

I. IDENTIFIKAČNÍ ÚDAJE

Název práce:	Extrakce klíčových slov z textových shluků
Jméno autora:	Diana Korladinova
Typ práce:	bakalářská
Fakulta/ústav:	Fakulta elektrotechnická (FEL)
Katedra/ústav:	KK
Oponent práce:	Gustav Šír
Pracoviště oponenta práce:	KP

II. HODNOCENÍ JEDNOTLIVÝCH KRITÉRIÍ

Zadání	průměrně náročné
<i>Hodnocení náročnosti zadání závěrečné práce.</i>	
Zadání se jeví jako adekvátně náročné pro bakalářskou práci.	

Splnění zadání	splněno
<i>Posuďte, zda předložená závěrečná práce splňuje zadání. V komentáři případně uveďte body zadání, které nebyly zcela splněny, nebo zda je práce oproti zadání rozšířena. Nebylo-li zadání zcela splněno, pokuste se posoudit závažnost, dopady a případně i příčiny jednotlivých nedostatků.</i>	
Bez vyhrad splněno.	

Zvolený postup řešení	vynikající
<i>Posuďte, zda student zvolil správný postup nebo metody řešení.</i>	
Postup je výborný, studentka začíná obsahlou reserší a experimentuje s širokou škálou vybraných metod.	

Odborná úroveň	B - velmi dobře
<i>Posuďte úroveň odbornosti závěrečné práce, využití znalostí získaných studiem a z odborné literatury, využití podkladů a dat získaných z praxe.</i>	
Studentka prozkoumává a pracuje s nejruznějšími metodami na rozhraní NLP a strojového učení, z velké části za hranicemi bakalářského studia. Místy je lehce znát, že porozumění těmto metodám je spíše intuitivní a lehce nepřesné, ale to je zcela pochopitelné. Trochu mi chybí nějaké explicitnější porovnání metod a nějaké kvantifikované závěry, ale je to opět pochopitelné vzhledem k unsupervised povaze úlohy.	

Formální a jazyková úroveň, rozsah práce	A - výborně
<i>Posuďte správnost používání formálních zápisů obsažených v práci. Posuďte typografickou a jazykovou stránku.</i>	
Textová část práce je velmi povedená, jen angličtina je místy lehce počeštěná, ale citelnosti (pro čecha) to nijak neubírá. Po typografické stránce velmi pěkná, zpracována se zjevnou pečlivostí a citem pro detail (i barvy).	

Výběr zdrojů, korektnost citací	A - výborně
<i>Vyjádřete se k aktivitě studenta při získávání a využívání studijních materiálů k řešení závěrečné práce. Charakterizujte výběr pramenů. Posuďte, zda student využil všechny relevantní zdroje. Ověřte, zda jsou všechny převzaté prvky řádně odlišeny od vlastních výsledků a úvah, zda nedošlo k porušení citační etiky a zda jsou bibliografické citace úplné a v souladu s citačními zvyklostmi a normami.</i>	
Bez problému.	

Další komentáře a hodnocení
<i>Vyjádřete se k úrovni dosažených hlavních výsledků závěrečné práce, např. k úrovni teoretických výsledků, nebo k úrovni a funkčnosti technického nebo programového vytvořeného řešení, publikačním výstupům, experimentální zručnosti apod.</i>
Viz celkové hodnocení.

III. CELKOVÉ HODNOCENÍ, OTÁZKY K OBHAJOBĚ, NÁVRH KLASIFIKACE

Shrňte aspekty závěrečné práce, které nejvíce ovlivnily Vaše celkové hodnocení. Uveďte případné otázky, které by měl student zodpovědět při obhajobě závěrečné práce před komisí.

Jedna se o peknu bakalarskou praci s cilem predevsim prozkoumat metody NLP v oblasti detekce shluku temat a jejich anotace na datasetu ceskeho Twitteru. Jedna se zjevne o pocatecni explorativni analyzu, ktera byla pro studentku nova, a poprala se s ni velmi pekne. Ocenuji predevsim siri metod, se kterymi se musela efektivne seznamit (od k-means az po transformery).

Poznamky/otazky:

Trochu mi chybi nejaky zaver/diskuze z hlediska vysledku, jakou metodu byste hodnotila jako nejslibnejsi?

5.1.1 – experiment A vs. B – z hlediska detekce slov, ktere maji charakterizovat jednotlivy clustery (a ne tweety) mi dava varianta A vyrazne vetsi smysl, nemyslíte? Pokud ano, cim si vysvetlujete ze vychazi podobne jako varianta B?

Vysledky dvou stezejnich postupu pomoci k-means a LDA by mozna bylo pekne nejak blize porovnat (neni mi jasne jak se doslo k zaveru ze k-means je lepsi).

+ par veci, ktere mi prisly vytrzene z kontextu (evokujici limitovane porozumeni danym metodam):

2.1.2: *Methods that embed the vectors into an R^n space and consider semantic relations and meaning (word order is taken into account)*

- Jak souvisi poradi slov s delenim na counting/embedding?

Podobne:

the conditional distribution is a quotient of the joint probability distribution of z , θ , and ϑ across all w and the probability of observing D across all topics

A high-dimensional space means multiple relations embedded for a single word.

Předloženou závěrečnou práci hodnotím klasifikačním stupněm **A - výborně**.

Datum: 10.6.2023

Podpis: