VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA INFORMAČNÍCH TECHNOLOGIÍ
ÚSTAV POČÍTAČOVÉ GRAFIKY A MULTIMÉDIÍ

FACULTY OF INFORMATION TECHNOLOGY
DEPARTMENT OF COMPUTER GRAPHICS AND MULTIMEDIA

ROZPOZNÁVÁNÍ POJMENOVANÝCH ENTIT

DIPLOMOVÁ PRÁCE
MASTER'S THESIS

AUTOR PRÁCE
AUTHOR

Bc. VOJTĚCH RYLKO

BRNO 2014

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY

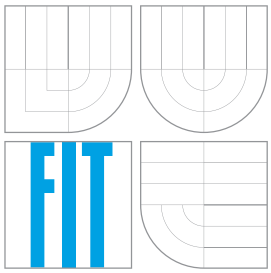

FAKULTA INFORMAČNÍCH TECHNOLOGIÍ
ÚSTAV POČÍTAČOVÉ GRAFIKY A MULTIMÉDIÍ

FACULTY OF INFORMATION TECHNOLOGY
DEPARTMENT OF COMPUTER GRAPHICS AND MULTIMEDIA

ROZPOZNÁVÁNÍ POJMENOVANÝCH ENTIT

DIPLOMOVÁ PRÁCE
MASTER'S THESIS

AUTOR PRÁCE
AUTHOR

Bc. VOJTĚCH RYLKO

VEDOUCÍ PRÁCE
SUPERVISOR

Doc. RNDr. SMRŽ PAVEL, Ph.D.

BRNO 2014

Abstrakt

V této práci je načrtnuta historie a jsou představena teoretická východiska rozpoznávání pojmenovaných entit, na jejichž základě je implementován systém v jazyce C++ pro detekci a zjednoznačňování pojmenovaných entit. Systém používá lokální metodu zjednoznačňování a pracuje se statistikami vytvořenými z rozsáhlých webových dat Wikilinks. S vyvinutým systémem jsou prováděny experimenty a je srovnáván s alternativními implementacemi. Experimenty prokazují dostatečnou úspěšnost a rychlost systému. Systém se účastní soutěže Entity Recognition and Disambiguation Challenge 2014.

Abstract

In this master thesis are described the history and theoretical background of named-entity recognition and implementation of the system in C++ for named entity recognition and disambiguation. The system uses local disambiguation method and statistics generated from the Wikilinks web dataset. With implemented system and with alternative implementations are performed various experiments and tests. These experiments show that the system is sufficiently successful and fast. System participates in the Entity Recognition and Disambiguation Challenge 2014.

Klíčová slova

Rozpoznávání pojmenovaných entit, strojové učení, zpracování přirozeného jazyka, Wikipedia.

Keywords

Named Entity Recognition, Machine Learning, Natural Language Processing, Wikipedia.

Citace

Vojtěch Rylko: Rozpoznávání pojmenovaných entit, diplomová práce, Brno, FIT BUT, 2014

Rozpoznávání pojmenovaných entit

Prohlášení

Prohlašuji, že jsem tuto diplomovou práci vypracoval samostatně pod vedením pana docenta Pavla Smrže.

.....
Vojtěch Rylko
26. května 2014

Poděkování

Chtěl bych poděkovat vedoucímu Doc. RNDr. Pavlu Smržovi, Ph.D. za vedení a odborné rady. Dále pak Ing. Lubomíru Otrusinovi za rady a pomoc.

Obsah

Seznam tabulek

Seznam obrázků

Kapitola 1

Úvod

> *„Nezapomeňte, že jazyk neužíváme podle přesných pravidel, ostatně jsme se mu tak ani nenaučili.“* (Ludwig Wittgenstein)

Obrovské množství hodnotných informací je dnes dostupné ve formě elektronických nestrukturovaných dat. Příkladem jsou texty psané běžným jazykem v síti Internet. Získávání informací z nestrukturovaných dat je však velmi náročná úloha. Touto úlohou se zabývá počítačové zpracování přirozeného jazyka (angl. *natural language processing*, NLP), zejména jeho podobor extrakce informací (angl. *information extraction*, *IE*).

Přirozenou součástí textů jsou pojmenované entity (angl. *named entities, NEs*), které nesou podstatné relevantní informace. Za pojmenované entity považujeme slova a slovní spojení vystupující v textu jako vlastní jména nějakých entit (osob, organizací, geopolitických útvarů apod.). Protože neexistuje jednoznačný vztah mezi výrazem jazyka a jeho významem, je pro úspěšnou extrakci informací nezbytné v textech identifikovat a klasifikovat pojmenované entity. Rozpoznávání pojmenovaných entit (angl. *named entity recognition,* NER) je tedy jedním z klíčových problémů zpracování přirozeného jazyka.

S rozvojem automatického zpracování přirozeného jazyka rostou požadavky na jemnější třídění pojmenovaných entit. V současnosti se tedy místo klasifikace pojmenovaných entit do tříd používá přímo zjednoznačňování pojmenovaných entit (angl. *named entity disambiguation,* NED), při kterém se k identifikovanému výrazu přiřazuje konkrétní označovaná entita.

Značkování pojmenovaných entit nelze pro velké objemy dat provádět ručně a je nutné jej automatizovat. Tato práce se zabývá právě statistickým přístupem k automatickému zjednoznačňování pojmenovaných entit.

1.1 Cíle práce

Cílem této práce je vyvinout systém, pracovně nazývaný *nerdp*, který dokáže rozpoznávat pojmenované entity s vysokou měrou přesnosti a úplnosti a bude dostatečně výkonný pro zpracování rozsáhlých dat. Abychom byli schopni ověřit, nakolik systém splňuje zmíněné požadavky, bude nutné vyvinout i testovací systém. Ten na testovacích datech ověří správnost a výkonnost sytému a porovná ji s konkurenty.

1.2 Struktura práce

Základní úvod do rozpoznávání pojmenovaných entit a analýzy koreferencí lze nalézt v kapitole 2. Kapitola obsahuje historické poznámky s informacemi o tematických konferencích, ozřejmuje rozdíly mezi rozpoznáváním a zjednoznačňováním pojmenovaných entit, rozlišuje lokální a globální přístupy k řešení zjednoznačňování, stručně zmiňuje základní způsob analýzy koreferencí a představuje existující nástroje a způsob vyhodnocování jejich úspěšnosti.

Následuje kapitola 3, ve které je diskutován návrh samotné aplikace a popsána implementace v jazyce C++, jakož i testovací prostředí pro vyhodnocení výsledků. Jsou uvedeny základní informace o možnostech konfigurace aplikace a vstupních a výstupních formátech. Jsou zmíněny i podpůrné nástroje pro snadnější vývoj systému a tvorbu vlastního korpusu.

Kapitola 4 obsahuje popis použitých znalostních bází, trénovacích dat pro výpočet potřebných statistik, testovacích dat pro vyhodnocování systémů, dále zkoumání vhodných parametrů implementovaného systému a zejména experimenty vyhodnocující a srovnávající jednotlivé nástroje – co do jejich správnosti, výkonnosti a podobnosti. Je připojena i informace o probíhající soutěži, které se vyvinutý systém účastní. V závěru kapitoly je aplikace zkoumána z pohledu časové a prostorové náročnosti.

V poslední kapitole jsou shrnuty experimentální výsledky a načrtnut možný další vývoj aplikace.

V přílohách jsou zahrnuty ukázky výstupu systému na několika textech, metriky kódů, ukázky zdrojových kódů aplikace i testovacího prostředí, návod k použití a obsah přiloženého kompaktního disku.

Kapitola 2

Rozpoznávání pojmenovaných entit a analýza koreferencí

Rozpoznávání pojmenovaných entit je jedním z nejtěžších problémů automatického zpracování textů. Příčinou tohoto problému je neexistence jednoznačného vztahu mezi výrazem jazyka a jeho významem. Takto nejednoznačný vztah může být: *synonymií*, kdy jeden význam může být vyjádřen více jazykovými formami, nebo *homonymií,* tedy *víceznačností* (angl. *ambiguity*), kdy jedna jazyková forma může nabývat více než jednoho významu. Rozpoznávání pojmenovaných entit se zabývá zejména vztahem víceznačnosti. V tradičním pojetí této úlohy byl u pojmenované entity určován její druh (organizace, osobnost, ...), v novém pojetí, nazývaném propojování entit nebo zjednoznačňování pojmenovaných entit, je určována konkrétní denotovaná entita.

Dalším složitým problémem je *analýza koreferencí* (angl. *coreference resolution*), který se zabývá vztahem jazykových výrazů a konkrétních objektů reálného světa. Tento vztah výrazů k předmětům nebo situacím reálného světa nazýváme referencí. Výraz v textu může odkazovat ke skutečnostem mimotextovým – reference exoforická (např. *„Chamberlain se v roce 1939 mýlil, když pronesl: Myslím, že je* to *mír na celou naši dobu.“*, kde zájmeno *to* odkazuje k mimotextové skutečnosti, k Mnichovské dohodě). Nebo může výraz odkazovat k jinému výrazu uvnitř téhož textu – mít s ním shodnou referenci – reference endoforická (například *„Delfín$_i$ rozpoznal sebe$_i$ v zrcadle.“*, kde slova *delfín* a *sebe* odkazují k témuž objektu). V počítačovém zpracování přirozeného jazyka je většinou problém analýzy koreferencí chápán jako proces určování takových párů (resp. skupin) slovních výrazů, které odkazují *(referují)* ke stejnému objektu reálného světa [27].

V kapitole je načrtnut historický vývoj v oblasti pojmenovaných entit (2.1), různé přístupy k jejich zpracování s rozlišením rozpoznávání a zjednoznačňování (2.2), stručně je představeno řešení koreferencí (2.3), v podkapitole 2.4 je popsán způsob vyhodnocování úspěšnosti systémů a v závěru (2.5) jsou představeny existující nástroje. Informace v kapitole vychází zejména z publikací [17, 29, 22, 16, 19].

2.1 Historie

Mezi roky 1987 až 1997 se konalo sedm konferencí *Message Understanding Conference (MUC)* iniciovaných zejména americkou agenturou *DARPA*[1]. Jejich cílem byla podpora a vyhodnocování výzkumu v oblasti extrakce informací. Konference kladly důraz na praktické

[1] Defense Advanced Research Projects Agency, www.darpa.mil

řešení zadaných problémů: každý tým, který se chtěl zúčastnit konference, musel vytvořit systém, jenž řešil předem specifikovanou úlohu. Implementovanými systémy poté byla zpracovávána testovací data a samotná konference sloužila zejména k prezentaci a porovnávání jednotlivých přístupů k řešení.

Na šesté z těchto konferencí (MUC-6), konané v roce 1995 ve Spojených státech amerických, byly vyhlášeny (mimo jiné) úkoly rozpoznávání pojmenovaných entit *(named entity recognition task)* a řešení koreferencí *(coreference task).*

V rámci úlohy rozpoznávání pojmenovaných entit byl poprvé zaveden termín „pojmenované entity“, a to jako označení pro výrazy *jednoznačně identifikující* osoby, organizace a místa *(entities)*, časové údaje *(times)* a množstevní údaje finančních částek a procent *(quantities).* Úloha byla definována jako nalezení maxima výskytů pojmenovaných entit *(entities* označovaných ENAMEX*, times* označovaných TIMEX a *quantities* označovaných NUMEX*)* ve vstupním textu a určení jejich typu. Pro tři druhy pojmenovaných entit mohly být typy následující:

- ENAMEX
  - ORGANIZATION pro firmu, státní podnik a jiné organizace
  - PERSON pro jméno osoby a rodiny
  - LOCATION pro geopoliticky vymezené místo (město, stát, ...)
- TIMEX
  - DATE pro datum, rok, období apod.
  - TIME pro časový údaj
- NUMEX
  - MONEY pro finanční částky
  - PERCENT pro procentuální výrazy

Uveďme příklad věty s anotovanými pojmenovanými entitami z pokynů vydaných ke konferenci MUC-6 [10]:

```
Mr. <ENAMEX TYPE="PERSON">Dooner</ENAMEX> met with
<ENAMEX TYPE="PERSON">Marti Puris</ENAMEX>, president and chief executive officer
of <ENAMEX TYPE="ORGANIZATION">Ammirati & Puris</ENAMEX>, about
<ENAMEX TYPE="ORGANIZATION">McCann</ENAMEX>'s acquiring the agency with billings
of <NUMEX TYPE="MONEY">$400 million</NUMEX>, but nothing has materialized.
```

Úloha řešení koreferencí byla definována jako (zjednodušeně): vyhledávání a značkování endoforických koreferencí mezi podstatnými jmény, jmennými frázemi a zájmeny.

Na konferenci MUC navázala konference CoNLL (Conference on Computational Natural Language Learning), která se zabývala rozpoznáváním pojmenovaných entit v letech 2002 a 2003. Byl kladen větší důraz na použití metod strojového učení a na jazykovou nezávislost implementovaných systémů.

Stále však přetrvávalo jedno omezení – počet typů pojmenovaných entit byl maximálně desítky. S rozvojem počítačového zpracování přirozeného jazyka však vyvstává potřeba mnohem jemnějšího třídění pojmenovaných entit. Tato potřeba vyústila v úlohu zjednoznačňování pojmenovaných entit.

V současnosti se nejčastěji určují přímo konkrétní entity z dané báze znalostí denotované slovními výrazy. Takováto úloha je nazývána zjednoznačňování pojmenovaných entit (v zahraniční literatuře nejčastěji jako *named entity disambiguation* (NED) nebo *entity linking* (*EL*)). Danou úlohou se aktuálně zabývají konference Text Analysis Conference (TAC) pořádané americkým NIST[2] a soutěž Entity Recognition and Disambiguation Challenge (ERD 2014) pořádaná v rámci konference ACM SIGIR[3].

2.2 Přístupy ke zpracování pojmenovaných entit

Pojmenované entity jsou většinou zpracovávány ve dvou navazujících krocích – prvním je detekce a druhým je rozpoznávání nebo zjednoznačňování.

2.2.1 Detekce

Detekci *(spotting)* definujeme jako proces nalezení takových kandidátních slovních výrazů v textu (angl. *surface forms*), které jsou potencionálně pojmenovanými entitami. Slovní výraz může obsahovat více než jeden token. Detekované výrazy poté slouží jako vstup pro další zpracování.

Pravidla a regulární výrazy jsou pro detekci používány zejména u rozpoznávání. Detekce jako předzpracování pro zjednoznačňování je většinou prováděna jako vyhledávání předem známých názvů entit v textu. Protože aproximační vyhledávání[4] je výpočetně velice náročné, v praxi se používá nejčastěji variací přesného vyhledávání pomocí algoritmu Aho-Corasickové nebo prefixové trie. Často se vyhledávané známé názvy entit obohacují i o jejich synonyma a přijatelně modifikované verze.

2.2.2 Rozpoznávání

Schopnost rozpoznat druh u dříve neznámé pojmenované entity je základní součástí systémů NER. Takováto schopnost se buduje na základě pozitivních a negativních příkladů. Starší systémy používaly ručně vytvořená pravidla, zatímco nově se využívá strojového učení pro automatickou indukci systémů založených na pravidlech nebo algoritmů značkujících sekvence *(sequence labeling)*.

Z metod kontrolovaného učení *(supervised learning)* se používají např. skryté Markovovy modely *(HMM)*, rozhodovací stromy, *support vector machines* apod. V principu většina postupů přečte rozsáhlý anotovaný korpus, zapamatuje si seznam entit a vytvoří klasifikační pravidla založená na diskriminačních příznacích.

Druhým možným přístupem je částečně kontrolované učení *(semi-supervised learning)*. Motivací pro jeho využití je nedostatek trénovacích dat pro kontrolované učení – jejich získávání může být náročné a drahé. Při tomto způsobu učení se využívá takzvaný *bootstrapping*, který umožňuje učení za použití pouze malého množství příkladů a mnoho neoznačeného textu. Příklady se používají pro inicializaci algoritmu. Inicializovaný systém poté v neoznačeném textu vyhledává předložené příklady a z jejich výskytu v textu se učí. Takto může být algoritmus několikrát znovu aplikován na neoznačený text. Ilustrujme tento postup na příkladu systému pro detekci knižních názvů. Tomuto systému je na počátku předloženo

[2] National Institute of Standards and Technology
[3] http://sigir.org/
[4] Aproximační vyhledávání je vyhledávání řetězců, jejichž maximální vzdálenost dle definované metriky je nižší než nějaká daná hodnota.

omezené množství příkladů knižních názvů. Systém poté v neoznačeném textu tyto názvy vyhledává a snaží se identifikovat kontextuální příznaky společné pro tyto názvy. Následně se sytém pokusí nalézt další názvy knih na základě podobnosti kontextu. Učící proces je posléze znovu aplikován na nově nalezené příklady.

2.2.3 Zjednoznačňování

Zjednoznačňování je proces, který pro každou detekovanou pojmenovanou entitu vybere nejpravděpodobnější označovanou entitu. K jakému významu pojmenovaná entita odkazuje, záleží na kontextu jejího užití. V některých případech je správné nepřiřazovat detekované frázi žádnou entitu, neboli přiřadit entitu *null* (např. mnoho *Jiřích Nováků* zmíněných na internetu nemusí odpovídat žádné konkrétní osobě v používané bázi znalostí). Formálně se jedná o proces, který pro vstupní dokument d a množinu detekovaných frází $M = \{m_1, \ldots, m_N\}$ s bází znalostí $W = \{e_1, \ldots, e_{|W|}\}$, kde e_i je entita, nalezne přiřazení $\Gamma = (t_1, \ldots, t_N)$, kde $t_i \in W$ je entita označovaná frází m_i. Báze znalostí W obsahuje speciální entitu *null*, která se přiřazuje frázím neoznačujícím žádnou jinou entitu z báze znalostí.

Ačkoliv se proces zjednoznačňování mezi NED systémy značně liší, lze vysledovat dva základní přístupy – lokální a globální [11, 24].

Lokální přístup zjednoznačňuje každou frázi m_i odděleně a nebere v úvahu zjednoznačňování ostatních frází $m_{k \neq i}$. Nechť $\phi(m_i, t_i)$ je ohodnocovací funkce udávající pravděpodobnost, že fráze m_i označuje kandidátní entitu $t_i \in W$. Pak lokální přístup řeší následující optimalizační problém

$$\Gamma^*_{local} = \arg\max_{\Gamma} \sum_{i=1}^{N} \phi(m_i, t_i). \tag{2.1}$$

Lokální přístupy používají takovou funkci $\phi(\cdot)$, která přiřazuje vyšší skóre entitám s podobným kontextem jako fráze ve vstupním dokumentu. Kontext entit systémy získávají ze zdrojů, jako je Wikipedia, webová data apod.

Globální přístupy rozšiřují lokální přístupy o předpoklad, že korektní zjednoznačnění vytváří koherentní množinu příbuzných konceptů. Globální přístupy definují funkci koherence ψ a řeší následující optimalizační problém

$$\Gamma^*_{global} = \arg\max_{\Gamma} \left(\sum \phi(m_i, t_i) + \psi(\Gamma) \right). \tag{2.2}$$

Výše definovaný globální optimalizační problém je NP-těžký, protože kvalita přiřazení entity k frázi závisí na všech ostatních přiřazeních, a je tedy nutné jej aproximovat. Jedním přístupem je definování funkce $\psi(t_i, t_j)$ udávající odhad příbuznosti entit t_i a t_j (např. z analýzy odkazů na Wikipedii) a sestavení zjednoznačňovacího kontextu Γ', který obsahuje všechny zjednoznačňované entity pro celý dokument. Nová funkce $\psi(t_i, t_j)$ pro entitu t_i nezávisí na vybraném přiřazení ostatních entit. A je tedy řešen jednodušší problém

$$\Gamma^*_{global} \approx \arg\max_{\Gamma} \sum_{i=1}^{N} \left(\phi(m_i, t_i) + \sum_{t_j \in \Sigma'} \psi(t_i, t_j) \right). \tag{2.3}$$

One sense per discourse je často uvažovaný předpoklad při rozpoznávání a zjednoznačňování pojmenovaných entit. Jedná se o hypotézu, podle níž víceznačné slovo použité vícekráte v jednom dokumentu má vždy s vysokou pravděpodobností tentýž význam. Např. se dá očekávat, že slovo *„Obama“*, které v článku označuje osobu současného prezidenta USA, nebude na jiném místě v tomtéž článku označovat japonské město Obama v prefektuře Fukui.

2.2.4 Příznaky

Příznaky (angl. *features)* jsou charakteristické atributy zkoumaného fenoménu určené pro následné algoritmické zpracování. Nabývají logické hodnoty příznak přítomen *(true)* / příznak nepřítomen *(false),* kategorické hodnoty (např. slovní druh slova), číselné hodnoty nebo řetězce.

Příznaky na úrovni jednoho slova jsou například: velké první písmeno, všechna písmena velká, obsahuje číslici, končí interpunkčním znaménkem, kořen slova, délka apod. Slovníkové příznaky využívají seznam prvků. Je-li zkoumaný prvek (nejčastěji slovo) v seznamu, poté nabývá příznak hodnoty pravda. Příkladem takovéhoto slovníku může být seznam pozitivně zabarvených hodnotících slov.

Dokumentové a korpusové příznaky, důležité pro úlohu NED, se vztahují k obsahu a struktuře dokumentu anebo k celému korpusu. Jsou jimi: poloha v rámci věty, počet výskytů v rámci dokumentu, koreference, četnost slova *(term frequency),* IDF *(inverse document frequency),* multimnožina slov *(bag-of-words)* dokumentu nebo kontextu apod.

Bag-of-words je modelem, při kterém není uvažována struktura a uspořádání slov v daném kontextu, pouze počet jejich výskytů (někdy není uvažován ani tento počet – pouze přítomnost slova). Model se často používá společně s předpokladem vzájemné nezávislosti přítomnosti slov v daném kontextu *(Naive Bayes assumption)*. Tento předpoklad zřejmě neplatí, jak je patrné z příkladu slov *číslo* a *matematika,* které se spolu vyskytují mnohem častěji než *matematika* a *modrý.* Přesto se tento předpoklad často uplatňuje, protože zjednodušuje problém a dosahuje se s ním dobrých výsledků.

TF-IDF je číselná statistika udávající, jak je dané slovo důležité pro daný kontext. Vypočítá se jako vážené násobení dvou statistik TF a IDF s případnou normalizací. Statistika TF je četnost slova v dokumentu a IDF je převrácená četnost slova ve všech dokumentech. Pokud se provádí váhování statistik, využívá se většinou logaritmů. Protože předpis pro výpočet TF-IDF může mít mnoho variant, uvedeme pro příklad jednu dle knihy [16]:

$$\mathrm{tfidf}(i,j) = \begin{cases} (1 + \log(\mathrm{tf}_{i,j})) \log \frac{N}{\mathrm{df}_i} & \text{pokud } \mathrm{tf}_{i,j} \geq 1 \\ 0 & \text{pokud } \mathrm{tf}_{i,j} = 0, \end{cases} \tag{2.4}$$

kde $\mathrm{tf}_{i,j}$ je počet výskytů slova w_i v dokumentu d_j, člen df_i je počet dokumentů v korpusu, které obsahují slovo w_i a konečně N je počet dokumentů.

2.3 Analýza koreferencí

Jedná se o problém s vysokou mírou komplexity. Pro jeho řešení se využívá různých heuristických pravidel, příznaků na úrovni slov, sémantických značek etc. Z praktických důvodů je vhodné rozdělit koreference na koreference využívající jazykových prostředků, jako jsou

zájmena, příslovce místa atd. (např. „*Tomáš*$_i$ přišel do práce pozdě. Budeme *ho*$_i$ muset pokárat.“), a koreference pomocí synonym („*Tomáš Výpustek*$_i$ přišel do práce pozdě. Budeme muset *Výpustka*$_i$ pokárat.“). První druh koreferencí většina systémů NED nepodporuje.

Jednoduchým a častým přístupem k řešení koreferencí je vyhledání první předcházející pojmenované entity kompatibilní se zkoumaným členem (kompatibilní je např. zájmeno *ona* s entitou *Maria Curie-Skłodowska*, nikoli už s entitou *Moždíř*). Tento postup vychází z pozorování, že koreference odkazují většinou anaforicky, tedy k předcházejícímu kontextu, a méně často kataforicky, tedy ke kontextu následujícímu.

2.4 Vyhodnocování

Nejčastěji používanými metrikami pro vyhodnocení úspěšnosti výše diskutovaných úloh jsou přesnost *(precision)* $P = tp/(tp + fp)$ a úplnost *(recall)* $R = tp/(tp + fn)$, které vycházejí z tabulky 2.1 [16, 4]. Pozitivní případy tp jsou systémem určeny správně, negativní tn jsou případy, u kterých systém správně nedetekoval nic (resp. detekoval entitu *null),* falešně pozitivní *fp* jsou případy, kdy systém detekoval frázi, která není pojmenovanou entitou, nebo určil označovanou entitu špatně, a falešně negativní fn jsou případy, kdy systém neurčil nic nebo určil entitu *null* pro frázi, která je pojmenovanou entitou. Přesnost vyjadřuje poměrově, kolik identifikovaných entit bylo vyhodnoceno správně, a úplnost vyjadřuje, kolik entit bylo vyhodnoceno správně v poměru ke všem detekovatelným entitám.

Pro porovnání úspěšnosti se používá harmonický průměr přesnosti a úplnosti – skóre $F_1 = 2 \cdot P \cdot R/(P + R)$. Skóre F_1 budeme považovat za hlavní vyhodnocovací metriku, protože se používalo pro vyhodnocení soutěží MUC a CoNLL, a bude použito i pro určení vítěze soutěže ERD 2014.

V praxi se rozsah anotací v textu považuje za dostatečně shodný, pokud se anotace překrývají. Tedy pokud ve větě „*I. Novák se nedostavil do práce.*“ je zlatým standardem označit *I. Novák* za osobu, je považováno označení pouze řetězce *Novák* za dostačující. Tato relace O je sice reflexivní a symetrická, ale není tranzitivní, a nelze ji tedy považovat za ekvivalenci.

Někdy může být užitečné vyhodnocení *podobnosti* výstupů dvou systémů NER. Podobnost $S(M_a,\Gamma_a,M_b,\Gamma_b)$ systémů a a b vypočteme jako

$$S(M_a,\Gamma_a,M_b,\Gamma_b) = \frac{|\{e_i \in \Gamma_a, m_i \in M_a | \exists\, (e_j \in \Gamma_b, m_j \in M_b) : (m_i,m_j) \in O \wedge e_i = e_j\}|}{|M_a| + |M_b|} + \frac{|\{e_i \in \Gamma_b, m_i \in M_b | \exists\, (e_j \in \Gamma_a, m_j \in M_a) : (m_i,m_j) \in O \wedge e_i = e_j\}|}{|M_a| + |M_b|}. \tag{2.5}$$

Podobnost $S(\cdot)$ nabývá hodnot $\langle 0,1 \rangle$, je symetrická a platí $S(M_a,\Gamma_a,M_a,\Gamma_a) = 1$.

	Správně	Chybně
Rozpoznáno	tp	fp
Nedetekováno	tn	fn

Tabulka 2.1: Kontingenční tabulka pro vyhodnocování NER systémů

systém	typ	znalostní báze	zjednoznačňování
NLTK	NER	-	
Stanford NER	NER	-	
DBpedia Spotlight	NED	DBpedia	lokální
Calais	NED	Calais	
AIDA	NED	YAGO2s	globální – *CocktailParty*
Illinois Wikifier	NED	Wikipedia	globální – koherence
Wikipedia-miner	NED	Wikipedia	lokální
TagMe	NED	Wikipedia	globální – *voting scheme*
Decipher NER	NED	Wikipedia a Freebase	lokální
nerdp	NED	Wikipedia a Freebase	lokální

Tabulka 2.2: Srovnání existujících nástrojů

2.5 Existující nástroje

Existuje celá škála nástrojů, které jsou schopny nalézat a klasifikovat pojmenované entity v nestrukturovaném textu. Nástroje se liší typy entit, které rozpoznávají (několik hrubých typů versus velice jemná granularita s miliony entit), důrazem na vybranou část úlohy NER (rozpoznávání nebo zjednoznačňování) a různými úrovněmi chybovosti, úplnosti, rychlosti a škálovatelnosti. Nástroje se taky odlišují způsobem a snadností integrace.

Uveďme nyní několik zajímavých nástrojů, jejichž srovnání je v tabulce 2.2. K některým nástrojům připojíme jako ukázku jimi anotovanou větu *„Paul Kane began a career as a sign and furniture painter at York where he met James Bowman. Bowman had persuaded Kane to study art in Europe. Kane returned in early 1843 to Mobile, Alabama.“* (formát ukázek je detailně popsán v podkapitole 4.3 na straně 35):

NLTK je knihovna v jazyce Python, která slouží ke komplexnímu zpracování přirozeného jazyka [1]. Jednou z jejích funkcí je i rozpoznávání pojmenovaných entit. Umožňuje rozpoznávat devět typů entit (organization, person, location, date, time, money, percent, facility, gpe) pomocí již natrénovaného klasifikátoru dostupného pomocí funkce `nltk.ne_chunk()`. Kód je dostupný pod licencí *Apache Licence 2.0*[5].

Stanford NER je implementací NER v jazyce Java [8]. Umožňuje natrénování vlastních modelů nebo použití již připravených. Rozpoznává sedm typů entit (location, time, person, organization, money, percent, date). Implementace je dostupná pod svobodnou licencí *GNU General Public License*[6].

DBpedia Spotlight je framework využívající mnoha knihoven a je napsán převážně v jazycích Java a Scala[7] [18, 6]. Program je dostupný jak ve formě zdrojových kódů pro lokální použití, tak i jako webová služba. Aktuálně je DBpedia Spotlight schopen zjednoznačňovat asi 1,7 milionu entit, které identifikuje pomocí názvů Wikipedia článků. Pro zjednoznačňování používá lokální přístup – skóre entity pro danou frázi je váženým součtem apriorní pravděpodobnosti entity pro tuto frázi a podobnosti kontextu fráze a entity. Pro výpočet podobnosti kontextů používá kosinovy podobnosti a TF-IDF, popř. TF-ICF (metrika, u které je vyšší skóre přiřazeno slovům, jež se vyskytují u méně

[5] http://www.apache.org/licenses/LICENSE-2.0
[6] Všeobecná veřejná licence GNU. Více na http://www.gnu.org/licenses/gpl-2.0.html
[7] Scala je multiparadigmatický programovací jazyk, který lze přeložit pro běh na Java Virtual Machine.

entit; vyšší skóre tak připadá slovům více diskriminačním). Je šířen pod svobodnou licencí *Apache Licence, 2.0*.

Ukázka Paul Kane began a career as a sign and furniture *(Furniture)* painter *(Painting)* at York *(York,_ Upper_ Canada)* where he met *(Metropolitan_ Museum_ of_ Art)* James Bowman. Bowman had persuaded Kane to study art *(Art)* in Europe. Kane returned in early 1843 to Mobile, Alabama *(Mobile,_ Alabama)*.

Calais[8] je proprietární webová služba, která umožňuje anotovat nestrukturovaný text, včetně zjednoznačňování entit, jenž identifikuje vlastními identifikátory. Službu je možno používat zdarma do množství 50 000 zpracovaných dokumentů za 24 hodin a maximální rychlosti čtyř dokumentů za sekundu. Službu provozuje mezinárodní mediální a informační společnost Thomson Reuters Corporation[9]. Zdrojové kódy nejsou veřejně dostupné.

AIDA je framework napsaný v jazyce Java[10], který v textu detekuje pojmenované entity, jež mapuje na entity ze své znalostní báze YAGO2s. Ta obsahuje i informace o sémantické souvislosti entit [14, 28]. Znalostní báze YAGO2s obsahuje více než 10 miliónů entit odvozených z Wikipedia, WordNet[11] a Geonames[12]. AIDA detekuje pojmenované entity v textu pomocí *Stanford NER* a kromě lokálního zjednoznačňování umožňuje i globální – nazvané *CocktailParty*, při kterém se využívá informací ze znalostní báze YAGO2s pro maximalizaci koherence mezi vybranými entitami, a to pomocí iteraktivního algoritmu založeného na grafech. AIDA je distribuována pod nekomerční licencí *CC BY-NC-SA 3.0*[13].

Ukázka Paul Kane *(Paul_ Kane)* began a career as a sign and furniture painter at York *(New_ York)* where he met James Bowman *(James_ Bowman_ (countertenor))*. Bowman *(James_ Bowman_ (countertenor))* had persuaded Kane *(Paul_ Kane)* to study art in Europe *(Europe)*. Kane *(Paul_ Kane)* returned in early 1843 to Mobile, Alabama *(Mobile,_ Alabama)*.

Illinois Wikifier vyhledává a zjednoznačňuje v textu pojmenované entity extrahované z textů odkazů a titulků z Wikipedie [24]. Proces zjednoznačňování je řešením optimalizačního problému hledání globální koherence mezi všemi entitami. Používá skóre příbuznosti založené na vyhledávání klíčových slov ve vyhledávači Google a *míru asociace – pointwise mutual information*. Software je dostupný pod svobodnou licencí *Illinois Open Source License*[14].

Wikipedia-miner je sada nástrojů umožňující (mimo jiné) detekci pojmenovaných entit v textu a jejich zjednoznačnění přiřazením odpovídající stránky na Wikipedii [20]. Systém využívá strojového učení na datech extrahovaných z Wikipedie. Používá tři

[9] http://thomsonreuters.com/
[10] Zdrojové kódy dostupné z https://github.com/yago-naga/aida
[11] WordNet je velká lexikální databáze angličtiny definující synonyma a sémantickou podobnost slov – http://wordnet.princeton.edu/
[12] Geonames je geografická databáze pokrývající všechny státy světa s více než osmi milióny názvů míst – http://www.geonames.org/
[13] Creative Commons Attribution-NonCommercial-ShareAlike 3.0 Unported License - http://creativecommons.org/licenses/by-nc-sa/3.0/
[14] *http://opensource.org/licenses/NCSA*

hlavní příznaky: apriorní pravděpodobnost entity, míru shodnosti kontextu fráze a kontextu, odkud byla entita extrahována, a *kvalitu kontextu* pro nastavení poměru mezi apriorní pravděpodobností a mírou shodnosti kontextu. Nástroje lze stáhnout pod licencí *GNU General Public License v.3*[15] nebo využít jako webovou službu.

Ukázka Paul Kane *(Paul_Kane)* began a career as a sign and furniture *(Furniture)* painter *(Painting)* at York where he met James Bowman *(James_Bowman_(countertenor))*. Bowman had persuaded Kane to study art *(Art)* in Europe *(Europe)*. Kane returned in early 1843 to Mobile, Alabama *(Mobile,_Alabama)*.

TagMe Jedná se o webovou službu, která nalézá v textu pojmenované entity a značkuje je odpovídající adresou článku na Wikipedii [7]. V textu detekuje pojmenované entity pomocí informací extrahovaných z názvů článků, přesměrování a odkazů na Wikipedii. K zjednoznačňování používá graf příbuznosti entit sestrojený analýzou odkazů v článcích Wikipedie a různé heuristiky pro zvýšení správnosti (princip nazývá *voting scheme)*. TagMe je navrženo zejména pro anotování kratších textů. Zdrojové kódy jsou od roku 2014 dostupné na žádost pod licencí *Apache Licence, 2.0.*

Ukázka Paul Kane *(Paul_Kane)* began a career as a sign and furniture *(Furniture)* painter *(Painting)* at York where he met James Bowman *(James_Bowman_(countertenor))*. Bowman had persuaded Kane *(Kane,_Pennsylvania)* to study art *(Art)* in Europe *(Europe)*. Kane returned in early 1843 to Mobile, Alabama *(Mobile,_Alabama)*.

Decipher NER je nástroj pro vyhledávání a zjednoznačňování pojmenovaných entit vyvinutý na FIT BUT v rámci projektu *Decipher*[16]. Nalezené entity identifikuje pomocí Wikipedia URI a Freebase URI. Jedná se o jediný doménově specializovaný nástroj, a to na oblast kultury.

Ukázka Paul Kane *(Paul_Kane)* began a career as a sign and furniture painter at York *(Prince_Andrew,_Duke_of_York)* where he *(coref Paul_Kane)* met James Bowman *(ulan_id=500031694)*. Bowman *(coref ulan_id=500031694)* had persuaded Kane *(Paul_Kane)* to study art in Europe *(Europe)*. Kane *(Paul_Kane)* returned in early 1843 *(1843-00-00)* to Mobile, Alabama *(Mobile,_Alabama)*.

nerdp Systém NED vyvíjený v rámci této práce.

Ukázka Paul Kane *(Paul_Kane)* began a career as a sign and furniture painter at York *(York)* where he met James *(William_James)* Bowman. Bowman had persuaded Kane to study art in Europe *(Europe)*. Kane returned in early 1843 *(1843-00-00)* to Mobile, Alabama *(Mobile,_Alabama)*.

[15] *http://www.gnu.org/licenses/gpl.html*
[16] *http://www.decipher-research.eu/*

Kapitola 3

Návrh a implementace

V této kapitole jsou prvně shrnuty požadavky na systém. Z nich vyplývá, že je nutno implementovat jak samotný systém, tak i testovací prostředí. Po návrhu a popisu implementace samotného systému tedy následuje i popis testovacího prostředí. V závěru jsou zmíněny i některé podpůrné skripty a nástroje, bez kterých by nebylo možné efektivně systém vyvíjet, ověřovat a zlepšovat.

3.1 Požadavky

Implementovaný systém musí zjednoznačňovat pojmenované entity a řešit koreference, a to s vysokou měrou přesnosti a úplnosti. Dále je na systém kladen výkonnostní požadavek rychlého zpracování rozsáhlých dat. Systém bude spouštěn pod operačním systémem Linux Ubuntu s pamětí $\geq 128\,\text{GiB}$ a s procesorem Intel Xeon E5, a to jako konzolová aplikace. Entity jsou reprezentovány URL článku na Wikipedii.

Aby bylo možné ověřit splnění výše uvedených požadavků, je nutné implementovat testovací prostředí. Testovací prostředí musí být schopno měřit přesnost, úplnost, F_1 skóre a výkonnost testovaných systémů.

Protože při vývoji ostatních testovaných systémů mohly být použity poskytované testovací sady, bude vytvořen nový testovací korpus nazvaný pracovně *KnotCorpus*. Pro usnadnění tvorby testovacího korpusu bude implementováno jednoduché grafické rozhraní pracovně nazývané *handy*.

3.2 Metoda zjednoznačňování

Pro potřeby navrhovaného systému jsou adaptovány lokální přístupy z [11, 14, 18]. Každá pojmenovaná fráze m_i je tedy zjednoznačňována zvlášť, a to pomocí jejího *apriorního skóre* $a(m_i,e_j)$ a *kontextového skóre* $c(m_i^c,e_j^c)$. Pro každou detekovanou pojmenovanou entitu m_i známe množinu E_i entit, které mohou být pojmenovanou entitou označovány (resp. tyto informace odvodíme z datových sad). Poté $a(m_i,e_j)$ pro všechna $e_j \in E_i$ značí pravděpodobnost, s jakou fráze m_i označuje entitu e_j. Tuto pravděpodobnost je nutno získat z dostatečně velkých dat (autoři v [14] tyto hodnoty získávají analýzou odkazů na Wikipedii). Např. fráze „Ford“ označuje s pravděpodobností 89,6 % Ford Motor Company, s 6,6 % Geralda Forda a s 3,8 % ostatní entity dle dat Wikilinks.

Kontextové skóre $c(m_i^c,e_j^c)$ udává, nakolik je kontext m_i^c fráze m_i „kompatibilní“ s kontexty, ve kterých se běžně vyskytuje entita e_j. Kontexty jsou reprezentovány modelem *bag-*

of-words a normalizovány hodnotou IDF. Běžný kontext e_j^c entity e_j je sestaven jako součet všech *bag-of-words* kontextů, ve kterých se entita e_j vyskytuje v trénovacích datech. Hodnoty v takto agregovaném kontextu jsou poté normalizovány velikostí tohoto kontextu. Kontextové skóre se posléze spočte následovně:

$$c(m_i^c,e_j^c) = \frac{m_i^c \cdot e_i^c}{|m_i^c|\,|e_i^c|}, \tag{3.1}$$

kde všechna slova jsou vážena hodnotou IDF.

Výsledné skóre $v(m_i,e_j)$ se počítá jako $v(m_i,e_j) = A \cdot a(m_i,e_j) + (1 - A) \cdot c(m_i^c,e_j^c)$, kde $A \in \langle 0,1 \rangle$ je apriorní váha udávající, nakolik má být systém senzitivní ke kontextu. Apriorní váhu A je nutno empiricky určit.

ookb je heuristickou modifikací výše uvedené metody vytvořenou při experimentování s implementovaným systémem. Metoda spočívá v tom, že mezi kandidátní entity je vždy přidána entita *null*. Její kontext $null^c$ je průměrem kontextů všech ostatních entit. Toto rozšíření umožňuje produkovat ve výstupu entity *null* a snížit míru falešně pozitivních případů. Tato modifikace je prakticky realizována jako odečtení skóre $c(m_i^c,null^c)$ od všech skóre $c(m_i^c,e_j^c)$ a následné odstranění kandidátních entit e_j se záporným výsledkem.

3.3 Systém *nerdp*

Vzhledem k požadavkům na výkonnost a běhové prostředí byl jako implementační zvolen jazyk C++ v aktuální verzi C++11. Dostatek poskytované paměti umožňuje, aby nebyla využívána databáze a systém si udržoval všechna potřebná data v paměti. Toto rozhodnutí implikuje řešení systému jako serveru; serverová architektura je u NED systémů běžná. Protože moduly, na kterých je budovaný systém závislý, nejsou určeny pro vícevláknové prostředí, zvolená architektura obsahuje „pouze“ jedno pracovní vlákno a další vlákno obsluhující fronty příchozích a odchozích požadavků. Běh serveru je ukončen příjmem signálu SIGINT.

Aplikace komunikuje s okolím, a je tedy nutné definovat kódování řetězců. Systém používá výhradně tabulku znaků Unicode v kódování UTF-8, což je dnes u podobných systémů nejběžnější. Jako interní reprezentaci řetězců používá posloupnost bytů v kódování UTF-8.

Protože báze znalostí je společná pro vícero systémů, bylo by neefektivní, aby si ji každý držel v paměti separátně. Dále je nutné, aby báze znalostí byla napříč systémem konzistentní. Proto je použita *SharedKB* systému Decipher NER.

Výstupní formát programu je JSON, jak je běžné mezi NED systémy. Vstupní formát je hybridní z důvodu výkonnosti.

Detekce pojmenovaných entit je prováděna pomocí externího modulu *figa*. Ten používá konečný stavový automat, je schopen pracovat s texty v kódování UTF-8, je extrémně rychlý a paměťově úsporný. Získání tokenů, nalezení dat a detekce možných koreferencí zájmeny a příslovci je prováděno pomocí tokenizátoru postaveného na regulárních výrazech.

Statistické informace nutné pro detekci a zjednoznačňování jsou vytvářeny separátním programem *stats* a jsou uloženy v textových souborech.

Z důvodů efektivity časové i prostorové je nezbytné při zpracování přirozeného jazyka mapovat slova na číselné identifikátory, a to konzistentně. Zároveň toto mapování musí být maximálně rychlé. Těmto požadavkům vyhovuje externí knihovna *Constant Quark Database (CQDB)* [23].

	B	o	ž		e	t	ě		c	h
offset znaku	0	1	2		3	4	5		6	7
Unicode znaky (hex)	0042	006f	017e		0065	0074	011b		0063	0068
offset v Unicode	0	1	2		3	4	5		6	7
UTF-8 kódování (hex)	42	6f	c5	be	65	74	c4	9b	63	68
offset v UTF-8	0	1	2	3	4	5	6	7	8	9

Tabulka 3.1: Ilustrace různých způsobů kódování řetězce „Božetěch“.

Logika zjednoznačňování je v třídě *PNERD*, která pro svou činnost využívá výše uvedených částí systému.

Celý systém je v jediném jmenném prostoru *nerdp*. (Jmenný prostor bude dále uváděn pouze u prvního výskytu identifikátoru.)

Zjednodušený diagram tříd 3.1 naznačuje základní třídy systému a jejich vazby.

3.3.1 Komunikace

Jako knihovna pro rychlou asynchronní komunikaci je zvolena ØMQ [12]. Tato knihovna spravuje frontu příchozích a frontu odchozích požadavků, a to v separátním vlákně, jak ilustruje obrázek 3.2. Stojí nad transportní vrstvou a podporuje komunikaci mezi vlákny pomocí sdílené paměti, mezi procesy pomocí socketů, komunikaci přes TCP a další. Zároveň přímo implementuje komunikační vzory, jako jsou *publisher-subscriber, distribuce úloh, request-reply* apod.

Vyvíjený systém využívá vzor *request-reply*. Postup je následující: příjem požadavku, zpracování, odeslání odpovědi, přičemž vstupní požadavky jsou řazeny při vytížení do fronty FIFO. Hlavní programová smyčka vypadá v principu takto:

```
1  zmq::context_t context;
2  zmq::socket_t server(context, ZMQ_REP);
3  server.bind("ipc://tmp/nerdp");
4  while (1) {
5      zmq::message_t msg;
6      server.recv(&msg);
7      // zpracuj zprávu msg
8      std::string response = zpracuj(msg);
9      s_send(server, response);
10 }
```

3.3.2 Kódování

Nejběžnějším způsobem kódování řetězců je dnes využití tabulky znaků Unicode s použitím kódování UTF-8. Řetězec „Božetěch“ v tabulce 3.1 ilustruje odlišnosti různých přístupů k nakládání s řetězci. Každý znak v řetězci je reprezentován číslem v tabulce Unicode, která definuje přes milion symbolů. To znamená, že pro reprezentaci znaků je nutno použít větších čísel, než odpovídá jednomu bajtu. Z důvodu efektivity se místo velkých čísel z tabulky Unicode využívá kódování. Offsety znaků, jak vidno z ilustrační tabulky, však nekorespondují s offsety bajtů při použití kódování.

Pro komunikaci s okolím aplikace používá Unicode v kódování UTF-8. Pro interní reprezentaci řetězců jsou tyto možnosti: používat standardní posloupnost bytů *char* v kódování

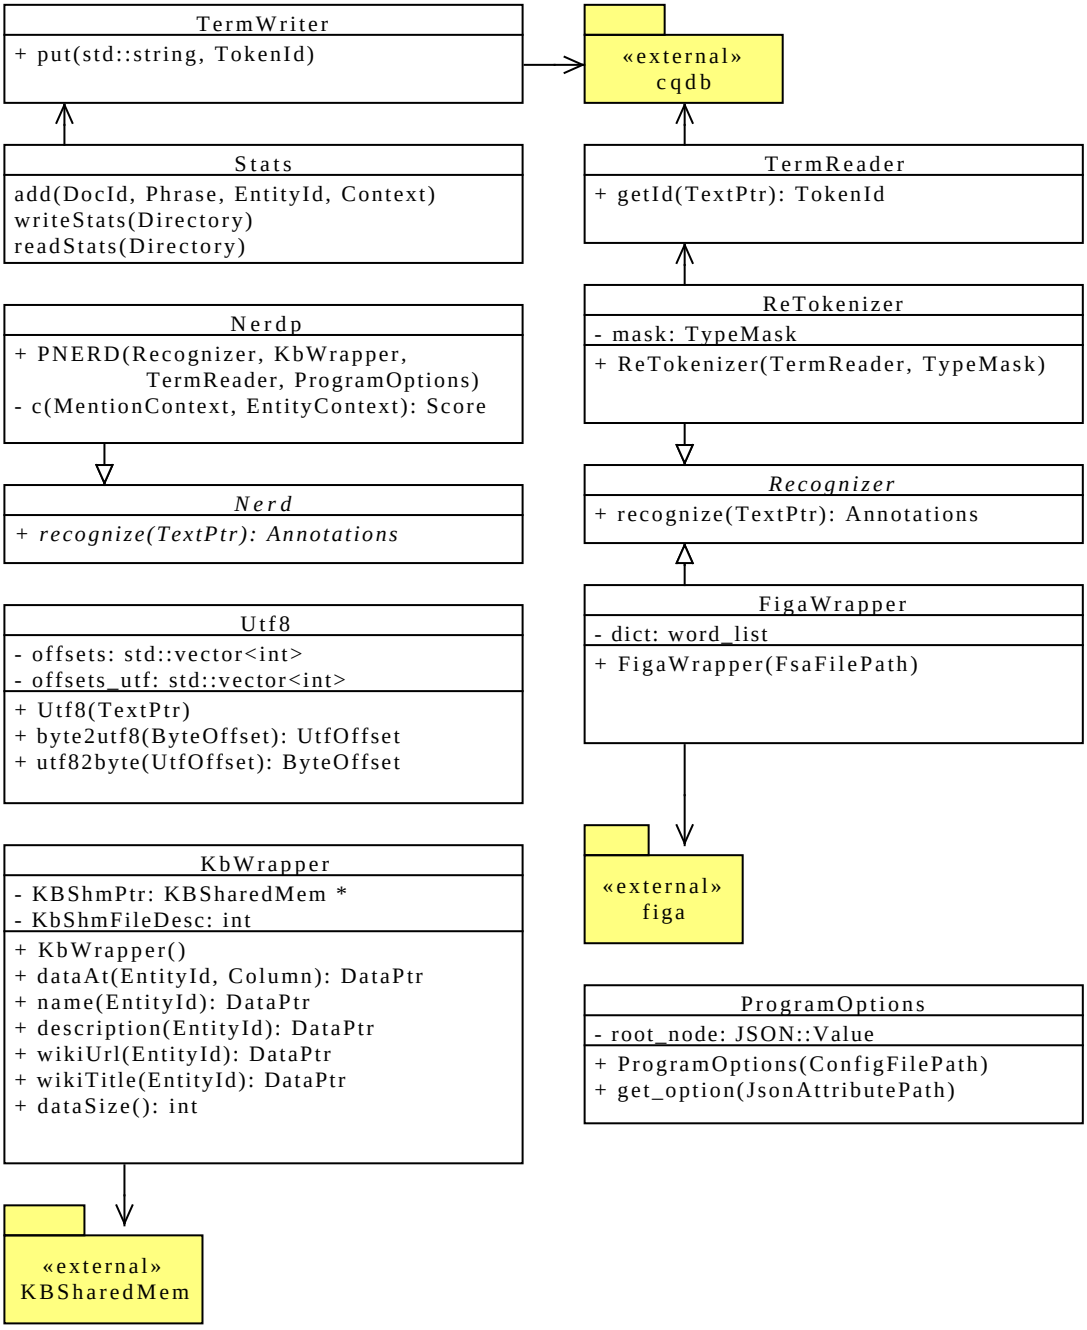

Obrázek 3.1: Diagram tříd systému *nerdp*

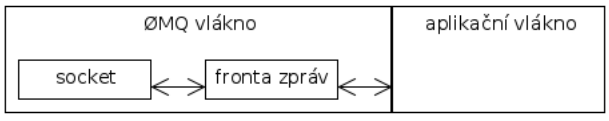

Obrázek 3.2: Vlákna systému

UTF-8, nebo použít knihovny ICU[1] pro korektní zacházení s řetězci Unicode. Výhodou prvního přístupu, s ohledem na převažující anglické texty, je úspora místa v paměti, což je důležité kvůli rozsáhlým statistikám, a skutečnost, že není třeba měnit kódování při vstupu a výstupu. Nevýhodou je potřeba přepočítávat offsety mezi řetězcem a jeho reprezentací v paměti. Druhý způsob je značně robustní, náročnější na paměť a umožňuje korektní manipulace s řetězci (např. převést správně velké písmeno „Č“ na malé).

Systém nepotřebuje pokročilou manipulaci s řetězci, používá knihovny, které pracují současně s řetězci v UTF-8 a s offsety znaků, a musí poskytovat na výstupu offsety v bytech i znacích. Proto využívá prvního přístupu – reprezentace řetězců v paměti v kódování UTF-8. Převody mezi offsety znaků v řetězci a offsety v poli bytů jeho kódované reprezentace zajišťuje třída *nerdp::UTF8*.

Třída *UTF8* funguje tak, že při inicializaci řetězcem *str* vytvoří dva vektory offsetů a průchodem řetězcem *str* je inicializuje na správné hodnoty. Takto inicializovaný objekt třídy *UTF8* v konstantním čase dokáže pro řetězec *str* provádět konverze *offset v řetězci* $\leftrightarrow$ *offset v bytech*. Třída nevaliduje správné kódování řetězce *str*. V případě, že je požadována nevalidní konverze z offsetu v bytech pro takovou hodnotu, která není na rozhraní znaků, je vrácena záporná hodnota odpovídajícího znaku. Příkladem takto nevalidního požadavku je, dle tabulky 3.1, požadavek konverze z offsetu bytu 3, který je uprostřed sekvence pro kódování znaku *ž*. Pro takovýto nevalidní požadavek by bylo vráceno -2, tedy záporná hodnota offsetu 2 znaku *ž*. V praxi při správném kódování vstupního řetězce k takto nevalidním požadavkům v systému nedochází.

3.3.3 Detekce

Pro detekci je využit stávající spotter *figa* systému Decipher NER. Jedná se o extrémně rychlý a paměťově efektivní spotter založený na konečném automatu. Jeho výstupem je seznam číselných identifikátorů entit potencionálně označovaných danou frází, pozice a fráze pojmenované entity. Pro ilustraci: pro větu „Barack Obama je současný prezident USA.“ je výstup spotteru následující:

identifikátory entit	*počáteční offset*	*koncový offset*	*fráze*
1709202;778569	1	12	Barack Obama
3325567;3344191;778569	8	12	Obama
3346081	36	38	USA

Z ukázky je patrné, že modul je schopen detekovat i překrývající se pojmenované entity. Navrácené offsety jsou offsety v řetězci, nikoli v bytech.

Třída *nerdp::FigaWrapper* zapouzdřuje použití modulu *figa*; je zde využit návrhový vzor fasáda. V současném stavu *figa* neobsahuje vhodné C++ API a poskytuje svůj výstup v jednom řetězci typu *std::string* ve formátu tabulátorem oddělených hodnot, viz ukázka výše. Třída *FigaWrapper* tento výstup analyzuje a poskytuje již v systému běžný seznam anotací. Díky použití návrhového vzoru fasáda bude snadné systém upravit pro novou verzi modulu *figa* s C++ API.

3.3.4 Tokenizace

Detekce slov, dat a možných koreferencí pomocí zájmen a příslovcí je prováděna na základě regulárních výrazů třídou *nerdp::ReTokenizer*. Regulární výrazy jsou zapsány ve speciál-

[1] ICU je kolekce knihoven v C++ a Java poskytující plnou podporu pro Unicode. Více na http://site.icu-project.org/

ních komentářích v implementaci třídy v souboru *ReTokenizer.re,* který je před kompilací přeložen do kódu v jazyce C++ nástrojem *re2c* [3]. Tím je vygenerován automat pro analýzu textu. Nástroj *re2c* produkuje extrémně rychlý a paměťově efektivní kód. Díky zápisu pomocí regulárních výrazů je velice snadné rozšířit nebo upravit způsob zpracování textu.

Spojení tokenizace, tedy detekce slov, interpunkčních znamének apod. s vyhledáváním dat a možných koreferencí poskytuje výhodu jediného průchodu vstupním textem. Třída *ReTokenizer* tokenizuje i text rozpoznaný jako např. datum – tato operace musela být zvláštně ošetřena: je-li detekován speciální výraz (koreference, datum), je přidán do odpovědi a poté se ukazatel aktuální pozice v textu navrátí před tento výraz a provede se tokenizace v módu ignorace speciálních výrazů. Jakmile se aktuální pozice dostane za detekovaný speciální výraz, pokračuje se v módu detekce všech výrazů. Tento mechanismus pomáhá i při zahazování nevalidních dat. Pro tyto módy skenování poskytuje přímou podporu *re2c.*

Pomocí bitové masky lze při požadavku na zpracování textu upřesnit, jaké typy údajů budou navráceny. To slouží k mírné optimalizaci pro případy, kdy není potřeba detekovat např. kalendářní data.

Ilustrujme výše zmíněné principy na zjednodušené ukázce několika regulárních výrazů pro detekci letopočtu, koreference pomocí osobního zájmena ženského rodu a tokenů:

```
1 YEAR4  = [012] [0-9] [0-9] [0-9];
2
3 YEAR4       { string2date("%Y", start_pointer); return AnnType::Date; }
4
5 'She'|'she'|'Her'|'her'|'Hers'|'hers'|'herself'
6             {*gender = Gender::Female; return AnnType::ReferingString; }
7
8 [a-zA-Z0-9&]+                          {return AnnType::Token;}
9 [a-zA-Z0-9&\x80-\xFD]+                  {return AnnType::UtfToken;}
```

Jako podpůrný nástroj byl implementován filtr[2] *tokenizer,* který využívá výše popsané třídy k jednoduchému zpracování vstupního textu a generuje na výstupu proud tokenů. Pro text *„Je noc: teď hlasitěji mluví vše řinoucí se studny. (Tak pravil Zarathustra, vydání XYZ 1.1.2010)“* je výstup (bez interpunkčních znamének a mezer) následující:

[2] *Filtr* je v Unixových systémech program, který většinu dat získává se standardního vstupu a tiskne své výsledky na standardní výstup. *Filtry* se často propojují Unixovými rourami.

