáře	Spearmanův koeficient pořadové korelace	0,22	1,00
	p-hodnota	0,044	-
	N	85	85

*Tabulka 8 – Korelační tabulka mezi sentimentem příspěvku a sentimentem komentáře (zdroj: Vlastní zpracování)*

#### 8.3.4 Existuje korelace mezi NPS banky a hladinou sentimentu v komentářích uživatelů?

Otázka zkoumá vztah mezi NPS banky a hladinou sentimentu v komentářích uživatelů. Test je prováděn se 16 záznamy, jelikož u Société Générale není známa hodnota NPS a u tří bank nejsou dostupná data týkající se sentimentu komentářů. Pro popis vztahu byl použit Spearmanův neparametrický korelační koeficient. Hypotézy jsou následující:

$$H_0: \rho = 0$$

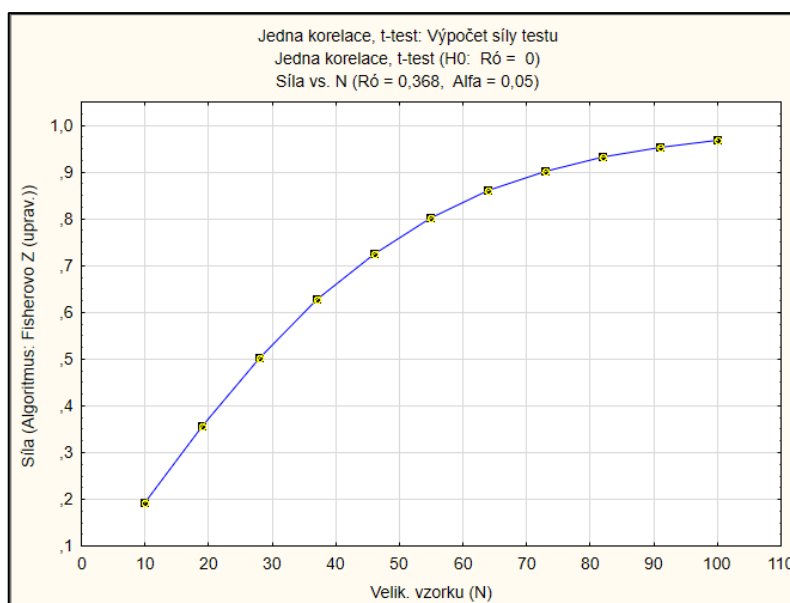
$$H_1: \rho \neq 0$$

Korelační tabulka níže říká, že na hladině významnosti  $\alpha$  (0,05) nezamítáme hypotézu o nulové hodnotě korelačního koeficientu, jelikož p-hodnota je vyšší než  $\alpha$ . Mezi NPS banky a sentimentem komentářů neexistuje statisticky významná korelace.

		NPS banky	Sentiment uživatelského komentáře
NPS banky	Spearmanův koeficient pořadové korelace	1,00	0,368
	p-hodnota	-	0,160
	N	16	16
Sentiment uživatelského komentáře	Spearmanův koeficient pořadové korelace	0,368	1,00
	p-hodnota	0,160	-
	N	16	16

Tabulka 9 – Korelační tabulka mezi NPS banky a sentimentem komentářů (zdroj: Vlastní zpracování)

S pomocí statistického nástroje byla vypočítána síla testu, která je 0,3. Chyba druhého druhu  $\beta$  (0,7), která říká, jaká je pravděpodobnost přijetí  $H_0$ , přestože  $H_0$  ve skutečnosti neplatí, je příliš vysoká, a výsledky toho testu nemusí být zcela relevantní. Dle grafu níže by pro relevantnost testu byl potřeba vzorek alespoň 55 bank, jelikož síla testu (0,8) se při tomto výběru považuje za dostatečnou (Shields, 2019).



Graf 7 – Síla testu v závislosti na velikosti vzorku (zdroj: Statistica)




## 8.4 VO3: Jaký je charakter odpovědí bank na komentáře uživatelů?

### 8.4.1 Jak často a jak rychle banky reagují na komentář uživatele?

Na 751 komentářů pod 85 posty banka přímo reagovala ve 357 případech. Jediná banka – Banco do Brasil – reagovala ve všech případech, naopak jihokorejské KB nebo Shinhan Financial Group neodpovídaly vůbec. Míry reakcí všech zkoumaných institucí jsou k dispozici v příloze.

Míra reakcí bankovních institucí



Graf 8 – Míra reakcí bankovních institucí na uživatelské komentáře (zdroj: Vlastní zpracování)


Tabulka na další straně obsahuje popisnou statistiku rychlosti reakce banky na příspěvek uživatele. Doba je počítána včetně víkendů a nočních hodin a z důvodu manuálního výpočtu je zaokrouhlena na čtvrt hodiny. Průměrná doba reakce 14 zkoumaných bank je téměř osm hodin. Nejrychleji reagují administrátoři ruské Sberbank, kteří na 22 komentářů reagovali do jedné hodiny. Nejpomaleji reagovali administrátoři indické státní banky, kteří navíc odpovídali jen na 12 % vybraných komentářů.

	Zkoumaný vzorek bank	Sberbank	State Bank of India
Počet komentářů	357	22	6
Průměrný čas reakce v hodinách	7,82	0,84	53,28
Medián	1,50	0,25	71,00
Modus	0,25	0,25	0,25
Rozptyl výběru	213,92	2,74	1738,17
Směrodatná odchylka	14,63	1,66	41,69
Nejrychlejší reakce [h]	0,25	0,25	0,25
Nejpomalejší reakce [h]	100	8	100
Rozdíl max-min	99,75	7,75	99,75

Tabulka 10 – Popisná statistika doby reakcí na uživatelské komentáře (zdroj: Vlastní zpracování)

Dle grafu níže byla téměř polovina ze 357 reakcí provedena do 60 minut včetně. Ve 101 případech bylo odpovězeno v rozpětí 60 minut až 8 hodin. 96 reakcí pak vyžadovalo delší časový úsek.

#### Doba reakce bankovních institucí



Graf 9 – Doba reakce bankovních institucí (zdroj: Vlastní zpracování)

#### 8.4.2 Jaký sentiment používají banky v komunikaci s uživatelem?


Z 357 reakcí administrátorů je patrné, že banky při komunikaci s uživatelem volí pozitivní tón, průměrná hladina sentimentu v reakcích je 2,48. Banco Bradesco ve svých reakcích dosahuje nejvyšší průměrné hladiny sentimentu, naopak ze 30 reakcí francouzské Société Générale je patrný spíše negativní tón. Tabulka v příloze (příloha č. 10 a 11) popisuje sentiment reakcí za všechny sledované bankovní instituce.

	<b>Zkoumaný vzorek bank</b>	<b>Banco Bradesco</b>	<b>Société Générale</b>
Počet komentářů	357	41	30
Průměrná hladina sentimentu	2,48	6,41	-0,35
Medián	0	3,45	0
Modus	0	0	0
Rozptyl výběru	24,14	66,05	7,25
Směrodatná odchylka	4,91	8,13	2,69
Minimum	-8,33	-8,33	-7,69
Maximum	30,77	30,77	6,38
Rozdíl max-min	39,10	39,10	14,08

*Tabulka 11 – Popisná statistika sentimentu reakcí bankovních institucí (zdroj: Vlastní zpracování)*

Koláčový graf č. 10 znázorňuje skladbu reakcí z hlediska voleného tónu komunikace. Téměř polovina reakcí (přesně 177) byla slovníkovým algoritmem vyhodnocena jako neutrálních, 146 jako pozitivně laděných a zbylých 34 jako negativní. Nejvyšší podíl pozitivních odpovědí je pozorován u Bradesca (přes 63 %), nejvyšší podíl těch negativních pak u americké Citigroup (25 %). Negativní sentiment v reakcích nebyl vyhodnocen u čtyř institucí, a to u Capital One, Royal Bank of Canada, Sberbank a Bank of Nova Scotia.

### Sentiment v reakcích bank



Graf 10 – Podíly polarity sentimentu v reakcích bankovních institucí (zdroj: Vlastní zpracování)

#### 8.4.3 Existuje závislost mezi sentimentem komentáře a rozhodnutím banky odpovědět na komentář?

S pomocí Pearsonova chí-kvadrát testu nezávislosti je testována hypotéza o závislosti mezi polaritou sentimentu komentáře a rozhodnutím firmy odpovědět na komentář.

$H_0$ : polarita komentáře a rozhodnutí firmy odpovědět jsou nezávislé

$H_1$ : polarita komentáře a rozhodnutí firmy odpovědět jsou závislé

Předpoklady testu jsou splněné – ani jedna z očekávaných četností není menší než pět, minimum je 79,9. Očekávané četnosti jsou popsány v kontingenční tabulce níže.

Testové kritérium  $\chi^2$  je 12,5 při dvou stupních volnosti. Přesná hladina významnosti  $p = 0,002$ . Na hladině významnosti  $\alpha (0,05)$  zamítáme hypotézu  $H_0$  a přijímáme alternativní hypotézu, jelikož  $p$ -hodnota je nižší než  $\alpha$ . Mezi sentimentem komentáře a rozhodnutím firmy reagovat na tento komentář existuje závislost. Z grafu níže je patrné, že administrátoři nejčastěji reagují na negativní komentáře uživatelů.

Sentiment	Četnost	Reakce banky		Součet
		ANO	NE	
Pozitivní	Absolutní	113	142	255
	Relativní	44,3 %	55,7 %	100 %
	Očekávaná	121,2	133,8	255
Neutrální	Absolutní	144	184	328
	Relativní	43,9 %	56,1 %	100 %
	Očekávaná	155,9	172,1	255
Negativní	Absolutní	100	68	168
	Relativní	59,5 %	40,5 %	100 %
	Očekávaná	79,9	88,1	255
Součet	Absolutní	357	394	751
	Relativní	47,5 %	52,5 %	100 %

Tabulka 12 – Kontingenční tabulka četností reakcí banky a sentimentu uživatelských komentářů (zdroj: Vlastní zpracování)



Graf 11 – Relativní četnost reakce banky v závislosti na sentimentu uživatelského komentáře (zdroj: Vlastní zpracování)

#### 8.4.4 Existuje korelace mezi sentimentem komentáře uživatele a sentimentem odpovědi banky?

Je zkoumaný vztah mezi voleným tónem v uživatelském komentáři a tónem reakce banky. Existence korelace je určena na základě 357 záznamů.

Pro popis vztahu byl použit Spearmanův neparametrický korelační koeficient, jelikož se neprokázalo normální rozdělení obou veličin. Hypotézy jsou následující:

$$H_0: \rho = 0$$

$$H_1: \rho \neq 0$$

Dle korelační tabulky č. 13 na hladině významnosti  $\alpha$  (0,05) zamítáme hypotézu  $H_0$  a přijímáme alternativní hypotézu o nenulové hodnotě korelačního koeficientu, jelikož p-hodnota je nižší než  $\alpha$ . Mezi sentimentem komentáře a sentimentem reakcí banky existuje statisticky významná závislost, která je ovšem slabá.

		Sentiment uživatelského komentáře	Sentiment reakce banky
Sentiment uživatelského komentáře	Spearmanův koeficient pořadové korelace	1,00	0,30
	p-hodnota	-	0,00
	N	357	357
Sentiment reakce banky	Spearmanův koeficient pořadové korelace	0,30	1,00
	p-hodnota	0,00	-
	N	357	357

*Tabulka 13 – Korelační tabulka mezi sentimentem komentáře a sentimentem reakcí banky (zdroj: Vlastní zpracování)*

## 9 Diskuze

### 9.1 Hlavní zjištění

Hlavní zjištění jsou seskupena dle výzkumných otázek. V první část jsou diskutovány otázky týkající se příspěvků vybraných institucí z hlediska jejich obsahu nebo sentimentu a tyto aspekty jsou dále porovnávány s výsledky jiných studií. Ve druhé části jsou komentovány výsledky představující charakter uživatelských komentářů, v poslední části jsou pak diskutovány výsledky z hlediska reakcí administrátorů komunikačního kanálu.

#### 9.1.1 Charakter příspěvků bankovních institucí

Vybraný vzorek oficiálních facebookových stránek bankovních institucí se nejčastěji prezentuje skrze obrazové materiály doplněné textem, tedy videa a fotografie, které lépe připoutají pozornost čtenáře, než samotný prostý text, který byl publikován minimálně. Téměř čtvrtina příspěvků byla tvořena odkazy, které mají za cíl zlákat čtenářovu pozornost na oficiální webové stránky finanční instituce nebo příspěvek odkazoval na zpravodajské servery informující např. o globální finanční situaci. Ankety vyzývající obecnost k aktivní spolupráci stejně tak jako pozvánky na vlastní nebo sponzorované eventy byly publikovány sporadicky. Na některých stránkách lze identifikovat z hlediska typu různorodé příspěvky, naopak správci několika sledovaných bank výrazněji upřednostňují jeden typ před ostatními.

Po obsahové stránce se sledované banky nejvíce zaměřovaly na marketingovou komunikaci založené především na představení nových a připomenutí stávajících produktů, a to především těch digitálních jako je internetové či mobilní bankovníctví. Druhou nejpočetnější skupinu tvoří vzdělávací příspěvky, a to v první řadě díky zvýšené aktivitě tří sledovaných bank (BBVA, Bank of Nova Scotia a Royal Bank of Canada) v této agendě. Humorný obsah se alespoň jednou objevil prakticky u všech sledovaných bank, příspěvky vyzývající ke spolupráci byly doménou především jihokorejských institucí. Z obsahu je dále patrné, že téměř všechny instituce se nějakým způsobem angažují v otázkách společenské odpovědnosti, jako jsou ekologické či charitativní aktivity. Obdobně jako u typu příspěvku, tak také v tomto případě platí, že některé marketingové týmy stojící na pozadí komunikace kladou důraz na vyvážený obsah (např. Banco do Brasil), jiné naopak preferují jeden typ obsahu. Výstupy se v tomto ohledu shodují s výsledky práce Kohouta (2018), který zkoumal komunikaci technologických firem (např. Intel apod.) na stejném komunikačním kanálu.

Banky v publikovaných příspěvcích používaly téměř ve dvou třetinách případů pozitivní sentiment, necelá desetina z 4 666 postů byla vyhodnocena s negativním tónem

komunikace. V případě francouzské Soci t  G n rale nebyl zjiřt n ani jeden post s negativn m obsahem. Z prezentovan ch v sledk  je rovn ř patrn , ťe se pod ly polarity sentimentu v pr spěvc ch bank ve sledovan ch m s c ch p r liř nem n . Zvolen  t n komunikace tak z st v  dlouhodob  konzistentn . Odliřn  v sledky prezentuj  ve v zkumu Alamsyah a Indraswari, dle kter ch t i indon sk  banky zveřejn j  nej ast ji neutr ln  posto (v 59 % pr pad ), pozitivn  pr spěvky tvořily necelou  tvrtinu (Alamsyah & Indraswari, 2017).

Vztah mezi interakcemi uťivateli a sentimentem pr spěvku se statisticky neprok zal. Podařilo se prok zat  zk  vztah mezi samotn mi interakcemi, zejména pak mezi po tem koment ř  a lik . Pokud pr spěvek vyvol v  odezvu publika, d je se tak vřemi dostupn mi zp soby.

#### 9.1.2 Charakter uťivatelsk ch koment ř 

T m ř 44 % uťivatelsk ch koment ř  bylo vyhodnoceno s neutr ln  polaritou sentimentu, 34 % s pozitivn  a zbyl ch 22,4 % s negativn m obsahem. Pr m rn  hladina sentimentu (2,06) je ve v sledku prakticky totoťn  s pr m rem pr spěvk  bank (2,08), nicm n  hodnoty sentimentu v koment ř ch dosahuj  na obou stran ch spektra extr mn jřich hodnot (od -50 do 50). Tento v sledek je jist  ovlivn n pouťivan m slovn kem obecnstva, ve kter m  asto nechyb  expresivn  v razy s negativn   i pozitivn  polaritou. V kone n m shrnut  to znamen , ťe n kter  str nky (např. Bank of Nova Scotia nebo KB Financial Group) eviduj  velmi pozitivn  koment ře, ve dvou pr padech to naopak zna i pr m rnou negativn  hladinu sentimentu. Zejm na jde o banky, u kter ch si uťivateli  asto st ťuj  na nedostupnost online prostřed , neetick  praktiky p i komunikaci nebo kvalitu nab zen ch produkt  a sluťeb. V sledn  sentiment m ťe rovn ř ovlivnit aktivita hater , kter  se mohou negativn  projevovat pod kaťd m publikovan m pr spěvkem banky. Nejvřřší pod l neutr ln ch koment ř  je zapř i n n  ast mi dotazy obecnstva nebo stru n mi ( asto jednoslovn mi) odpov ďmi na kv zov  ot zky. V tomto sm ru jsou jihokorejřt  pr znivci velmi aktivn . Obdobn  v sledky popisuj ci hladinu sentimentu v reakc ch fanouřk  p n ř  pr ce Kohouta (2018). Dle pr ce Liena je patrn , ťe o bank ch na norsk m trhu se uťivateli vyjadřuj  sp ře negativn  (ve 47 %), pozitivn ch zm nek bylo evidov no 42 % (Lien, 2017).

Podle v sledk  se nepodařilo prok zat statisticky v znamn  rozd l v sentimentu koment ř  pouťivan  pod r zn m typem obsahu pr spěvk . Z bavn  nebo vzd l vac  pr spěvky tedy statisticky nevykazuj  vřřší hladinu sentimentu reakc  fanouřk , jak by



mohlo být očekáváno. Vztah mezi sentimentem příspěvku a sentimentem komentářů je statisticky významný, ovšem slabý. Existující korelaci mezi NPS banky a hladinou sentimentu v komentářích uživatelů se nepodařilo prokázat. V tomto případě by bylo relevantnější získat názory a komentáře z různých komunikačních kanálů banky, nejen Facebooku. Otázkou zůstává, zda hladina sentimentu skutečně odráží dlouhodobou loajalitu zákazníka.

### 9.1.3 Charakter reakcí bankovních institucí na uživatelské komentáře

Administrátoři stránek reagovali na uživatelské komentáře téměř v polovině případů s průměrnou dobou reakce osm hodin, přičemž komunikační tým ruské Sberbank reagoval v průměru do jedné hodiny. Některé banky ze studovaného výběru zapojují do komunikace několik moderátorů najednou, kteří v nemálo případech reagovali delším odstavcem. V těchto případech je evidentní důraz na promptní reakci a vysoký standard komunikačních služeb. Naopak správci některých stránek nereagovali na komentáře a dotazy z publika vůbec (minimálně tedy vůbec v komentářích pod příspěvkem). V jiných případech lze pozorovat reakce téměř na každý komentář, a ne vždy se jedná o dotaz nebo připomínku z publika. Na stížnosti nebo otázky je reagováno buď přímo ve vlákne komentářů, nebo je odeslána odpověď s informací, že bylo reagováno skrze soukromou zprávu na Facebooku. Tyto stručné informace odkazující na soukromou korespondenci do jisté míry zapřičiňují převládající polaritu neutrálních reakcí banky. Jen necelá desetina reakcí byla vyhodnocena s negativním obsahem sdělení. Zajímavostí je, že v případě francouzské Sociétés Générale byla zjištěna nejnižší průměrná hladina sentimentu reakcí (mírně negativní s hodnotou -0,35), přestože příspěvky té samé banky byly vyhodnoceny s nejvyšší průměrnou hladinou sentimentu (3,55). Tento nekonzistentní projev může být do jisté míry způsoben malým vzorkem dat, v případě Sociétés Générale bylo publikováno jen 46 příspěvků za rok 2019 převážně se sportovní tematikou týkající se sponzorovaného mistrovství světa v rugby a vyhodnocení sentimentu bylo podrobena 30 reakcí administrátorů. Při bližším zkoumání dat je rovněž evidentní, že algoritmus ne vždy zcela správně přiřadil sentiment zkoumaným reakcím (viz kapitola 9.3).

Z výsledků je dále patrné, že na negativní komentáře uživatelů banky reagují častěji než na neutrální či pozitivní. Výsledky se v tomto směru shodují s prací Kohouta (2018). Korelace mezi sentimentem komentáře a sentimentem odpovědi banky se statisticky prokázala. Podobně jako mezi příspěvkem a komentářem je hodnota korelace slabá.

## 9.2 Doporučení na základě hlavních zjištění

Na základě shrnutých výsledků lze předložit marketingovým týmům pohybujícím se v prostředí Facebooku několik doporučení tak, aby byl podán kvalitní servis z pohledu komunikace, který si uživatelé sociálních sítí tolik přejí.

Bankovní instituce a obecně jakékoliv prezentující se firmy na sociální síti by měly používat různorodé prostředky k oslovování potenciálních zákazníků a k udržení těch stávajících. To znamená využití širokého spektra možností, ať už jde o příspěvky doplněné kvalitním obrazovým materiálem, ankety sloužící pro výzkum mínění fanoušků nebo pořádání kulturních či sportovních událostí, které banka hrdě sponzoruje. Obsah sdělení by neměl být určen pouze k marketingovému cílení, ale měl by být pestrý a vyvážen adekvátně k demografickému a sociálnímu složení přítomného obecnstva. Jak plyne z některých výsledků, např. Vojtěchové (2017), mladí lidé od finančních institucí působících na Facebooku očekávají více vzdělávacího materiálu a zpravodajství z oblasti ekonomie. Bohužel, minimálně v českém prostředí, banky musejí více suplovat roli základních a středních škol v oblasti vzdělávání finanční gramotnosti. Těmto aktivitám se intenzivně věnuje např. Česká spořitelna ve svém programu Abeceda peněz, angažuje se také Komerční banka nebo ČSOB (Langová, 2019).

Doporučuje se rovněž pravidelné přispívání, které by mělo být sladěné s ostatními komunikačními kanály banky a podniku obecně. Dle Bubáka a Berana (2020) je důležitý rovněž empatický a proaktivní přístup, který spolu s rychlou a kvalitní komunikací zvyšuje loajalitu zákazníků. Proto je důležité, aby banky adekvátně reagovaly na všechny připomínky a otázky z publika a nevyhýbaly se z hlediska sentimentu negativním komentářům a v případě stížnosti se snažily nalézt konstruktivní řešení. Důležitá je rovněž reakce na pozitivní ohlas nebo poděkování. V tomto případě může postačit jen krátká odpověď s oslovením, případně dát najevo reakci likem, tak jako to dělá např. Banco do Brasil.

V neposlední řadě se bankám doporučuje používat analýzu sentimentu jako jeden z podpůrných nástrojů firemního SCRM a to nejen v prostředí sociální sítě Facebook, ale i v ostatních komunikačních kanálech. Nástroj může být pro podnik užitečným zdrojem dat, může dodávat další cenné informace o klientech, popisovat jejich chování, osobní preference nebo mínění o bance. Analýza sentimentu může najít uplatnění rovněž v optimalizaci komunikace. S její pomocí lze včasně detekovat negativní obsah komentáře a prioritně na něj zareagovat.

### 9.3 Limity práce

Řešené problémy a limity použitého softwaru nebo datových souborů jsou popsány chronologicky tak, jak probíhal celý proces sběru a zpracování podkladů pro analýzu sentimentu nebo obsah příspěvků.

Pro získání dat byl stěžejní skript kooperující spolu s několika knihovnamí implementovaný v jazyce Python. Skript dokázal zpracovat velké množství dat v relativně krátkém čase – všechny příspěvky za celý rok 2019 celkem 64 facebookových stránek byly bez menších problémů uloženy ve formátu xlsx do dvou hodin od spuštění (práce byla nakonec zpracována se 4 814 příspěvků z 20 stránek). Autorovi se nepodařilo skript upravit tak, aby získával rovněž typ příspěvků nebo komentáře uživatelů. Do roku 2018 se nabízelo využití API Facebooku, které tato data distribuovalo, v současné době je funkcionalita API značně omezená v zájmu ochrany citlivých dat uživatelů a podnikajících subjektů.

Komentáře uživatelů, reakce banky a typ nebo obsah příspěvků byly nakonec získány manuální cestou. V podobných případech lze použít jako alternativu nástroje pro dolování informací (tzv. Scraping Tools), nicméně s jedním z testovaných nástrojů nebyl autor zcela spokojen. Autor vyhodnotil obsah u 586 náhodně vybraných postů, které tvoří 12,5 % ze všech příspěvků, u kterých byl automaticky přiřazen sentiment. Časově náročnou práci lze v budoucnu nahradit např. textminingovým algoritmem strojového učení, který může být předmětem budoucího výzkumu.

Hromadný překlad textu do angličtiny v Google Translate se ukázal jako zcela dostačující pro zpracování práce. S jistou chybovostí je však potřeba počítat.

Software Orange a jeho extenze pro textovou analýzu posloužil pro zpracování většího množství dat zcela bez problémů, intuitivní prostředí je velikou výhodou. Jak je vidět na obrázcích č. 13 a 14 níže, analýza sentimentu slovníkovou metodou dle Liu Hu má drobné nedostatky. Kvalitu dosažených výsledků může v tomto případě ovlivnit předzpracování textu. Problematice vlivu předzpracování textu na výsledky analýzy se věnuje např. Patočka (2013), jehož výsledky jsou komentovány v kapitole 6.5. Nabízí se rovněž využití jiných algoritmů, Orange nabízí také metodu Vader. Úspěšnost několika testovaných klasifikačních algoritmů lze následně posoudit např. metodou křížové validace.

Pro vyšší relevanci vyhodnocení korelace mezi NPS banky a komentáři uživatelů by bylo potřeba se zaměřit na větší vzorek bankovních institucí. Rovněž dosažené výsledky z pohledu komentářů obecnostva a reakcí banky by ještě lépe vypovídaly v případě většího množství dat zpracovaného automaticky.



Robin White Terrible customer service

To se mi líbí · Odpovědět · 36 t

Obrázek 13 – Příklad chybně vyhodnoceného sentimentu komentáře. Metodou Liu Hu označen jako neutrální, metoda Vader vyhodnotila správně jako negativní. (Zdroj: Oficiální profil Bank of America na Facebooku)



Jerry Winegar Great bank, until you need customer service. I have been with Wells Fargo for years, that will change soon.

To se mi líbí · Odpovědět · 22 t



1

Obrázek 14 – Příklad komentáře s náznakem ironie. Vyhodnocen jako neutrální. (Zdroj: Oficiální profil Wells Fargo na Facebooku)

#### 9.4 Další možnosti zkoumání

Analýzu sentimentu a text mining obecně lze považovat za progresivní vědní obor, který nabízí spoustu možností pro výzkum. V teoretické části práce jsou některé z nich popsány detailněji. V souvislosti s výše popsanými výsledky se nabízí otázka, jak detekovat sentiment ve zbylých 148 případech, kdy z důvodu chybějícího textu nemohl být vyhodnocen. Je pravděpodobné, že se v budoucnu objeví praktické nástroje pro analýzu sentimentu z fotografie nebo videa. V odborných člancích lze nalézt několik zajímavých výzkumů.

V závěru kapitoly věnující se doporučení je zmíněna možná implementace automatické detekce negativních nebo relevantních komentářů s pomocí klasifikačních algoritmů, které mohou administrátorům výrazněji pomoci s filtrováním prioritních komentářů jako jsou stížnosti nebo dotazy.

Předmětem zkoumání může být rovněž analýza sentimentu bankovních institucí v čase a jaké objektivní faktory mají na sentiment obsažený v komunikaci největší vliv.

Bylo by rovněž zajímavé detailněji zkoumat sentiment napříč různými kulturami a objevit rozdíly ve způsobu komunikace jihokorejských, jihoamerických nebo evropských bank. Některé takové nuance lze pozorovat v kapitole popisující ve stručnosti charakter komunikace sledovaných institucí.

## 10 Závěr

Teoretická část se zabývá základními aspekty marketingové komunikace a blíže představuje současné trendy komunikace bankovních institucí. Jsou popsány teoretické aspekty CRM, představeny jsou rovněž výsledky výzkumů v oblasti sociálního CRM. Ve druhé části je stručně popsán text mining a podrobněji pak analýza sentimentu spolu s procesem zpracování dat.

Cílem praktické části je zjistit charakter komunikace 20 bank ze žebříčku S&P Global z roku 2019, které působí na sociální síti Facebook, s pomocí analýzy sentimentu identifikovat tón jejich komunikace a následné reakce uživatelů.

Sledované banky v roce 2019 nejvíce publikovaly příspěvky doplněné obrazovým materiálem a v převážné většině prezentovaly své produkty a služby. Ve dvou třetinách případů zveřejnily administrátoři příspěvky s pozitivním sentimentem, přičemž v komunikovaném obsahu se jeho zastoupení v průběhu roku výrazně neměnilo. Sentiment v komentářích uživatelů byl ze 43 % neutrální a 34 % pozitivní. Sentiment komentářů se neliší mezi příspěvky s různým obsahem. Podařila se prokázat slabá závislost mezi sentimentem příspěvku a sentimentem komentářů. Banky reagovaly téměř na polovinu všech zkoumaných komentářů s průměrnou časovou prodlevou necelých osmi hodin. Banky v reakci na komentáře používaly převážně neutrální komentář a prokazatelně více reagovaly na negativní obsah.

Výsledky se shodují s výsledky práce Kohouta (2018), ve které vybrané firmy rovněž publikovaly pozitivní posty a uživatelé nejvíce přidávali komentáře s neutrálním sentimentem. V obou shrnutích je patrné, že firmy prokazatelně více reagují na negativní obsah publika. Naopak odlišné výsledky předkládají Alamsyah a Indraswari (2017) nebo Lien (2017). Banky podle dvojice autorů prezentují spíše neutrální posty, dle Liena mají uživatelé o bankách spíše negativní mínění.

Teoretická i praktická část ukázaly význam analýzy sentimentu, a proto se institucím doporučuje implementace takového nástroje do SCRM procesů.

Algoritmy zpracování přirozeného jazyka i analýza sentimentu mají veliký potenciál a do budoucna budou moci nabídnout ještě pokročilejší využití v oblasti marketingové komunikace a sociálního CRM. Podniky, které tyto nástroje včas implementují a adekvátně využijí, budou mít oproti konkurenci nejspíše nemalou výhodu.

## 11 Seznam použitých zdrojů

### Knižní zdroje

1. BLAŽKOVÁ, Martina. *Jak využít internet v marketingu: krok za krokem k vyšší konkurenceschopnosti*. Praha: Grada, 2005. Manažer. ISBN 8024710951.
2. ČECH, Pavel a Vladimír BUREŠ. *Podniková informatika*. Hradec Králové: Gaudeamus, 2009. ISBN 9788070414798.
3. DOHNAL, Jan. *Řízení vztahů se zákazníky: procesy, pracovníci, technologie*. Praha: Grada, 2002. Management v informační společnosti. ISBN 80-247-0401-3.
4. FELDMAN, Ronen a James SANGER. *The text mining handbook: advanced approaches in analyzing unstructured data*. New York: Cambridge University Press, 2007. ISBN 978-0-521-83657-9.
5. HOMMEROVÁ, Dita. *CRM v podnikových procesech*. Praha: Grada, 2012. ISBN 978-80-247-4388-2.
6. CHMELAR Petr, HELLEBRAND David, HRUŠECKÝ Michal a BARTÍK Vladimír. Nalezení slovních kořenů v češtině. *Znalosti 2011: Sborník příspěvků 10. ročníku konference*. Stará Lesná: VŠB Technická univerzita Ostrava, 2011, s. 66-77. ISBN 978-80-248-2369-0.
7. KARLÍČEK, Miroslav. *Marketingová komunikace: jak komunikovat na našem trhu*. 2., aktualizované a doplněné vydání. Praha: Grada Publishing, 2016. ISBN 978-80-247-5769-8.
8. KOHOUT, Martin. *Sociální CRM se zaměřením na analýzu sentimentu*. Hradec Králové, 2018. Diplomová práce. Univerzita Hradec Králové.
9. KOTÍKOVÁ, Michaela. *Aplikace metod předzpracování při dolování znalostí z textových dat*. Brno, 2014. Diplomová práce. Mendelova univerzita v Brně.
10. KOTLER, Philip. *Moderní marketing: 4. evropské vydání*. Praha: Grada, 2007. ISBN 978-80-247-1545-2.
11. KOTLER, Philip a Kevin Lane KELLER. *Marketing management*. [14. vyd.]. Praha: Grada, 2013. ISBN 978-80-247-4150-5.
12. KRAJÍČEK, Jan. *Marketing v peněžnictví*. 1. vyd. Brno: Masarykova univerzita, 2005, 132 s. Distanční studijní opora. ISBN 80-210-3659-1.
13. KUCHAR, Vladimír. *Medonosný marketing: přitáhněte zákazníky – návody, rady a tipy pro vytvoření skutečně efektivního marketingového systému pro vaši firmu*. Brno: BizBooks, 2012. ISBN 978-80-265-0024-7.
14. LEHTINEN, Jarmo. *Aktivní CRM: řízení vztahů se zákazníky*. Praha: Grada, 2007. Expert (Grada). ISBN 9788024718149.

15. LIU, Bing. *Sentiment analysis: mining opinions, sentiments, and emotions*. New York, NY: Cambridge University Press, 2015. ISBN 978-1-107-01789-4.
16. MINER, Gary. *Practical text mining and statistical analysis for non-structured text data applications*. Waltham, MA: Academic Press, 2012. ISBN 978-0-12-386979-1.
17. PATOČKA, Michal. *Metody strojového učení pro analýzu sentimentu*. Plzeň, 2013. Diplomová práce. Západočeská univerzita v Plzni.
18. PETROVSKÝ, Jonáš. *Ziskávání a analýza textových dat pro oblast finančních trhů*. Brno, 2016. Diplomová práce. Mendelova univerzita v Brně.
19. PROCHÁZKA, Tomáš a Josef ŘEZNÍČEK. *Obsahový marketing*. Brno: Computer Press, 2014. ISBN 978-80-251-4152-6.
20. PŘIKRYLOVÁ, Jana. *Moderní marketingová komunikace*. 2., zcela přepracované vydání. Praha: Grada Publishing, 2019. Expert (Grada). ISBN 978-80-271-0787-2.
21. SAFKO, Lon a David K. BRAKE. *The social media bible: tactics, tools, and strategies for business success*. New Jersey: John Wiley & Sons, c2009. ISBN 978-0-470-41155-1.
22. SHIELDS, Morgan. *Research Methodology and Statistical Methods*. United Kingdom: ED-Tech Press, 2019. ISBN 978-1-78882-100-1.
23. SYCHRA, Martin. *Analýza sentimentu s využitím dolování dat*. Brno, 2016. Diplomová práce. Vysoké učení technické v Brně.
24. VESELOVSKÁ, Kateřina. *Sentiment analysis in Czech*. Praha: Ústav formální a aplikované lingvistiky, 2017b. Studies in computational and theoretical linguistics. ISBN 978-80-88132-03-5.
25. VOJTĚCHOVÁ, Kristýna. *Digitální komunikace bank s vybraným segmentem zákazníků*. Praha, 2017. Diplomová práce. Vysoká škola ekonomická v Praze.

