

Vybrané aktuální projekty Centra ZPJ

Jan Rygl, Vít Suchomel

E-mail: xrygl@fi.muni.cz, 139723@mail.muni.cz
http://nlp.fi.muni.cz/poc_lingv/

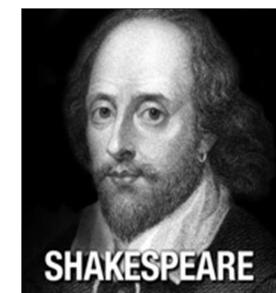
Obsah:

- ▶ Rozpoznávání autorství anonymních dokumentů na Internetu
- ▶ Budování textových korpusů z Internetu

Motivace

Proč se začalo mluvit o určování autorství?

- ▶ Může za to Shakespearovo dílo:
 - Gale Ecco, 1787:
 A Dissertation on the Three Parts of King Henry VI. Tending to Show That Those Plays Were Not Written Originally by Shakspeare.



Motivace

Proč nás zajímá autorství dokumentů?

- ▶ Anonymní výhrůžky (omezený seznam potenciálních kandidátů)
 - Lidé dříve trestaní za šíření poplašné zprávy (bomba na letišti)
 - Všichni sousedi (příliš hlučné páry)
 - Studenti (příliš těžké zkoušky)
- ▶ Zpochybňení závěti (ověření shody autorství)
- ▶ Falešné doznání obžalovaného napsané policisty ([1. použití před soudem](#))

Motivace

Proč v prostředí Internetu?

- ▶ Rasistické diskuzní příspěvky psané z internetové kavárny
- ▶ Extremistické blogy zveřejněné přes anonymní proxy servery
- ▶ Oznámení bomby na letišti pachatelem, který má čistý rejstřík
- ▶ Na Internetu se dá najít téměř vše.



Dennis Bayley, 2004:
Anonymity is the single most important enabler of criminal activity.

Praktické zadání

1. Máme dokument D a množinu dokumentů autora A. *Napsal A dokument D?*
2. Máme anonymní dokument D a množinu potenciálních autorů. *Je autorem D někdo z autorů? Kdo?*
3. Máme anonymní dokument, chceme zjistit autora.
 - Až zde potřebujeme Internet.
 - Pokud předem neomezíme množinu (autor je registrovaný na webu, bydlí v nějaké vesnici apod.), úloha je velmi "ambiciozní".
 - Předpokládá se, že skutečný **autor někdy publikoval pod svým pravým jménem** (bakalářská práce, inzerát, ...)

1. Předzpracování

- ▶ Závislé na jazyce. Pro češtinu lze použít fakultní nástroje (majka, synt, set), pro angličtinu a některé další jazyky existují další kvalitní software.
- ▶ Pokud nejsme schopni předzpracování udělat, nebudeme moci použít v dalším kroku některé autorské charakteristiky.

```
<p align="justify">  Společnost se za
svou historii dokázala
<s>

Společnost se za
za svou historii dokázala
k1gFnSc1
k3xPyFc4
k7c4
k3x0yFpXgFnSc4
k1gFnSc4
k5eAaPmAgFnS
N
N
N
Y
N
N
```

Jak na ověření autorství

Nejjednodušší případ, máme dokument D a texty autora A. *Jaká je pravděpodobnost, že mají shodné autorství?*

Postup:

1. Předzpracujeme texty
 - Odstranění šumu (text, který nenapsal uživatel)
 - Tokenizace
 - Značkování pro další zpracování (morfologie, syntaxe)
2. Spočítáme z textů charakteristiky autora dokumentu D a autora A.
3. Srovnáme **charakteristiky autorů** a dle jejich podobnosti určíme pravděpodobnost shody autorství.



3. Porovnání autorů (1)

- Každá charakteristika c_i po srovnání dvou autorů vrátí racionální číslo v intervalu $\langle 0, 1 \rangle$
 $c_i(A, D) \sim$ podobnost A a D.

Příklad (frekvence slovních druhů)

- Pro slovní druhy 1 až 10 spočítáme relativní frekvence v dokumentu:
 $f_D^i, i \in \{1, \dots, 10\}$
 a ve sjednocení textů autora: $f_A^i, i \in \{1, \dots, 10\}$
- Frekvence srovnáme pomocí druhé mocniny rozdílů odpovídajících si frekvencí:

$$1 - \frac{\sum_{i \in \{1, \dots, 10\}} f_D^i - f_A^i}{2}$$

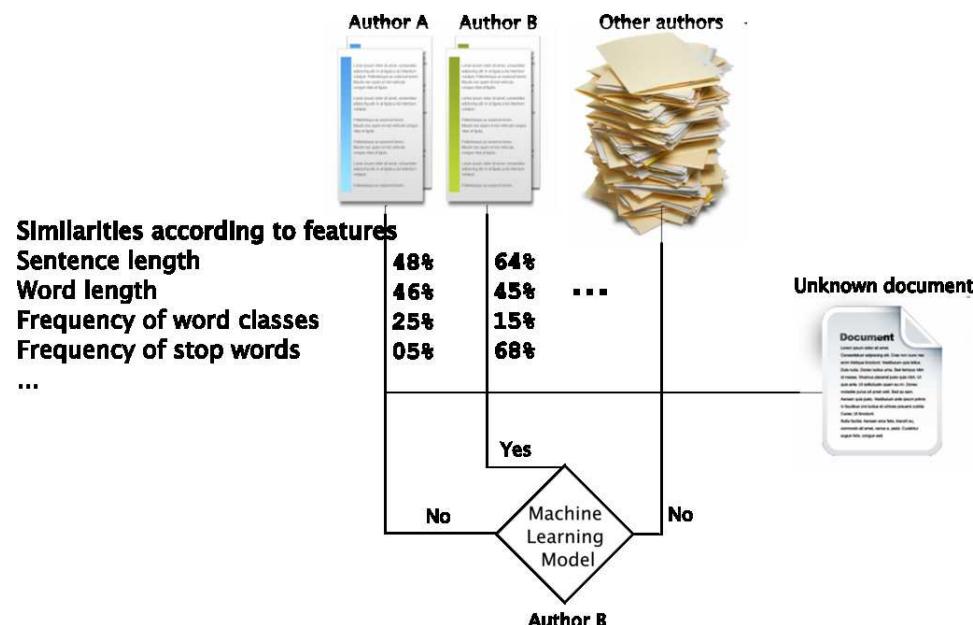
- Např.

$$A = \{k1:0.5, k5:0.4, k2:0.1\}$$

$$D = \{k1:0.4, k5:0.3, k2:0.2, k3:0.1\}$$

$$P = 1 - \frac{(0.5-0.4)^2 + (0.4-0.3)^2 + (0.1-0.2)^2 + (0-0.1)^2}{2} = 1 - \frac{0.04}{2} = 0.98$$

Rozšíření na úlohu N autorů



3. Porovnání autorů (2)

- S autory a dokumenty, u nichž známe autorství, vytvoříme velké sady dvojic autor dokument tak, abychom měli stejný případ shod i neshod (např. 10000 od každého). Každé dvojice bude reprezentována n-ticí $c_i(A, D)$.
- Použijeme strojové učení, aby se naučilo rozpoznávat n-tice signalizující shodu a rozdílnost autorů.
 Získáme tak model M takový, že:

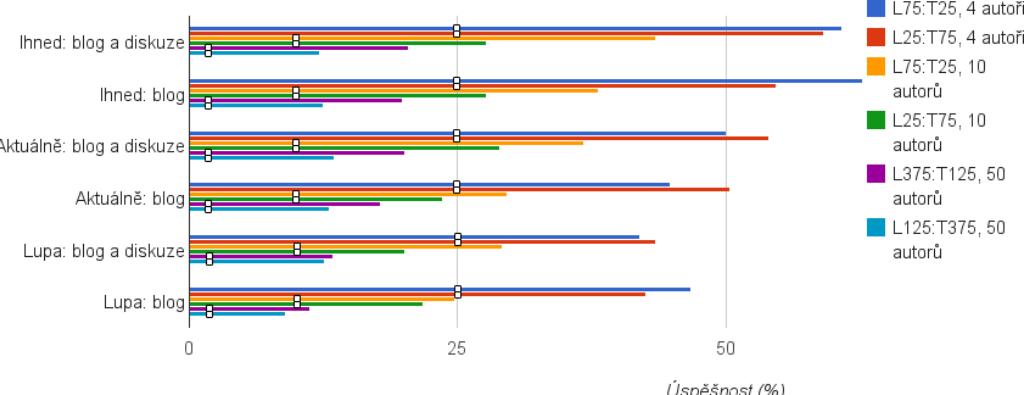
$$M([c_1(A, D), \dots, c_n(A, D)]) = P(\text{autor}(A) == \text{autor}(D))$$

- Vždy, když budeme chtít srovnávat dokument a autora, extrahuje je jejich autorské charakteristiky a předložíme je jako n-tici modelu. Ten vrátí odpověď.

Na čem závisí úspěšnost

- Počet možných autorů.
- Délka zdroje (knihy >> diskuze)
- Kvalita zdroje (je třeba detektovat citace, odkazy, ...)

Úspěšnost přiřazení autora podle dané množiny autorských dokumentů

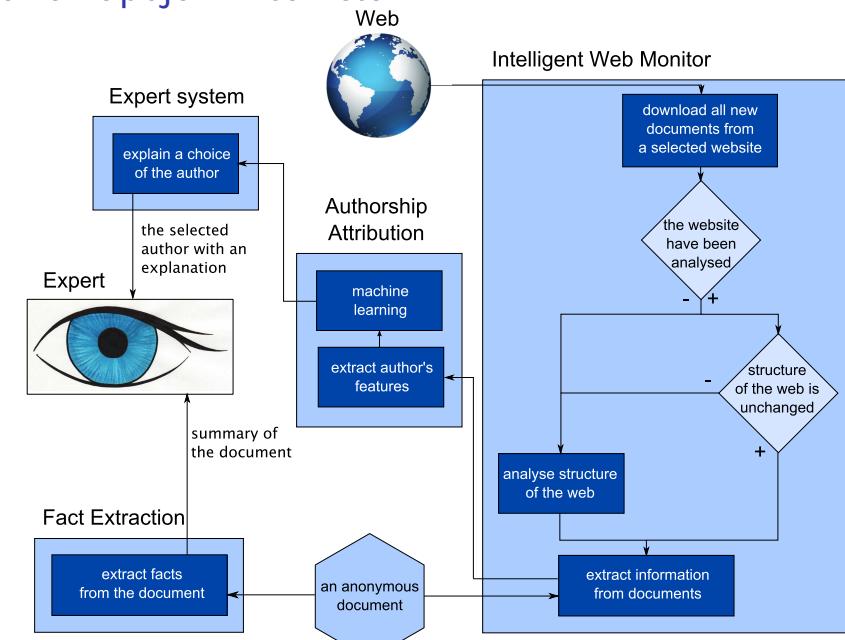


Přidání Internetu

Co potřebujeme:

- ▶ Znát weby, kde jsou texty autorů.
- ▶ Detektovat strukturu webů.
- ▶ Pravidelně stahovat nové dokumenty z webů (nutná struktura).
 - Odhalit změnu struktury webu a aktualizovat informace.
- ▶ Dokumenty spravovat v databázi.
 - Vyhledávání (stovky tisíc a více dokumentů)
 - Hledání dle času, kategorií, autora, ...
- ▶ Předzpracovávat si dokumenty.
- ▶ Ukládat si drahé mezinásledky (nepočítat např. frekvence slovních druhů vícekrát pro jeden dokument).

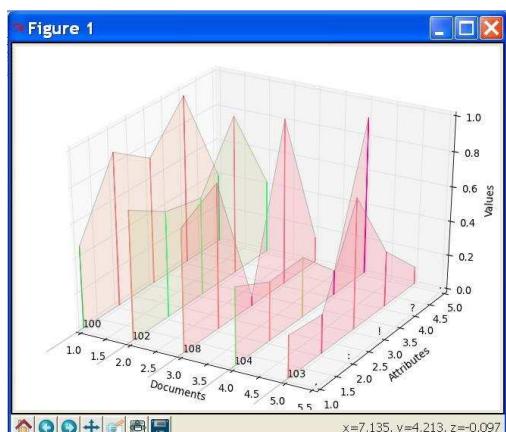
Schéma zapojení Internetu



Další výstupy

- ▶ Uživatelům často nestačí říci, který autor je nejpravděpodobnější
- ▶ Je potřeba poskytnout textovou nebo vizuální podporu výsledků

Příklad srovnání 5 autorů na autorském rysu frekvence interpunkce:



Shrnutí

- ▶ Projekt je stále ve vývoji
- ▶ Pokud vás něco zaujalo, je pravý čas se přidat
 - lingvistika nebo statistika
Vytvářet **nové charakteristiky autora** (analýza chyb, nářečí, počet jednoduchých a složitých vět, formátování textu, či nejlépe vymyslet vlastní)
 - grafika nebo analýza dat
Vymyslet kreativní přístupy k **vizualizaci výstupních dat**, případně k summarizaci výsledků programu, aby jim rozuměl školený uživatel
 - programování a struktura webu
Navrhnout nové metody pro **automatickou detekci struktury webu**, přihlašování se ke zdrojům vyžadujícím autentizaci, vyhledávání odkazů na dokumenty v doméně
 - strojové učení a analýza
Hrát si s různými metodami **strojového učení** a framework
 - vše ostatní
A mnoho dalšího, stačí se domluvit, jsou potřeba **lingvisti**, **programátoři**, **grafici**, **právníci**, ...

Proč potřebujeme velké korpusy?

Použití korpusů

- ▶ lexikografové: slovníky
- ▶ lingvisté: jazykové analýzy ([Word Sketches](#))
- ▶ statistické nástroje ZPJ: jazykové modely pro značkovače, analyzátoři, překladové systémy, prediktivní psaní,...

Přínosy velkých korpusů

- ▶ větší slovník (více různých slov)
- ▶ více/lepší příklady použití slov ve větách
- ▶ lepší pokrytí řídkých jazykových jevů
- ▶ více dat pro přesnější jazykové modely

Tradiční textové korpusy

Vznik

- ▶ obvykle na objednávku vládní instituce nebo nakladatelství
- ▶ zdroje: nakladatelství, skenování knih, přepisy rozhovorů

Výhody tradičních korpusů

- ▶ kontrolovaný obsah

Nevýhody tradičních korpusů

- ▶ nedostatenčná velikost pro některá použití
- ▶ obtížné získávání dat, vysoké náklady
- ▶ problémy s autorskými právy

Web je největší korpus

Výhody internetových korpusů

- ▶ obrovské množství dat
- ▶ dokumenty různých druhů
- ▶ aktuální podoba psané formy jazyka v populaci
- ▶ snadná dostupnost, nízké náklady

Nevýhody internetových korpusů

- ▶ neuspořádanost
- ▶ nežádoucí obsah
- ▶ duplicity
- ▶ chyby
- ▶ víme, co stahujeme?

