

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

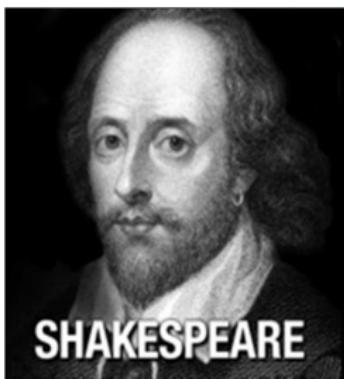
Motivace

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 Shew 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 párvy)
 - 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, . . .)

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 (morphologie, syntaxe)
2. Spočítáme z textů charakteristiky autora dokumentu D a autora A.
3. Srovnáme **charakteristiky autorů** a dle jejich podobnosti určíme pravděpodobnost shody autorství.



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	společnost	k1gFnSc1	N
	se	sebe	k3xPyFc4	N
	za	za	k7c4	N
	svou	svůj	k3x0yFpXgFnSc4	Y
	historii	historie	k1gFnSc4	N
	dokázala	dokázat	k5eAaPmAgFnS	N

2. Počítání charakteristik autora

- Jazykově závislé
 - Osoba mluvčího (pohlaví, číslo)
 - Analýza gramatických značek v textu
 - Analýza počtu vět (hlavní, vedlejší, ...)
 - Chyby v textu (překlepy, hrubky, syntax)
- Jazykově nezávislé (stačí tokenizace)
 - Analýza délky vět (počet slov, znaků)
 - Analýza délky slov (porovnání histogramů)
 - Frekvence slov, bigramů, ... (ovlivněna tématem)
 - Frekvence stopслов (tematicky nezávislá)
 - δ -score (srovnání frekvencí slov v textu s běžnou frekvencí slova v korpusech)
 - Bohatost slovní zásoby

3. Porovnání autorů (1)

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

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

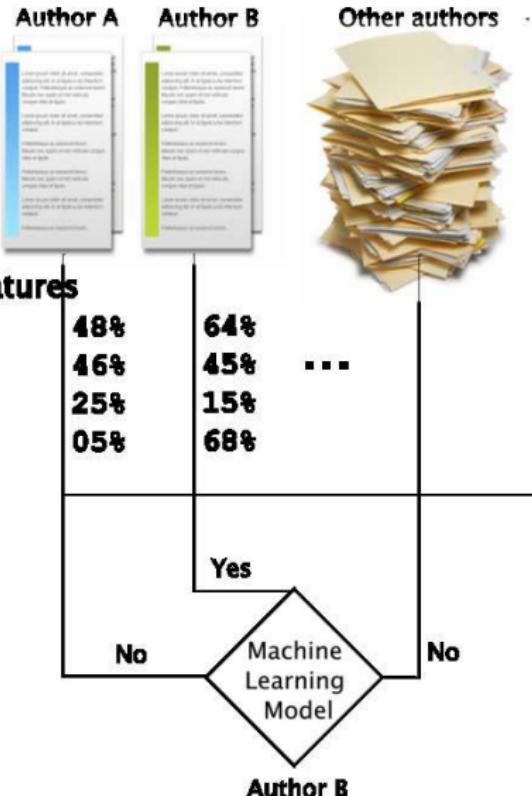
3. Porovnání autorů (2)

- 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:

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

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

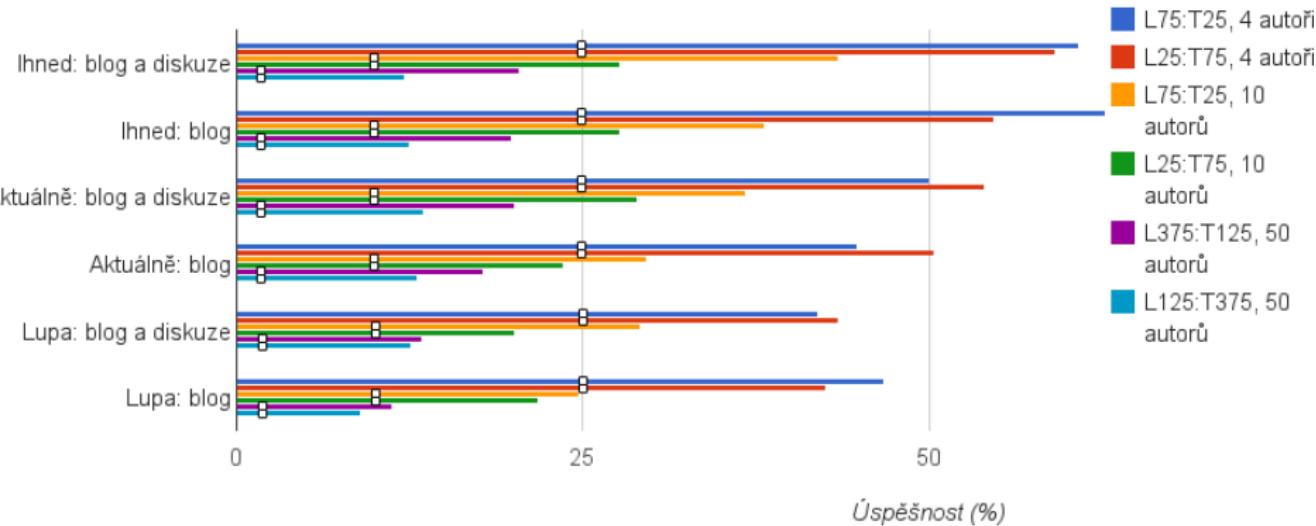
Rozšíření na úlohu N autorů



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

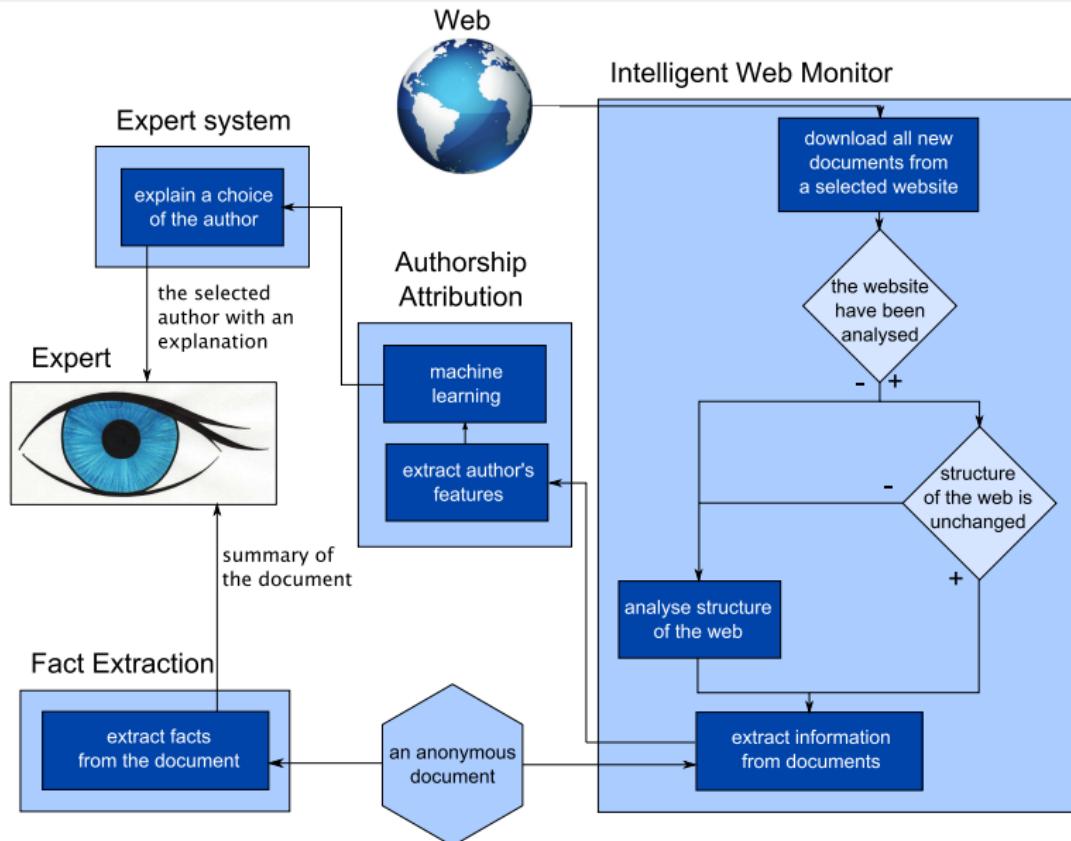


Přidání Internetu

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 mezivýsledky (nepočítat např. frekvence slovních druhů vícekrát pro jeden dokument).

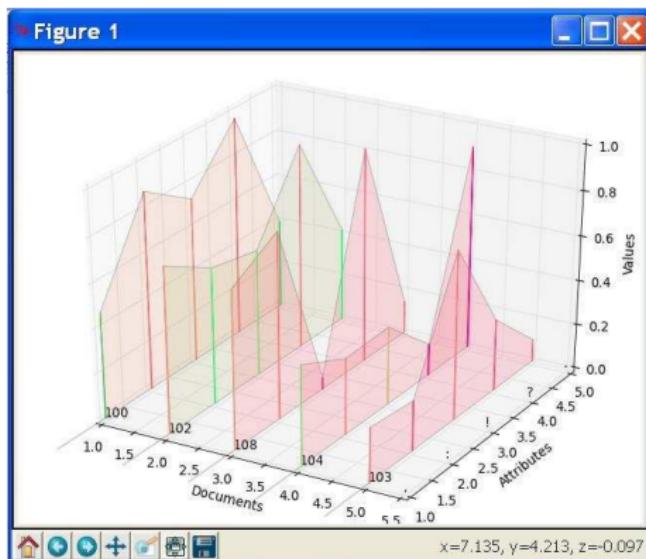
Schéma zapojení Internetu



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 sumarizaci výsledků programu, aby jím rozuměl školený uživatel
 - programování a struktura webu
Navrhnut 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 frameworky
 - vše ostatní
A mnoho dalšího, stačí se domluvit, jsou potřeba **lingvisti, programátoři, grafici, právníci, ...**

Obsah

- 1 Rozpoznávání autorství anonymních dokumentů na Internetu
 - ART – Authorship Recognition Tool
- 2 Budování textových korpusů z Internetu
 - Motivace
 - Získávání dokumentů z internetu
 - Nástroje pro zpracování
 - Výsledky

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

Crawlery

- 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

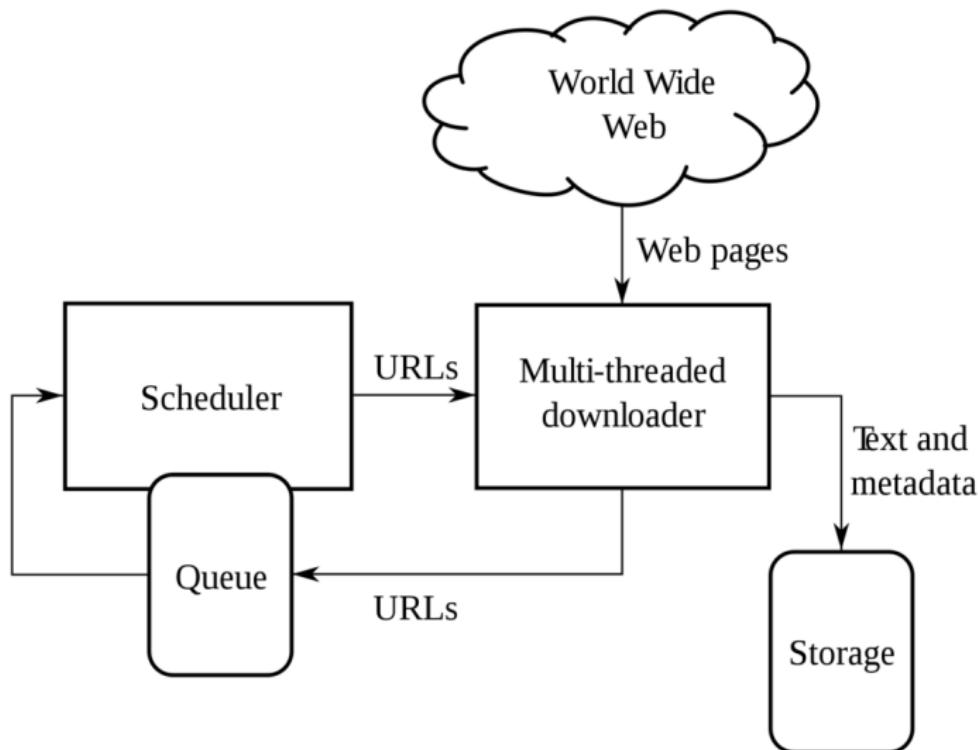


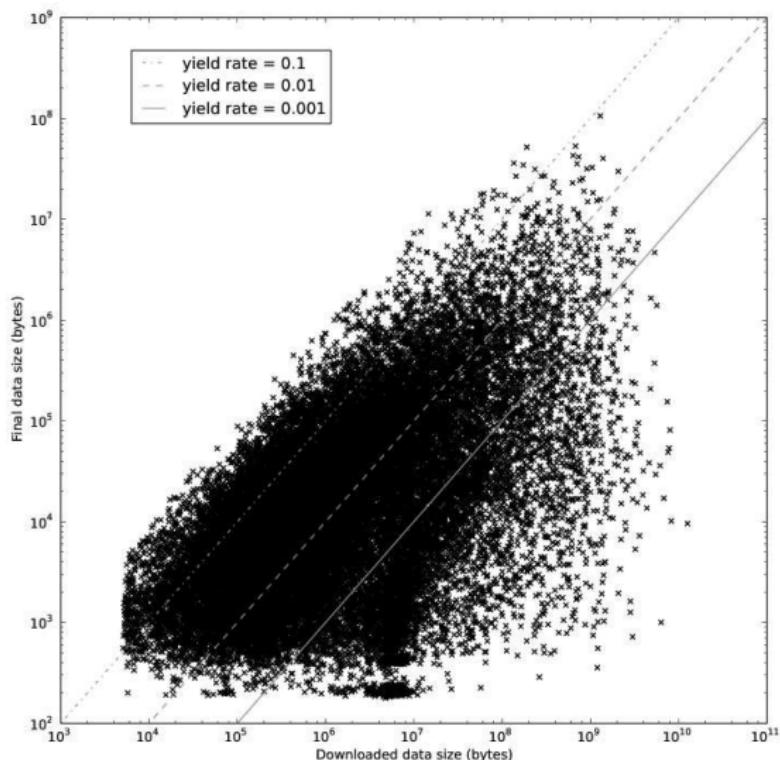
Schéma z http://en.wikipedia.org/wiki/Web_crawler

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

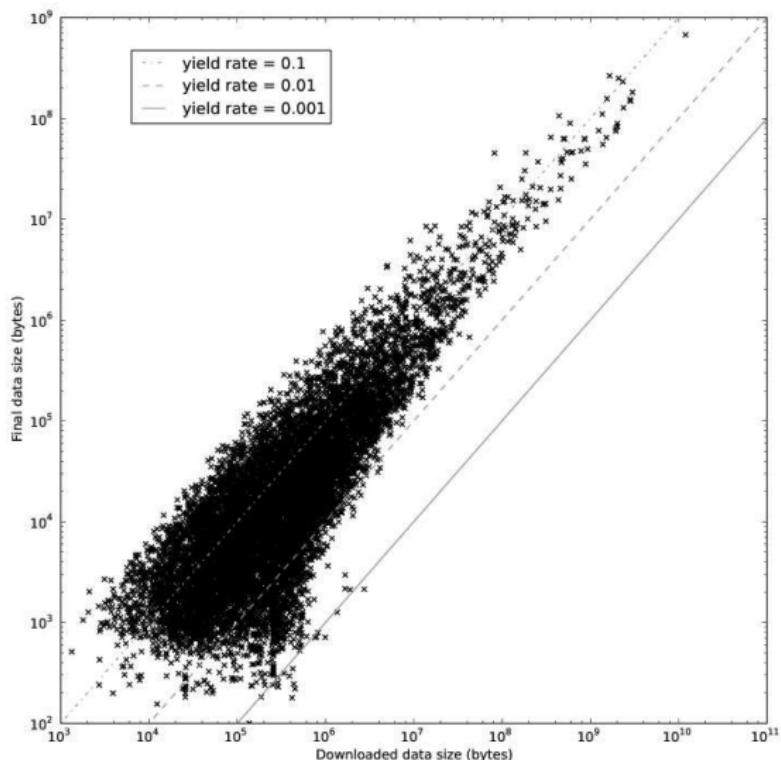
Efektivita stahování z webových domén

Heritrix, portugalský internet



Efektivita stahování z webových domén

SpiderLing, český internet



Postup získávání webových korpusů v CZPJ

- příprava jazykově 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 výtěž- nosti	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