### Internetové zdroje

26. 5 Reasons why Customer Retention is better than Customer Acquisition. *Wheelhouse Advisors* [online]. 2015a [cit. 2019-10-30]. Dostupné z: <http://www.wheelhouseadvisors.net/5-reasons-why-customer-retention-is-better-than-customer-acquisition/>
27. AGARWAL, Basant a Namita MITTAL. Optimal Feature Selection for Sentiment Analysis. *Computational Linguistics and Intelligent Text Processing* [online]. Berlin, Heidelberg: Springer Berlin Heidelberg, 2013, s. 13-24 [cit. 2019-10-20]. DOI: 10.1007/978-3-642-37256-8\_2. ISBN 978-3-642-37255-1. Dostupné z: [http://link.springer.com/10.1007/978-3-642-37256-8\\_2](http://link.springer.com/10.1007/978-3-642-37256-8_2)

28. AGARWAL, Rahul. The 5 Feature Selection Algorithms every Data Scientist should know. *Towards Data Science* [online]. 2019 [cit. 2019-10-20]. Dostupné z: <https://towardsdatascience.com/the-5-feature-selection-algorithms-every-data-scientist-need-to-know-3a6b566efd2>
29. AKYÜZ, İlker, Kadri Cemil AKYÜZ, Nadir ERSEN a Muhammet BEKER. A Research on the Customer Relationship Management in the Furniture and Other Forest Products Business (Istanbul Provincial Sample). *Kastamonu University Journal of Forestry Faculty* [online]. 2017, s. 88-98 [cit. 2019-11-15]. DOI: 10.17475/kastorman.296506. ISSN 1303-2399. Dostupné z: <http://dergipark.gov.tr/doi/10.17475/kastorman.296506>
30. ALAMSYAH, Andry a Anindia Aulia INDRASWARI. Social Network and Sentiment Analysis for Social Customer Relationship Management in Indonesia Banking Sector. *Advanced Science Letters* [online]. 2017, s. 3808-3812 [cit. 2020-03-13]. DOI: 10.1166/asl.2017.9279. ISSN 1936-6612. Dostupné z: <http://www.ingentaconnect.com/content/10.1166/asl.2017.9279>
31. ANG, Lawrence. Community relationship management and social media. *Journal of Database Marketing & Customer Strategy Management* [online]. 2011, s. 31-38 [cit. 2019-11-20]. DOI: 10.1057/dbm.2011.3. ISSN 1741-2447. Dostupné z: <http://link.springer.com/10.1057/dbm.2011.3>
32. BACHMANN, Pavel a Kateřina KANTOROVÁ. From customer orientation to social CRM. New insights from Central Europe. *Scientific papers of the University of Pardubice. Series D, Faculty of Economics and Administration* [online]. 2016, s. 29-41 [cit. 2019-11-25]. Dostupné z: <https://dk.upce.cz/handle/10195/64714>
33. BAILIS, Rochelle. The State of Influencer Marketing: 10 Influencer Marketing Statistics to Inform Where You Invest. *BigCommerce* [online]. 2019 [cit. 2019-11-01]. Dostupné z: <https://www.bigcommerce.com/blog/influencer-marketing-statistics/#conclusion>
34. BAIRD, Carolyn a Gautam PARASNIS. From social media to Social CRM. *IBM* [online]. 2011 [cit. 2019-11-26]. Dostupné z: <https://www.ibm.com/downloads/cas/OV3V63GX>
35. BAIRD, Carolyn. From social media to Social CRM: The new frontier in customer relationship management. *IBM* [online]. 2011 [cit. 2019-11-15]. Dostupné z: <https://www.ibm.com/services/us/gbs/thoughtleadership/ibv-social-crm-whitepaper.html>
36. BARRY, Chris, Rob MARKEY, Eric ALMQUIST a Chris BRAHM. Putting social media to work. *Bain & Company* [online]. 2011 [cit. 2019-11-15]. Dostupné z: <https://www.bain.com/insights/putting-social-media-to-work/>
37. BELYH, Anastasia. Complete Comparison of the Major Marketing Channels. *Cleverism* [online]. 2017 [cit. 2019-11-01]. Dostupné z: <https://www.cleverism.com/complete-comparison-major-marketing-channels/>
38. BOHLIN, Erik, Aijaz A. SHAIKH a Payam HANAFIZADEH. Social Network Banking. *International Journal of E-Business Research* [online]. 2018, s. 1-13 [cit. 2020-02-11]. DOI: 10.4018/IJEER.2018040101. ISSN 1548-1131. Dostupné z: <http://services.igi-global.com/resolvedoi/resolve.aspx?doi=10.4018/IJEER.2018040101>



39. BOLLEN, Johan, Huina MAO a Xiaojun ZENG. Twitter mood predicts the stock market. *Journal of Computational Science* [online]. 2011, s. 1-8 [cit. 2019-10-25]. DOI: 10.1016/j.jocs.2010.12.007. ISSN 18777503. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S187775031100007X>
40. BRYCHCÍN, Tomáš a Miloslav KONOPÍK. HPS: High precision stemmer. *Information Processing & Management* [online]. 2015, s. 68-91 [cit. 2019-10-29]. DOI: 10.1016/j.ipm.2014.08.006. ISSN 03064573. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S0306457314000843>
41. BRYNLEY-JONES, Luke. Traditional CRM vs Social CRM (Infographic). *Econsultancy* [online]. 2012 [cit. 2019-11-28]. Dostupné z: <https://econsultancy.com/traditional-crm-vs-social-crm-infographic/>
42. BUBÁK, Zdeněk a Karel BERAN. Tři pilíře moderního bankovníctví pro rok 2020 – digitální onboarding, proaktivní komunikace a empatie. *Finparáda* [online]. 2020 [cit. 2020-02-10]. Dostupné z: <https://www.finparada.cz/6139-Tri-pilire-moderniho-bankovnictvi.aspx>
43. BUDAI, David. Češi ze Semantic Visions vidí i budoucnost: Příběh firmy, která globálním gigantům šetří miliardy. *StartupJobs* [online]. 2020 [cit. 2020-03-16]. Dostupné z: <https://www.startupjobs.cz/newsroom/semantic-visions-frantisek-vrabel-rozhovor-pribeh-firmy>
44. Co je ověřená stránka nebo profil? *Facebook – Centrum nápovědy* [online]. 2020 [cit. 2020-03-13]. Dostupné z: <https://www.facebook.com/help/196050490547892>
45. D'ANDREA, Alessia, Fernando FERRI, Patrizia GRIFONI a Tiziana GUZZO. Approaches, Tools and Applications for Sentiment Analysis Implementation. *International Journal of Computer Applications* [online]. 2015, s. 26-33 [cit. 2019-10-01]. DOI: 10.5120/ijca2015905866. ISSN 09758887. Dostupné z: <http://www.ijcaonline.org/research/volume125/number3/dandrea-2015-ijca-905866.pdf>
46. Digital Ad Spending to Surpass TV Next Year. *eMarketer* [online]. 2016 [cit. 2019-11-11]. Dostupné z: <https://www.emarketer.com/Article/Digital-Ad-Spending-Surpass-TV-Next-Year/1013671>
47. ENBERG, Jasmine. Global Digital Ad Spending 2019: Digital Accounts for Half of Total Media Ad Spending Worldwide. *eMarketer* [online]. 2019 [cit. 2020-03-16]. Dostupné z: <https://www.emarketer.com/content/global-digital-ad-spending-2019>
48. Etický kodex ČBA. *Česká bankovní asociace* [online]. 2012 [cit. 2020-02-01]. Dostupné z: <https://cbaonline.cz/eticky-kodex-cba>
49. FOX, Zoe. 5 Best Practices for Financial Institutions on Facebook. *Mashable* [online]. 2011 [cit. 2020-02-19]. Dostupné z: <https://mashable.com/2011/10/24/banks-facebook/?europe=true>
50. GALETTO, Molly. What is Interactive Marketing? *NGDATA* [online]. 2016 [cit. 2019-11-01]. Dostupné z: <https://www.ngdata.com/what-is-interactive-marketing/>

51. GARRIDO, Francis a Saqib CHAUDHRY. The world's 100 largest banks. *S&P Global Market Intelligence* [online]. 2019 [cit. 2020-01-15]. Dostupné z: <https://www.spglobal.com/marketintelligence/en/news-insights/latest-news-headlines/50964984>
52. GONZÁLEZ-IBÁÑEZ, Roberto, Smaranda MURESAN a Nina WACHOLDER. Identifying Sarcasm in Twitter: A Closer Look. *Proceedings of the 49th Annual Meeting of the Association for Computational Linguistics: Human Language Technologies* [online]. Portland, Oregon, USA: Association for Computational Linguistics, 2011, s. 581-586 [cit. 2019-10-20]. Dostupné z: <https://www.aclweb.org/anthology/P11-2102.pdf>
53. GREENBERG, Paul. The impact of CRM 2.0 on customer insight. *Journal of Business & Industrial Marketing* [online]. 2010, s. 410-419 [cit. 2019-11-15]. DOI: 10.1108/08858621011066008. ISSN 0885-8624. Dostupné z: <https://www.emerald.com/insight/content/doi/10.1108/08858621011066008/full/html>
54. HANSEN, Greg. What is Marketing 3.0? *Startup Grind* [online]. 2017 [cit. 2019-11-10]. Dostupné z: <https://www.startupgrind.com/blog/what-is-marketing-30/>
55. HANUŠ, Ondřej. Trendy v CRM: Šestidílný seriál článků o trendech v CRM. *CRM fórum* [online]. 2015 [cit. 2019-11-10]. Dostupné z: <https://www.crmforum.cz/trendy/trendy-v-crm.html>
56. HUBBEL, Anna. Facebook Announces API Restrictions for Privacy Protection. *Advertisemint* [online]. 2018 [cit. 2020-03-17]. Dostupné z: <https://www.advertisemint.com/facebook-announces-api-restrictions-for-privacy-protection/>
57. HUTTON, Graeme a Maggie FOSDICK. The Globalization of Social Media. *Journal of Advertising Research* [online]. 2011, s. 564-570 [cit. 2019-11-20]. DOI: 10.2501/JAR-51-4-564-570. ISSN 0021-8499. Dostupné z: <http://www.journalofadvertisingresearch.com/lookup/doi/10.2501/JAR-51-4-564-570>
58. CHAFFEY, Dave. Social CRM Strategy Definition. *Smart Insights* [online]. 2013 [cit. 2019-11-15]. Dostupné z: <https://www.smartinsights.com/customer-relationship-management/social-crm/social-crm-strategy/>
59. ISRAEL, Shel. Dell Modernizes Ideastorm. *Forbes* [online]. 2012 [cit. 2019-11-25]. Dostupné z: <https://www.forbes.com/sites/shelisrael/2012/03/27/dell-modernizes-ideastorm/#7bf85d06405a>
60. JAVŮREK, Karel. Tomáš Mikolov: Zkoumám umělou inteligenci ve Facebooku. Myslím, že se jí nemusíme bát. *Connect* [online]. 2019 [cit. 2020-03-16]. Dostupné z: <https://connect.zive.cz/clanky/tomas-mikolov-zkoumam-umelou-inteligenci-ve-facebooku-myslim-ze-se-ji-nemusime-bat/sc-320-a-198404/default.aspx>
61. JEŽEK, Karel a Josef STEINBERGER. Sumarizace textů. *DATAKON 2010: sborník databázové konference* [online]. 2010 [cit. 2019-09-20]. Dostupné z: <http://textmining.zcu.cz/publications/SumarizDATAKON.pdf>