Web crawler

Web crawler je druh počítačového programu

- ▶ prochází internet (stránky propojené odkazy)
- ▶ stahuje dokumenty (metainformace, obsah)
- ▶ ukládá části dokumentů v různých formátech k dalšímu použití

Crawlers

- ▶ k získávání obsahu dokumentů – GoogleBot (navíc k indexování), Heritrix a mnoho dalších
- ▶ ke sbírání odkazů
- ▶ k získávání textových dokumentů pro ZPJ – SpiderLing

Základní návrh crawleru

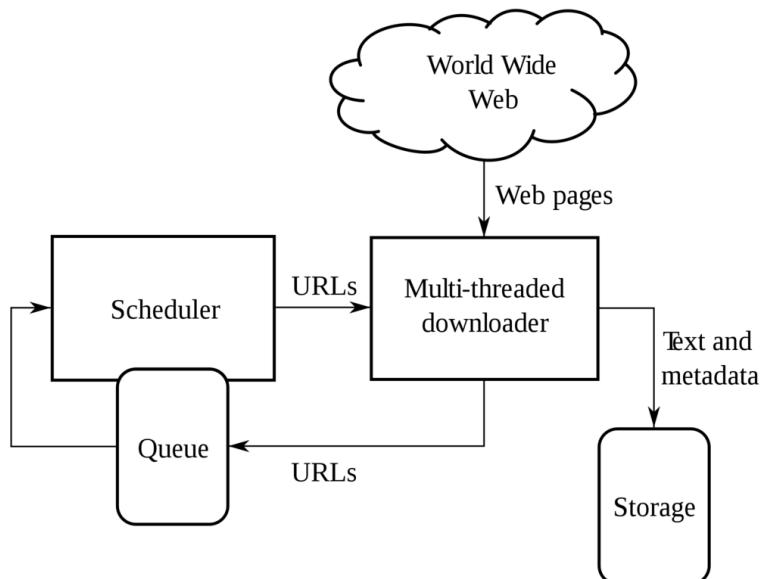
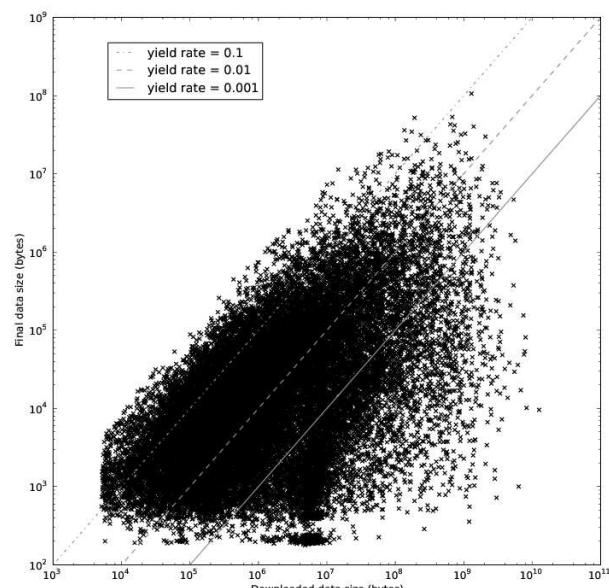