62. JOSHI, Aditya, Pushpak BHATTACHARYYA a Mark J. CARMAN. Automatic Sarcasm Detection. *ACM Computing Surveys* [online]. 2017, s. 1-22 [cit. 2019-10-25]. DOI: 10.1145/3124420. ISSN 03600300. Dostupné z: <http://dl.acm.org/citation.cfm?doid=3145473.3124420>
63. KASÍK, Pavel a Matouš LÁZŇOVSKÝ. „Málem jsem zabil bratra!“ Nový překladač je lepší, chyby jsou vtipnější. *Idnes.cz* [online]. 2017 [cit. 2020-03-17]. Dostupné z: [https://www.idnes.cz/technet/internet/google-prekladac-neuronove-site-google-translate-srovnani-test.A170509\\_130949\\_sw\\_internet\\_pka](https://www.idnes.cz/technet/internet/google-prekladac-neuronove-site-google-translate-srovnani-test.A170509_130949_sw_internet_pka)
64. KEMP, Simon. DIGITAL 2020: 3.8 BILLION PEOPLE USE SOCIAL MEDIA. *We Are Social* [online]. 2020 [cit. 2020-03-16]. Dostupné z: <https://wearesocial.com/blog/2020/01/digital-2020-3-8-billion-people-use-social-media>
65. Komentované zprávy bank: Infolinka ČSOB umí komunikovat s neslyšícími a KB zkrátila ceník. *Bankovní poplatky* [online]. 2019 [cit. 2020-02-01]. Dostupné z: <https://www.bankovnipoplatky.cz/38209>
66. KRALJ NOVAK, Petra, Jasmina SMAILOVIĆ, Borut SLUBAN, Igor MOZETIČ a Matjaz PERC. Sentiment of Emojis. *PLOS ONE* [online]. 2015, [cit. 2019-10-20]. DOI: 10.1371/journal.pone.0144296. ISSN 1932-6203. Dostupné z: <https://dx.plos.org/10.1371/journal.pone.0144296>
67. KRUPKA, Jaroslav. Češi a reklama: postoje se nemění, jen zostrují. *Mediář* [online]. 2016 [cit. 2019-11-01]. Dostupné z: <https://www.mediar.cz/cesi-a-reklama-polarizuji-se-ale-nazor-nemeni/>
68. KUČERA, Petr. Mažu si tě z přátel. Banka končí na Facebooku, sklízí posměch. *Peníze.cz* [online]. 2019 [cit. 2020-02-01]. Dostupné z: <https://www.penize.cz/osobni-ucty/406039-mazu-si-te-z-pratel-banka-konci-na-facebooku-sklizi-posmech>
69. LANGOVÁ, Magdaléna. Reklamní kampaň bez akreditace? Školy si Abecedu peněz od České spořitelny chválí. *Lidovky* [online]. 2019 [cit. 2020-03-13]. Dostupné z: [https://www.lidovky.cz/domov/reklamni-kampan-bez-akreditace-skoly-si-abecedu-penez-od-ceske-sporitelny-chvali.A190925\\_173932\\_In\\_domov\\_ele](https://www.lidovky.cz/domov/reklamni-kampan-bez-akreditace-skoly-si-abecedu-penez-od-ceske-sporitelny-chvali.A190925_173932_In_domov_ele)
70. LIEN, Anders. *Brand sentiment analysis of the Norwegian banking sector* [online]. Trondheim, 2017 [cit. 2020-03-13]. Master thesis. Norwegian University of Science and Technology. Dostupné z: <https://ntnuopen.ntnu.no/ntnu-xmlui/handle/11250/2456869>
71. LIU, Bing a Lei ZHANG. A Survey of Opinion Mining and Sentiment Analysis. *Mining Text Data* [online]. Boston, MA: Springer US, 2012, s. 415-463 [cit. 2019-10-01]. DOI: 10.1007/978-1-4614-3223-4\_13. ISBN 978-1-4614-3222-7. Dostupné z: [http://link.springer.com/10.1007/978-1-4614-3223-4\\_13](http://link.springer.com/10.1007/978-1-4614-3223-4_13)
72. MALIK, Radka a Hana PAVLASOVÁ. Sentiment analýza médií. *Medium* [online]. 2018 [cit. 2019-10-15]. Dostupné z: <https://medium.com/@radkamalik/medi%C3%A1ln%C3%AD-obraz-druh%C3%A9-p%C5%99%C3%ADm%C3%A9-prezidentsk%C3%A9-volby-v-%C4%8Dr-m%C3%ADra-a-sentiment-medializace-jednotliv%C3%BDch-2910da7d3177>

73. MÄNTYLÄ, Mika V., Daniel GRAZIOTIN a Miikka KUUTILA. The evolution of sentiment analysis – A review of research topics, venues, and top cited papers. *Computer Science Review* [online]. 2018, s. 16-32 [cit. 2019-10-01]. DOI: 10.1016/j.cosrev.2017.10.002. ISSN 15740137. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S1574013717300606>
74. MEHELMI, Heba El a Heba SADEK. Investigating the usage of social customer relationship management (SCRM) and its impact on firm performance in the mobile telecommunication services: Egypt case. *Journal of Business & Retail Management Research* [online]. 2019, s. 282-291 [cit. 2019-11-21]. DOI: 10.24052/JBRMR/V13IS03/ART-25. ISSN 17518202. Dostupné z: <http://jbrmr.com/details&cid=479>
75. MILLER, Jason. 5 Simple Metrics to Track Your Social Media Efforts. *Social Media Examiner* [online]. 2012 [cit. 2019-11-25]. Dostupné z: <https://www.socialmediaexaminer.com/metrics-to-track-your-social-media-efforts/>
76. MITIC, Miljana a Alexandros KAPOULAS. Understanding the role of social media in bank marketing. *Marketing Intelligence & Planning* [online]. 2012, s. 668-686 [cit. 2020-02-19]. DOI: 10.1108/02634501211273797. ISSN 0263-4503. Dostupné z: <https://www.emerald.com/insight/content/doi/10.1108/02634501211273797/full/html>
77. MORGAN, Jacob. What is Social CRM? An Introduction. *Jacob Morgan: Future of Organization* [online]. 2010 [cit. 2019-11-26]. Dostupné z: <https://thefutureorganization.com/what-is-social-crm-an-introduction/>
78. NADEEM, Mohammed. Social Customer Relationship Management (SCRM): How Connecting Social Analytics to Business Analytics Enhances Customer Care and Loyalty? *International Journal of Business and Social Science* [online]. 2012, s. 88-102 [cit. 2019-11-15]. Dostupné z: [https://www.researchgate.net/publication/269039312\\_Social\\_Customer\\_Relationship\\_Management\\_SCRM\\_How\\_connecting\\_social\\_analytics\\_to\\_business\\_analytics\\_enhances\\_customer\\_care\\_and\\_loyalty](https://www.researchgate.net/publication/269039312_Social_Customer_Relationship_Management_SCRM_How_connecting_social_analytics_to_business_analytics_enhances_customer_care_and_loyalty)
79. NACHER, Patrik. Reklamní gigant s malou důvěrou. *Bankovní poplatky* [online]. 2005 [cit. 2020-02-05]. Dostupné z: <https://www.bankovnipoplatky.cz/clanky/reportaz/reklamni-gigant-s-malou-duverou-strategie-24-10-2005-357.html>
80. OLBRICHOVÁ, Silvie. Reklamní kampaně bank: Která z nich boduje? *Ušetřeno.cz* [online]. 2015 [cit. 2020-02-01]. Dostupné z: <https://www.usetreno.cz/reklamni-kampane-bank-analyza-2015/>
81. Online data (OLA). *NetMonitor* [online]. 2019 [cit. 2019-10-15]. Dostupné z: <http://www.netmonitor.cz/online-data-ola>
82. OPÁLKOVÁ, Markéta. Jazykové korpusy. *Ikaros* [online]. 2008 [cit. 2019-09-15]. Dostupné z: <https://ikaros.cz/jazykove-korpusy>
83. ORTIZ-OSPINA, Esteban. The Rise of Social Media. *Our World in Data* [online]. 2019 [cit. 2019-11-01]. Dostupné z: <https://ourworldindata.org/rise-of-social-media>

84. PETKEVIČ, Vladimír. Disambiguace. *CzechEncy – Nový encyklopedický slovník češtiny* [online]. 2017 [cit. 2019-09-10]. Dostupné z: <https://www.czechency.org/slovník/DISAMBIGUACE%20/%20DESAMBIGUACE#disambiguace,%20desambiguace>
85. POTTS, Christopher. Sentiment Symposium Tutorial: Lexicons. Stanford University [online]. 2011 [cit. 2019-10-21]. Dostupné z: <http://sentiment.christopherpotts.net/lexicons.html#tab:mpqa>
86. PRETNAR, Ajda. Text Analysis: New Features. *Orange Data Mining* [online]. 2017 [cit. 2020-03-17]. Dostupné z: <https://orange.biolab.si/blog/2017/08/04/text-analysis-new-features/>
87. REITZ, Joan M. Stopword. *ODLIS – Online Dictionary for Library and Information Science* [online]. 2014 [cit. 2019-09-15]. Dostupné z: [https://www.abc-clio.com/ODLIS/odlis\\_s.aspx](https://www.abc-clio.com/ODLIS/odlis_s.aspx)
88. RILOFF, Ellen, Janyce WIEBE a Theresa WILSON. Learning subjective nouns using extraction pattern bootstrapping. *Proceedings of the seventh conference on Natural language learning* [online]. Morristown, NJ, USA: Association for Computational Linguistics, 2003, s. 25-32 [cit. 2019-10-25]. DOI: 10.3115/1119176.1119180. Dostupné z: <http://portal.acm.org/citation.cfm?doid=1119176.1119180>
89. ŘEHÁKOVÁ, Markéta. Rychlost a kvalita komunikace je pro klienty bank a pojišťoven důležitá. Nejlépe si v testu vedla Komerční banka. *Hospodářské noviny* [online]. 2017 [cit. 2020-02-01]. Dostupné z: <https://byznys.ihned.cz/c1-65941740-rychlost-a-kvalita-komunikace-je-pro-klienty-bank-a-pojistoven-dulezita-nejlepe-si-v-testu-vedla-komercni-banka>
90. SEDLÁČEK, Petr. Text mining a jeho možnosti (aplikace). *Fakulta informatiky: Masarykova univerzita* [online]. 2003 [cit. 2019-09-20]. Dostupné z: <https://www.fi.muni.cz/usr/jkucera/pv109/2003p/xsedlac5.htm>
91. SEDLÁK, Jan. Čína kompletně zablokovala WhatsApp. Facebooku už v zemi nefunguje. *Lupa.cz* [online]. 2017 [cit. 2020-03-13]. Dostupné z: <https://www.lupa.cz/aktuality/cina-kompletne-zablokovala-whatsapp-facebooku-uz-v-zemi-nefunguje-nic/>
92. Sentiment Analysis Explained. *Lexalytics* [online]. 2019 [cit. 2019-09-01]. Dostupné z: <https://www.lexalytics.com/technology/sentiment-analysis>
93. Sentiment Analysis: Live Demo. *The Stanford Natural Language Processing Group* [online]. 2013 [cit. 2019-10-15]. Dostupné z: <http://nlp.stanford.edu:8080/sentiment/rntnDemo.html>
94. Sentiment. *Dictionary.com* [online]. 2019 [cit. 2019-09-01]. Dostupné z: <https://www.dictionary.com/browse/sentiment>

95. SHEN, Gang a Xiong HUANG. *Advanced Research on Electronic Commerce, Web Application, and Communication* [online]. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011 [cit. 2019-11-10]. Communications in Computer and Information Science. DOI: 10.1007/978-3-642-20370-1. ISBN 978-3-642-20369-5. Dostupné z: <https://link.springer.com/book/10.1007/978-3-642-20367-1>
96. SINGH, Digvijay. Sarcasm Detection: Step towards Sentiment Analysis. *Towards Data Science* [online]. 2019 [cit. 2019-10-05]. Dostupné z: <https://towardsdatascience.com/sarcasm-detection-step-towards-sentiment-analysis-84cb013bb6db>
97. SIRIWARDANA, Anushka a Ravindra DISSANAYAKE. Social Customer Relationship Management (SCRM) in Contemporary Business Era. *International Journal of Business and Management Invention* [online]. 2018, s. 59-64 [cit. 2019-11-24]. Dostupné z: [https://www.researchgate.net/publication/328345710\\_Social\\_Customer\\_Relationship\\_Management\\_SCRM\\_in\\_Contemporary\\_Business\\_Era](https://www.researchgate.net/publication/328345710_Social_Customer_Relationship_Management_SCRM_in_Contemporary_Business_Era)
98. Smart Communications Survey Reveals Enterprises Risk Losing Customers if They Don't Communicate Effectively. *Smart Communications* [online]. 2018 [cit. 2020-02-01]. Dostupné z: <https://www.smartcommunications.com/smart-communications-survey/>
99. STEINBERGER, Josef, Mohamed EBRAHIM, Maud EHRMANN, et al. Creating sentiment dictionaries via triangulation. *Decision Support Systems* [online]. 2012, s. 689-694 [cit. 2019-10-25]. DOI: 10.1016/j.dss.2012.05.029. ISSN 01679236. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S0167923612001406>
100. STEPHEN, Elizabeth. 89 % of global banks are investing in new customer communication channels – shouldn't you? *Striata* [online]. 2015 [cit. 2020-02-01]. Dostupné z: <https://www.striata.com/posts/89-of-global-banks-are-investing-in-new-customer-communication-channels-shouldnt-you/>
101. ŠPERKOVÁ, Lucie. Unstructured Data Analysis from Facebook Banking Sites. *Acta Informatica Pragensia* [online]. 2014, s. 154-167 [cit. 2020-03-13]. DOI: 10.18267/j.aip.44. ISSN 18054951. Dostupné z: <http://aip.vse.cz/doi/10.18267/j.aip.44.html>
102. ŠTANCLOVÁ, Lucie. Customer Experience – technologie, které pomáhají zlepšit zkušenosti zákazníků. *CRM fórum* [online]. 2016 [cit. 2019-11-15]. Dostupné z: <https://www.crmforum.cz/reseni/customer-experience-technologie-ktere-pomahaji-zlepsit-zkusenosti-zakazniku.html>
103. TAYLOR, Christine. Structured vs. Unstructured Data. *Datamation* [online]. 2018 [cit. 2020-03-16]. Dostupné z: <https://www.datamation.com/big-data/structured-vs-unstructured-data.html>
104. VAPNIK, Vladimir. *Estimation of Dependences Based on Empirical Data* [online]. New York, N.Y: Springer New York, 2006 [cit. 2019-10-08]. Information Science and Statistics. DOI: 10.1007/0-387-34239-7. ISBN 978-0-387-30865-4. Dostupné z: <https://link.springer.com/book/10.1007/0-387-34239-7>

105. VESELOVSKÁ, Kateřina a Ondřej BOJAR. Czech SubLex 1.0. *LINDAT/CLARIN: Centrum jazykové výzkumné infrastruktury v České republice* [online]. 2013 [cit. 2019-10-19]. Dostupné z: <https://lindat.mff.cuni.cz/repository/xmlui/handle/11858/00-097C-0000-0022-FF60-B>
106. VESELOVSKÁ, Kateřina. Postojová analýza. *CzechEncy – Nový encyklopedický slovník češtiny* [online]. 2017a [cit. 2019-09-05]. Dostupné z: <https://www.czechency.org/slovník/POSTOJOV%C3%81%20ANAL%C3%9DZA>
107. Všeobecná prezentace o Finanční skupině ČS. *Česká spořitelna* [online]. 2019 [cit. 2020-02-10]. Dostupné z: [https://www.csas.cz/static\\_internet/cs/Obecne\\_informace/FSCS/CS/Prilohy/vseobecna\\_prezentace.pdf](https://www.csas.cz/static_internet/cs/Obecne_informace/FSCS/CS/Prilohy/vseobecna_prezentace.pdf)
108. WAN, Jiangping a Leqi XIE. A Bibliometric Review of Research Trends in Social CRM. *WHICEB 2018 Proceedings* [online]. 2018, s. 358-365 [cit. 2019-11-20]. Dostupné z: <https://aisel.aisnet.org/whiceb2018/63/>
109. What really builds customer loyalty? *Wheelhouse Advisors* [online]. 2015b [cit. 2019-10-30]. Dostupné z: [http://www.wheelhouseadvisors.net/what-really-builds-customer-loyalty/?utm\\_source=Wyzowl&utm\\_medium=Blog&utm\\_campaign=5%20Reasons%20why%20Customer%20Retention%20is%20better%20than%20Customer%20Acquisition%20](http://www.wheelhouseadvisors.net/what-really-builds-customer-loyalty/?utm_source=Wyzowl&utm_medium=Blog&utm_campaign=5%20Reasons%20why%20Customer%20Retention%20is%20better%20than%20Customer%20Acquisition%20)

## 12 Seznam tabulek, grafů a obrázků

### Tabulky

Tabulka 1 – Porovnání internetu s ostatními médii (zdroj: Blažková (2005, s. 14) a Belyh (2017)).	6
Tabulka 2 – Porovnání CRM a SCRM (zdroj: Brynley-Jones (2012))	22
Tabulka 3 – Finální výběr bankovních institucí (zdroj: Oficiální profily na Facebooku)	42
Tabulka 4 – Popisná statistika sentimentu příspěvků (zdroj: Vlastní zpracování)	56
Tabulka 5 – Korelační tabulka mezi sentimentem příspěvku a interakcemi uživatelů (zdroj: Vlastní zpracování)	59
Tabulka 6 – Popisná statistika sentimentu uživatelských komentářů (zdroj: Vlastní zpracování)	60
Tabulka 7 – Popisná statistika sentimentu uživatelských komentářů v závislosti na obsahu příspěvku (zdroj: Vlastní zpracování)	62
Tabulka 8 – Korelační tabulka mezi sentimentem příspěvku a sentimentem komentáře (zdroj: Vlastní zpracování)	63
Tabulka 9 – Korel. tab. mezi NPS banky a sentimentem komentářů (zdroj: Vlastní zpracování)	64
Tabulka 10 – Popisná stat. doby reakcí na uživatelské komentáře (zdroj: Vlastní zpracování)	66
Tabulka 11 – Popisná stat. sentimentu reakcí bankovních institucí (zdroj: Vlastní zpracování)	67
Tabulka 12 – Kontingenční tabulka četností reakcí banky a sentimentu uživatelských komentářů (zdroj: Vlastní zpracování)	69
Tabulka 13 – Korelační tabulka mezi sentimentem komentáře a sentimentem reakcí banky (zdroj: Vlastní zpracování)	70

### Grafy

Graf 1 – Publikované typy příspěvků (Zdroj: Vlastní zpracování)	55
Graf 2 – Publikované obsahy příspěvků (zdroj: Vlastní zpracování)	56
Graf 3 – Podíly polarity sentimentu v příspěvcích bank (zdroj: Vlastní zpracování)	57
Graf 4 – Podíly polarity sentimentu v příspěvcích bank v první polovině roku 2019 (zdroj: Vlastní zpracování)	58
Graf 5 – Podíly polarity sentimentu v příspěvcích bank ve druhé polovině roku 2019 (zdroj: Vlastní zpracování)	58
Graf 6 – Podíly polarity sentimentu v komentářích uživatelů (zdroj: Vlastní zpracování)	61
Graf 7 – Síla testu v závislosti na velikosti vzorku (zdroj: Statistica)	64
Graf 8 – Míra reakcí bankovních institucí na uživatelské komentáře (zdroj: Vlastní zpracování)	65
Graf 9 – Doba reakce bankovních institucí (zdroj: Vlastní zpracování)	66
Graf 10 – Podíly polarity sentimentu v reakcích bank. institucí (zdroj: Vlastní zpracování)	68
Graf 11 – Relativní četnost reakce banky v závislosti na sentimentu uživatelského komentáře (zdroj: Vlastní zpracování)	69



## Obrázky

Obrázek 1 – Segmentace trhu (zdroj: Krajíček (2005)) .....	10
Obrázek 2 – Členění retailového bankovníctví v ČR (zdroj: Česká spořitelna (2019)) .....	11
Obrázek 3 – Architektura CRM (zdroj: Čech & Bureš (2009, s. 138)).....	16
Obrázek 4 – Výzkumné oblasti text miningu (zdroj: Miner (2012)).....	24
Obrázek 5 – Proces text miningu (zdroj: Miner (2012)).....	25
Obrázek 6 – Proces analýzy sentimentu (zdroj: D'Andrea et al. (2015) a Liu (2015)).....	32
Obrázek 7 – Fragment MPQA slovníku (zdroj: Potts (2011)) .....	34
Obrázek 8 – Stromová struktura rozboru věty (zdroj: The Stanford Natural Language Processing Group (2013)).....	37
Obrázek 9 – Schéma sběru a zpracování dat pro analýzu sentimentu příspěvků (zdroj: Vlastní zpracování).....	44
Obrázek 10 – Schéma využitých komponent v programu Orange (zdroj: Vlastní zpracování).....	46
Obrázek 11 – Ukázka komponenty Word Cloud v programu Orange (zdroj: Vlastní zpracování) .	47
Obrázek 12 – Vybrané příspěvky pro ukázkou. (Zdroj: Oficiální profily na Facebooku) .....	54
Obrázek 13 – Příklad chybně vyhodnoceného sentimentu komentáře. (Zdroj: Oficiální profil Bank of America na Facebooku) .....	76
Obrázek 14 – Příklad komentáře s náznakem ironie. (Zdroj: Oficiální profil Wells Fargo na Facebooku).....	76

## 13 Seznam zkratek

API – Application Programming Interface	SIM – Social Influence Marketing Score
BBVA – Banco Bilbao Vizcaya Argentaria	SOV – Share of Voice
BI – Business Intelligence	SVM – Support Vector Machines
CoRM – Community Relationship Management	UOB – United Overseas Bank
CRM – Customer Relationship Management	URL – Uniform Resource Locator
CSR – Společenská odpovědnost firem	
ČS – Česká spořitelna	
ČSOB – Československá obchodní banka	
DBS – Development Bank of Singapore	
ERP – Enterprise Resource Planning	
GPOMS – Google-Profile of Mood State	
HSBC – Hongkong and Shanghai Banking Corporation	
HTML – HyperText Markup Language	
ICT – Information and Communication Technologies	
IS – Information Systém	
KB – Kookmin Bank	
MPQA – MultiPerspective Question Answering	
NHL – National Hockey League	
NLP – Natural Language Processing	
NPS – Net Promoter Score	
OCBC – Oversea-Chinese Banking Corporation	
OECD – Organisation for European Economic Cooperation	
OLAP – On-Line Analytical Processing)	
PDT – Prague Dependency Treebank	
PIN – Personal Identification Number	
POS – Part-of-speech	
RBC – Royal Bank of Canada	
ROI – Return On Investments	
SBI – State Bank of India	
SCM – Supply chain management	
SCRM – Social Customer Relationship Management	