Schéma z http://en.wikipedia.org/wiki/Web_crawler

Efektivita stahování z webových domén

Heritrix, portugalský internet

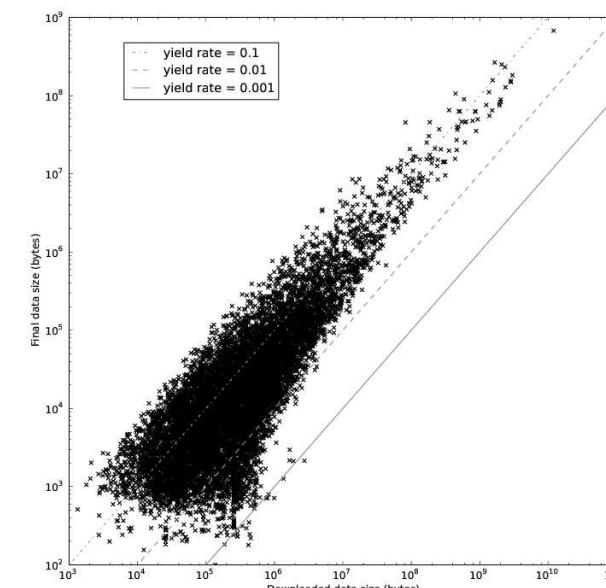


SpiderLing – crawler pro textové korpusy

- ▶ důraz kladen na efektivitu stahování
- ▶ míra výtěžnosti = $\frac{\text{velikost výsledných dat}}{\text{velikost stažených dat}}$
- ▶ crawler průběžně vyhodnocuje výtěžnost webových domén, zaměřuje se na „textově bohaté“ a odkládá stahování (nebo vůbec nestahuje) z neperspektivních webů
- ▶ cílem je sestavit korpusy velikosti $\geq 10^{10}$ slov pro všechny významné jazyky

Efektivita stahování z webových domén

SpiderLing, český internet



Postup získávání webových korpusů v CZPJ

- ▶ příprava jayzkově závislých modelů používaných v dalších krocích – učení na dokumentech z Wikipedie
- ▶ spuštění crawleru (*SpiderLing*)
- ▶ zpracování a vyhodnocování během běhu crawleru
 - detekce znakové sady dokumentu (*Chared*)
 - filtrování jazyka (vektor trigramů znaků)
 - odstraňování nežádoucího obsahu (*Justtext*)
 - kontrola duplicitních dokumentů
 - vyhodnocování průběžné výtěžnosti webových domén
- ▶ zpracování získaných dat
 - odstranění podobných odstavců (*Onion*)
 - tokenization (*Unitok* nebo jiný nástroj)
 - značkování morfologické a syntaktické – externími nástroji, jsou-li dostupné
 - zakódování a nahrání do korpusového manažeru (*Manatee/Bonito*)

Více v předmětu PA154 nástroje pro korpusy

Detekce kódování znaků

Používáme nástroj Chared
(<http://nlp.fi.muni.cz/projects/chared>)

- ▶ 57 podporovaných jazyků, samostatný model pro každý
- ▶ model obsahuje vektor četnosti trigramů bajtů pro každé z používaných kódování
- ▶ klasifikátor vybere kódování, jehož vektor má největší skalární součin s vektorem testovaného dokumentu
- ▶ demo na stránce nástroje

Odstraňování nežádoucího obsahu

Nežádoucí obsah

- ▶ html značky, styly, poznámky
- ▶ negramatické věty: navigace, reklamy, tabulky, příliš krátké úseky,...

Používáme nástroj jusText

(<http://nlp.fi.muni.cz/projects/justtext>)

- ▶ rozdelení na odstavce
- ▶ slovník častých slov v daném jazyce
- ▶ klasifikace odstavce podle délky, hustoty slov ze slovníku, hustoty odkazů, třídy okolních odstavců
- ▶ demo na stránce nástroje

Odstraňování duplicit

Duplicity

- ▶ shodné dokumenty nebo odstavce – snadné
- ▶ podobné dokumenty nebo odstavce – obtížné

Používáme nástroj onion (<http://nlp.fi.muni.cz/projects/onion>)

Velké textové korpusy získané z internetu v CZPJ

jazyk	surová data [GB]	velikost korpusu [GB]	míra výtěžnosti	velikost korpusu [10 ⁹ tokenů]	doba běhu [dny]
angličtina	2859	108	3.78 %	17.8	17
am. španělština	1874	44	2.36 %	8.7	14
arabština	2015	58	2.89 %	6.6	28
čeština	4000			5.8	40
francouzština	3273	72	2.19 %	12.4	15
japonština	2806	61	2.19 %	11.1	28
ruština	4142	198	4.77 %	20.2	14
turečtina	2700	26	0.97 %	4.1	14

V NLPC máme k dispozici také kolekci dat ClueWeb '09 – vyčištěná anglická část obsahuje zhruba 70 miliard tokenů.

Ukázky internetových korpusů

- ▶ srovnání korpusů BNC (tradiční) a enTenTen (internetový)
 - novější bývá lepší
 - větší bývá lepší
- ▶ získávání termínů z doménového korpusu
- ▶ korpus tádžické perštiny