## 14 Přílohy

- 1) Tabulka: 100 největších světových bank dle aktiv za rok 2019 (zdroj: Garrido & Chaudhry (2019))
- 2) Tabulka – Základní charakteristiky vybraných bank (zdroj: Vlastní zpracování)
- 3) Tabulka – Počty publikovaných příspěvků dle typu postu a typu obsahu (zdroj: Vlastní zpracování)
- 4) Tabulka – Popisná statistika sentimentu v příspěvcích bank, 1. část (zdroj: Vlastní zpracování)
- 5) Tabulka – Popisná statistika sentimentu v příspěvcích bank, 2. část (zdroj: Vlastní zpracování)
- 6) Tabulka – Popisná statistika sentimentu v komentářích uživatelů, 1. část (zdroj: Vlastní zpracování)
- 7) Tabulka – Popisná statistika sentimentu v komentářích uživatelů, 2. část (zdroj: Vlastní zpracování)
- 8) Tabulka – Popisná statistika doby reakcí bank na uživatelské komentáře, 1. část (zdroj: Vlastní zpracování)
- 9) Tabulka – Popisná statistika doby reakcí bank na uživatelské komentáře, 2. část (zdroj: Vlastní zpracování)
- 10) Tabulka – Popisná statistika sentimentu v reakcích bank, 1. část (zdroj: Vlastní zpracování)
- 11) Tabulka – Popisná statistika sentimentu v reakcích bank, 2. část (zdroj: Vlastní zpracování)



Název banky	NPS	Počet postů za rok 2019 celkem	Počet postů s detekovaným sentimentem	Podíl liků na post	Podíl komentářů na post	Podíl sdílení na post	Nejčastější slova v postech
State Bank of India	49	687	680	26 115	133	3	sbi, offer, download
Itaú Unibanco Holding SA	29	182	174	7 549	286	1	look, read, book
Banco Bilbao Vizcaya Argentaria SA	9	645	640	12	2	4	bbva, bank, new
Banco Bradesco SA	20	59	54	27 522	968	435	bradesco, start, music
Capital One Financial Corp.	18	134	131	255	60	4	cardhold, reward, card
Caixa Econômica Federal	12	204	180	747	215	8	caixa, withdraw, 2019
Banco do Brasil SA	4	403	399	5 862	175	8	show, Brasil, video
Bank of America Corp.	18	470	467	137	32	1	bank, America, learn
Citigroup Inc.	-8	144	134	5 710	49	6	citi, learn, support
Wells Fargo & Co.	14	153	151	184	92	4	help, today, account
Shinhan Financial Group Co. Ltd.	21	347	331	1 003	341	7	shinhan, event, winner
United Overseas Bank Ltd.	60	91	88	571	4	1	uob, art, year
DBS Group Holdings Ltd.	19	45	45	6	1	0	social, enterprise, business
Société Générale SA	N/A	46	46	34	6	0	rugbi, team, Japan
Bank of Nova Scotia	20	209	208	103	13	11	perspect, check, scotia
Commonwealth Bank of Australia	-3	116	116	675	336	24	better, custom, update
KB Financial Group Inc.	-4	276	225	1 070	194	1	kb, world, change
Royal Bank of Canada	27	212	210	120	43	6	rbc, discover, help
Intesa Sanpaolo SpA	19	34	34	10	2	4	intesa, world, bank
PAO Sberbank of Russia	29	357	353	340	19	10	sberbank, card, online
CELKEM		4 814	4 666				

Tabulka – Základní charakteristiky vybraných bank (zdroj: Vlastní zpracování)

Název banky	Text	Fotografie	Video	Odkaz	Událost	Anketa	Komunikace	Výzva ke spol.	Vzdělání	Zábava	CSR
State Bank of India	0	61	8	0	0	0	49	8	2	0	10
Itaú Unibanco Holding SA	0	6	11	3	0	0	11	5	1	2	1
Banco Bilbao Vizcaya Argentaria SA	0	0	4	61	0	0	25	0	26	5	9
Banco Bradesco SA	0	0	21	0	0	0	2	0	1	14	4
Capital One Financial Corp.	0	4	16	0	0	0	7	0	0	13	0
Caixa Econômica Federal	1	8	12	0	0	0	16	2	0	1	2
Banco do Brasil SA	6	7	26	2	0	0	25	4	4	3	5
Bank of America Corp.	0	8	33	5	0	1	35	1	4	1	6
Citigroup Inc.	0	1	12	7	0	0	9	1	3	0	7
Wells Fargo & Co.	0	4	14	2	0	0	11	1	3	1	4
Shinhan Financial Group Co. Ltd.	1	24	7	1	0	0	3	20	5	4	1
United Overseas Bank Ltd.	0	6	11	3	0	0	15	1	1	0	3
DBS Group Holdings Ltd.	0	1	16	4	0	0	9	0	4	1	7
Société Générale SA	0	0	18	1	1	0	3	0	4	11	2
Bank of Nova Scotia	0	0	16	5	0	0	1	0	10	6	4
Commonwealth Bank of Australia	2	10	8	0	0	0	12	0	2	5	1
KB Financial Group Inc.	4	17	3	3	0	1	7	15	0	4	2
Royal Bank of Canada	0	1	9	13	0	0	8	0	12	3	0
Intesa Sanpaolo SpA	0	0	0	20	0	0	12	0	6	0	2
PAO Sberbank of Russia	0	14	10	11	0	1	27	6	1	1	1
<b>CELKEM</b>	<b>14</b>	<b>172</b>	<b>255</b>	<b>141</b>	<b>1</b>	<b>3</b>	<b>287</b>	<b>64</b>	<b>89</b>	<b>75</b>	<b>71</b>

Tabulka – Počty publikovaných příspěvků dle typu postu a typu obsahu (zdroj: Vlastní zpracování)

Název banky	Počet postů	Prům. hladina sentimentu	Medián	Modus	Rozptyl výběru	Směrodatná odchylka
State Bank of India	680	2,3	2,0	0	9,5	3,1
Itaú Unibanco Holding SA	174	2,1	1,6	0	6,5	2,6
Banco Bilbao Vizcaya Argentaria SA	640	1,9	1,8	0	10,6	3,3
Banco Bradesco SA	54	2,2	2,0	0	2,4	1,6
Capital One Financial Corp.	131	2,7	3,0	0	14,6	3,8
Caixa Econômica Federal	180	1,3	1,1	0	3,4	1,8
Banco do Brasil SA	399	2,0	1,9	0	4,8	2,2
Bank of America Corp.	467	2,3	2,2	0	12,2	3,5
Citigroup Inc.	134	2,9	2,4	0	10,5	3,2
Wells Fargo & Co.	151	2,1	1,8	0	17,6	4,2
Shinhan Financial Group Co. Ltd.	331	1,7	1,5	0	4,1	2,0
United Overseas Bank Ltd.	88	3,0	2,5	0	10,4	3,2
DBS Group Holdings Ltd.	45	1,7	1,5	0	6,8	2,6
Société Générale SA	46	3,5	2,5	0	12,4	3,5
Bank of Nova Scotia	208	2,5	2,2	0	15,2	3,9
Commonwealth Bank of Australia	116	1,9	2,0	0	15,5	3,9
KB Financial Group Inc.	225	1,0	0,9	0	7,2	2,7
Royal Bank of Canada	210	2,7	1,7	0	13,7	3,7
Intesa Sanpaolo SpA	34	1,7	2,3	0	4,8	2,2
PAO Sberbank of Russia	353	1,8	1,8	0	10,0	3,2
CELKEM	4666	2,1	1,8	0	9,8	3,1

Tabulka – Popisná statistika sentimentu v příspěvcích bank, 1. část (zdroj: Vlastní zpracování)

Název banky	Minimum	Maximum	Rozdíl min-max	Podíl pozitivních postů [%]	Podíl neutrálních postů [%]	Podíl negativních postů [%]
State Bank of India	-6,3	16,7	22,9	62,1	31,3	6,6
Itaú Unibanco Holding SA	-2,9	14,3	17,2	67,2	25,9	6,9
Banco Bilbao Vizcaya Argentaria SA	-12,2	14,0	26,2	54,2	33,1	12,7
Banco Bradesco SA	-0,6	6,0	6,6	87,0	11,1	1,9
Capital One Financial Corp.	-10,0	15,8	25,8	60,3	32,8	6,9
Caixa Econômica Federal	-4,4	8,0	12,4	68,9	22,8	8,3
Banco do Brasil SA	-5,8	14,3	20,1	79,4	12,8	7,8
Bank of America Corp.	-7,4	16,7	24,1	59,7	30,8	9,4
Citigroup Inc.	-3,3	16,0	19,3	68,7	29,1	2,2
Wells Fargo & Co.	-9,1	18,2	27,3	55,6	32,5	11,9
Shinhan Financial Group Co. Ltd.	-3,4	10,3	13,7	76,7	12,1	11,2
United Overseas Bank Ltd.	-4,5	13,8	18,3	73,9	20,5	5,7
DBS Group Holdings Ltd.	-2,8	7,8	10,5	68,9	11,1	20,0
Société Générale SA	0,0	11,8	11,8	65,2	34,8	0,0
Bank of Nova Scotia	-7,7	17,6	25,3	59,6	29,8	10,6
Commonwealth Bank of Australia	-10,3	11,5	21,9	56,0	29,3	14,7
KB Financial Group Inc.	-10,5	14,3	24,8	54,7	31,6	13,8
Royal Bank of Canada	-4,5	15,0	19,5	59,5	35,7	4,8
Intesa Sanpaolo SpA	-6,0	6,2	12,2	67,6	26,5	5,9
PAO Sberbank of Russia	-9,1	23,1	32,2	69,1	19,3	11,6
CELKEM	-12,2	23,1	35,3	64,1	26,6	9,3

Tabulka – Popisná statistika sentimentu v příspěvcích bank, 2. část (zdroj: Vlastní zpracování)



Název banky	Počet zkoumaných komentářů	Prům. hladina sentimentu	Medián	Modus	Rozptyl výběru	Směrodatná odchylka
State Bank of India	50	2,4	0	0	204,1	14,3
Itaú Unibanco Holding SA	50	2,9	0	0	41,4	6,4
Banco Bilbao Vizcaya Argentaria SA	–	–	–	–	–	–
Banco Bradesco SA	50	4,2	1,5	0	73,4	8,6
Capital One Financial Corp.	50	-1,1	0	0	42,5	6,5
Caixa Econômica Federal	50	1,3	0	0	14,4	3,8
Banco do Brasil SA	50	1,4	0	0	38,9	6,2
Bank of America Corp.	47	0,6	0	0	38,7	6,2
Citigroup Inc.	48	1,1	0	0	65,9	8,1
Wells Fargo & Co.	50	0,1	0	0	32,3	5,7
Shinhan Financial Group Co. Ltd.	50	1,9	0	0	28,6	5,4
United Overseas Bank Ltd.	10	7,7	0,4	0	120,1	11,0
DBS Group Holdings Ltd.	–	–	–	–	–	–
Société Générale SA	37	1,9	0	0	80,1	8,9
Bank of Nova Scotia	26	11,0	0	0	342,1	18,5
Commonwealth Bank of Australia	50	-1,6	0	0	33,5	5,8
KB Financial Group Inc.	50	5,4	0	0	133,7	11,6
Royal Bank of Canada	33	4,0	0	0	37,5	6,1
Intesa Sanpaolo SpA	–	–	–	–	–	–
PAO Sberbank of Russia	50	0,2	0	0	60,8	7,8
<b>CELKEM</b>	<b>751</b>	<b>2,1</b>	<b>0</b>	<b>0</b>	<b>77,2</b>	<b>8,8</b>

*Tabulka – Popisná statistika sentimentu v komentářích uživatelů, 1. část (zdroj: Vlastní zpracování)*

Název banky	Minimum	Maximum	Rozdíl min-max	Podíl pozitivních komentářů [%]	Podíl neutrálních komentářů [%]	Podíl negativních komentářů [%]
State Bank of India	-50,0	33,3	83,3	32,0	52,0	16,0
Itaú Unibanco Holding SA	-14,3	18,2	32,5	42,0	36,0	22,0
Banco Bilbao Vizcaya Argentaria SA	–	–	–	–	–	–
Banco Bradesco SA	-9,1	33,3	42,4	52,0	18,0	30,0
Capital One Financial Corp.	-25,0	22,2	47,2	20,0	48,0	32,0
Caixa Econômica Federal	-4,2	12,5	16,7	40,0	36,0	24,0
Banco do Brasil SA	-12,5	25,0	37,5	32,0	48,0	20,0
Bank of America Corp.	-11,1	33,3	44,4	25,5	38,3	36,2
Citigroup Inc.	-20,0	33,3	53,3	22,9	35,4	41,7
Wells Fargo & Co.	-18,2	17,1	35,3	30,0	34,0	36,0
Shinhan Financial Group Co. Ltd.	-8,7	16,7	25,4	36,0	50,0	14,0
United Overseas Bank Ltd.	0,0	28,6	28,6	50,0	50,0	0,0
DBS Group Holdings Ltd.	–	–	–	–	–	–
Société Générale SA	-14,3	50,0	64,3	29,7	56,8	13,5
Bank of Nova Scotia	0,0	50,0	50,0	38,5	61,5	0,0
Commonwealth Bank of Australia	-25,0	18,2	43,2	22,0	50,0	28,0
KB Financial Group Inc.	-14,3	40,0	54,3	38,0	52,0	10,0
Royal Bank of Canada	0,0	20,0	20,0	45,5	54,5	0,0
Intesa Sanpaolo SpA	–	–	–	–	–	–
PAO Sberbank of Russia	-33,3	15,8	49,1	38,0	42,0	20,0
CELKEM	-50,0	50,0	100,0	34,0	43,7	22,4

*Tabulka – Popisná statistika sentimentu v komentářích uživatelů, 2. část (zdroj: Vlastní zpracování)*

Název banky	Podíl reakcí bank na komentáře [%]	Prům. doba reakce [h]	Medián	Modus	Rozptyl výběru	Směrodatná odchylka
State Bank of India	12,0	53,3	71,0	0,3	1738,2	41,7
Itaú Unibanco Holding SA	86,0	11,2	1,5	0,3	353,5	18,8
Banco Bilbao Vizcaya Argentaria SA	–	–	–	–	–	–
Banco Bradesco SA	82,0	14,5	8,0	1,5	278,6	16,7
Capital One Financial Corp.	16,0	1,7	0,3	0,3	11,7	3,4
Caixa Econômica Federal	78,0	12,4	5,8	2,5	186,8	13,7
Banco do Brasil SA	100,0	5,7	1,9	0,3	51,0	7,1
Bank of America Corp.	38,3	7,0	9,5	10,0	24,7	5,0
Citigroup Inc.	50,0	4,4	0,3	0,3	219,4	14,8
Wells Fargo & Co.	62,0	1,3	0,5	0,0	4,7	2,2
Shinhan Financial Group Co. Ltd.	–	–	–	–	–	–
United Overseas Bank Ltd.	–	–	–	–	–	–
DBS Group Holdings Ltd.	–	–	–	–	–	–
Société Générale SA	81,1	8,0	0,9	0,3	178,8	13,4
Bank of Nova Scotia	23,1	1,3	0,4	0,5	5,3	2,3
Commonwealth Bank of Australia	60,0	2,0	1,0	1,0	18,2	4,3
KB Financial Group Inc.	–	–	–	–	–	–
Royal Bank of Canada	27,3	2,3	0,5	0,3	11,9	3,5
Intesa Sanpaolo SpA	–	–	–	–	–	–
PAO Sberbank of Russia	44,0	0,8	0,3	0,3	2,7	1,7
CELKEM	47,5	7,8	1,5	0,3	213,9	14,6

*Tabulka – Popisná statistika doby reakcí bank na uživatelské komentáře, 1. část (zdroj: Vlastní zpracování)*

Název banky	Nejrychlejší reakce [h]	Nejpomalejší reakce [h]	Rozdíl min-max [h]	Podíl reakcí do 1 h včetně [%]	Podíl reakcí mezi 1 h a 8 h včetně [%]	Podíl reakcí nad 8 h [%]
State Bank of India	0,25	100,00	99,84	16,7	16,7	66,7
Itaú Unibanco Holding SA	0,25	78,00	77,75	41,9	25,6	32,6
Banco Bilbao Vizcaya Argentaria SA	–	–	–	–	–	–
Banco Bradesco SA	0,25	70,50	70,25	9,8	41,5	48,8
Capital One Financial Corp.	0,25	10,00	9,75	75,0	12,5	12,5
Caixa Econômica Federal	0,25	54,75	54,50	7,7	48,7	43,6
Banco do Brasil SA	0,25	21,00	20,75	38,0	34,0	28,0
Bank of America Corp.	0,50	13,00	12,50	27,8	16,7	55,6
Citigroup Inc.	0,25	73,00	72,75	70,8	20,8	8,3
Wells Fargo & Co.	0,25	12,00	11,75	74,2	22,6	3,2
Shinhan Financial Group Co. Ltd.	–	–	–	–	–	–
United Overseas Bank Ltd.	–	–	–	–	–	–
DBS Group Holdings Ltd.	–	–	–	–	–	–
Société Générale SA	0,25	60,50	60,25	56,7	6,7	36,7
Bank of Nova Scotia	0,25	6,00	5,75	83,3	16,7	0,0
Commonwealth Bank of Australia	0,25	24,00	23,75	60,0	36,7	3,3
KB Financial Group Inc.	–	–	–	–	–	–
Royal Bank of Canada	0,25	10,00	9,75	66,7	22,2	11,1
Intesa Sanpaolo SpA	–	–	–	–	–	–
PAO Sberbank of Russia	0,25	8,00	7,75	81,8	18,2	0,0
CELKEM	0,25	100,00	99,75	44,8	28,3	26,9

*Tabulka – Popisná statistika doby reakcí bank na uživatelské komentáře, 2. část (zdroj: Vlastní zpracování)*

Název banky	Počet reakcí banky	Prům. hladina sentimentu	Medián	Modus	Rozptyl výběru	Směrodatná odchylka
State Bank of India	6	0,9	0	0	21,2	4,6
Itaú Unibanco Holding SA	43	3,0	0	0	16,8	4,1
Banco Bilbao Vizcaya Argentaria SA	–	–	–	–	–	–
Banco Bradesco SA	41	6,4	3,4	0	66,0	8,1
Capital One Financial Corp.	8	2,0	0	0	10,7	3,3
Caixa Econômica Federal	39	0,7	0	0	3,3	1,8
Banco do Brasil SA	50	3,7	0	0	25,6	5,1
Bank of America Corp.	18	2,2	1,0	0	14,4	3,8
Citigroup Inc.	24	0,1	0	0	9,4	3,1
Wells Fargo & Co.	31	2,3	0	0	22,0	4,7
Shinhan Financial Group Co. Ltd.	–	–	–	–	–	–
United Overseas Bank Ltd.	–	–	–	–	–	–
DBS Group Holdings Ltd.	–	–	–	–	–	–
Société Générale SA	30	-0,3	0	0	7,2	2,7
Bank of Nova Scotia	6	3,4	1,5	0	30,7	5,5
Commonwealth Bank of Australia	30	1,1	0	0	11,5	3,4
KB Financial Group Inc.	–	–	–	–	–	–
Royal Bank of Canada	9	2,3	0	0	7,8	2,8
Intesa Sanpaolo SpA	–	–	–	–	–	–
PAO Sberbank of Russia	22	3,8	0	0	22,4	4,7
CELKEM	357	2,5	0	0	24,1	4,9

Tabulka – Popisná statistika sentimentu v reakcích bank, 1. část (zdroj: Vlastní zpracování)

Název banky	Minimum	Maximum	Rozdíl min-max	Podíl pozitivních reakcí [%]	Podíl neutrálních reakcí [%]	Podíl negativních reakcí [%]
State Bank of India	-4,2	9,7	13,8	16,7	66,7	16,7
Itaú Unibanco Holding SA	-3,7	14,3	18,0	46,5	51,2	2,3
Banco Bilbao Vizcaya Argentaria SA	–	–	–	–	–	–
Banco Bradesco SA	-8,3	30,8	39,1	63,4	34,1	2,4
Capital One Financial Corp.	0,0	8,8	8,8	37,5	62,5	0,0
Caixa Econômica Federal	-3,7	6,4	10,1	28,2	66,7	5,1
Banco do Brasil SA	-4,2	16,7	20,8	44,0	52,0	4,0
Bank of America Corp.	-4,8	8,3	13,1	50,0	33,3	16,7
Citigroup Inc.	-7,1	8,0	15,1	33,3	41,7	25,0
Wells Fargo & Co.	-4,2	15,8	20,0	38,7	48,4	12,9
Shinhan Financial Group Co. Ltd.	–	–	–	–	–	–
United Overseas Bank Ltd.	–	–	–	–	–	–
DBS Group Holdings Ltd.	–	–	–	–	–	–
Société Générale SA	-7,7	6,4	14,1	16,7	60,0	23,3
Bank of Nova Scotia	0,0	14,3	14,3	50,0	50,0	0,0
Commonwealth Bank of Australia	-4,3	12,5	16,8	40,0	36,7	23,3
KB Financial Group Inc.	–	–	–	–	–	–
Royal Bank of Canada	0,0	6,3	6,3	44,4	55,6	0,0
Intesa Sanpaolo SpA	–	–	–	–	–	–
PAO Sberbank of Russia	0,0	14,3	14,3	45,5	54,5	0,0
CELKEM	-8,3	30,8	39,1	40,9	49,6	9,5

Tabulka – Popisná statistika sentimentu v reakcích bank, 2. část (zdroj: Vlastní zpracování)

Univerzita Hradec Králové  
Fakulta informatiky a managementu  
Akademický rok: 2018/2019

Studijní program: Systémové inženýrství a informatika  
Forma: Kombinovaná  
Obor/komb.: Informační management (im2-k)

**Podklad pro zadání DIPLOMOVÉ práce studenta**

<b>PŘEDKLÁDÁ:</b>	<b>ADRESA</b>	<b>OSOBNÍ ČÍSLO</b>
Bc. Marek Jakub	Prokopa Holého 138, Kutná Hora - Sedlec	I1700372

**TÉMA ČESKY:**

Firemní online komunikace na sociálních sítích

**TÉMA ANGLICKY:**

Online corporate (business) communication on social networks

**VEDOUcí PRÁCE:**

doc. Ing. Pavel Bachmann, Ph.D. - KM

**ZÁSADY PRO VYPRACOVÁNÍ:**

Cílem práce je analyzovat online komunikaci na sociálních sítích u vybraných firem z daného odvětví s kladeným důrazem na analýzu sentimentu.

1. Úvod
2. Teoretická východiska
3. Metodika
4. Výsledky
5. Diskuze
6. Závěr

**SEZNAM DOPORUČENÉ LITERATURY:**

Google Scholar

Podpis studenta: .....

Datum: .....

Podpis vedoucího práce: .....

Datum: .....