Je	Token	
noc	Token	
teď	UtfToken	
hlasitěji	UtfToken	
mluví	UtfToken	
vše	UtfToken	
řinoucí	UtfToken	
se	Token	
studny	Token	
Tak	Token	
pravil	Token	
Zarathustra	Token	
vydání	UtfToken	
XYZ	Token	
1.1.2010	Date	2010-01-01
1	Token	
1	Token	
2010	Token	

Ukázka demonstruje způsob rozdělení textu na slova, rozlišování slov obsahujících znaky s ordinální hodnotou vyšší než 127 *(UtfToken)* a detekci data *1. 1. 2010* i jeho tokenů.

3.3.5 Báze znalostí

Pro přístup k bázi znalostí je použit podsystém *SharedKB* systému Decipher NER. Tento podsystém se skládá ze dvou částí – z démona *decipherKB-daemon*, který efektivně načte bázi znalostí ze souboru do sdílené paměti, a z modulu *libKB_shm,* který poskytuje C++ API pro přístup k bázi znalostí ve sdílené paměti.

Formát báze znalostí, se kterým pracuje démon *decipherKB-daemon,* se skládá z hlavičky a z dat dle specifikace hlavičky. Jednotlivé hodnoty jsou odděleny tabulátory. Nejjednodušší báze znalostí může vypadat následovně:

```
e:entity  ui:wikipedia_url

e:33426   http://en.wikipedia.org/wiki/1926_VFA_season
e:33427   http://en.wikipedia.org/wiki/1926_VFL_Grand_Final
e:33428   http://en.wikipedia.org/wiki/1926_VFL_season
                              ⋮
```

Klíč *e* určuje typ záznamu – v příkladu je to *entity.* Za klíčem následuje identifikátor – číslo. Pro druhý sloupec záznamu typu *entity* specifikuje hlavička údaj *wikipedia url.* Každý typ záznamu může mít v hlavičce specifikovány jiné údaje v jiném pořadí, což je poté nutno řešit v aplikaci.

Opět je využit vzor fasáda – třída *nerdp::KbWrapper* zapouzdřuje přístup k modulu *SharedKB* a poskytuje metody pro přístup k specifickým údajům u záznamů (např. názvy, Wikipedia adresy apod.). Přístup k některým údajům je závislý na typu záznamu – pro tyto případy jsou vybudovány mapy typu *std::map<char, unsigned short>*, které mapují klíč záznamu *char* na pozici *unsigned short* pro daný záznam a daný údaj. Získání Wikipedia URL pro libovolný typ záznamu poté vypadá následovně (zjednodušeno):

```
1  const char *KbWrapper::wikiUrl(EntityId entityId) const {
2      // ziskej ukazatel na radek zaznamu pro entityId
3      const char *row = dataAt(entityId, 1);
4      // klic zaznamu
5      const char key = *row;
6      // sloupec s Wikipeda adresou
7      unsigned short column = wikipedia_column.at(key);
8      // wikipedia adresa
9      const char *wiki_url = dataAt(entityId, column);
10     return wiki_url;
11 }
```

3.3.6 Statistické údaje a program *stats*

Třída *nerdp::Stats* poskytuje metody pro tvorbu statistik, jejich uložení do souborů (převážně v textových formátech) a opětovné načtení ze souborů. Nastavení ovlivňující tvorbu statistik jsou stručně popsána v 3.3.9. Třída je využívána ve dvou případech – k tvorbě statistik a k jejich používání. Statistiky jsou používány při zjednoznačňování, např. třídou *PNERD*.

Program *stats* pomocí třídy *Stats* čte na standardním vstupu výskyty pojmenovaných entit v textu, vytváří statistiky a ty ukládá do souborů. Vstup programu vypadá následovně: na každém řádku jsou tabulátory odděleny následující hodnoty: identifikátor dokumentu, identifikátor entity, fráze a kontext. Jeden řádek tedy odpovídá jednomu výskytu entity pojmenované danou frází v daném kontextu v rámci určitého dokumentu. Z těchto údajů poté třída *Stats* odvodí všechny potřebné statistiky.

Pomocí dodatečných transformací skripty jsou ze statistik vytvořeny soubory nutné pro kompilaci automatu modulu *figa*.

3.3.7 Mapování slov na identifikátory

K rychlému mapování slov na unikátní číselné identifikátory je použita externí knihovna *CQDB*. Jedná se o knihovnu optimalizovanou pro serializaci a získávání statických asociací mezi řetězci a číselnými identifikátory. Vlastnosti knihovny jsou:

Rychlé vyhledání číselného identifikátoru pro daný řetězec (běžně přístupem k třem paměťovým blokům) nebo řetězce pro daný číselný identifikátor (vždy přístupem ke dvěma paměťovým blokům).

Nízká režie. Databáze sestává z 24 bajtové hlavičky, hašovací tabulky (2048 bajtů a 16 bajtů na jeden záznam), pole pro zpětné vyhledávání (čtyři bajty na identifikátor) a záznamů (osm bajtů plus velikost řetězce).

Sofistikovaná hašovací funkce optimalizovaná pro maximální rychlost a odolná kolizím.

Statické asociace nedovolující žádné změny v databázi, pouze přidávání nových dvojic řetězec-identifikátor.

Práce se soubory. Databáze se dá snadno uložit a načíst ze souboru.

Databázi *CQDB* obalují třídy *nerdp::TermWriter* a *nerdp::TermReader;* první je určena pro tvorbu databáze a druhá pro její čtení. Tvorbu databáze pomocí *TermWriter* využívá třída *Stats* při tvorbě statistik – konstruuje tak databázi všech slov, se kterými bude moci

systém pracovat. Čtení z databáze prostřednictvím *TermReader* využívá zejména *ReTokenizer*, který každému detekovanému slovu přiřadí odpovídající identifikátor z databáze (popř. neplatnou hodnotu, není-li slovo v databázi – takové slovo je neužitečné a je později zahazováno).

3.3.8 Zjednoznačňování

Způsob zjednoznačňování uvedený výše v 3.2 je implementován v třídě *nerdp::PNERD,* konkrétně metodou *recognize*. Každý požadavek na zpracování textu lze parametrizovat, jak je psáno dále v 3.3.10.

Metoda *recognize* funguje následovně. Dle požadavku na zpracování správně nastaví odpovídající proměnné. Poté získá pomocí *figa* přes instanci fasády *FigaWrapper* seznam anotací – anotace je dvojice fráze a kandidátní hodnoty (entity, data nebo koreference). Fráze jsou představovány offsety v textu a entity řádkem v bázi znalostí. Pokud se fráze dvou anotací překrývají, anotace s kratší frází je odstraněna. Fráze z *figa* rozdělíme na koreferenční a entitní.

Nyní jsou pro každou entitní anotaci (m_i,e_j) vypočtena kontextová skóre. Statistické údaje e_j^c a $a(m_i,e_j)$ pro entitu e_j získáme pomocí modulu *Stats*, *bag-of-words* kontext m_i^c počítáme z tokenů získaných z *ReTokenizer* – z důvodu optimalizace toto činíme vždy pouze jednou pro všechny anotace s překrývajícími se frázemi. V případě, že je uživatelem zadaná velikost používaného kontextu větší než velikost textu, tato příprava se provádí pouze jednou. Poté se vypočítá kontextové skóre $c(m_i^c,e_j^c)$, přičemž tokeny odpovídající vlastní frázi m_i nejsou při výpočtu součástí konextu m_i^c.

Nyní již známe apriorní pravděpodobnosti i kontextová skóre entitních anotací. Můžeme je nazývat kandidátní anotace.

Následuje získání seznamu tokenů, kalendářních dat a koreferencí pomocí instance třídy *ReTokenizer*. Kalendářní data jsou přidána ke kandidátním anotacím, přičemž jejich kontextové skóre je heuristicky nastaveno na nízkou hodnotu a apriorní skóre na vysokou hodnotu (čím delší datum, tím vyšší hodnota). Koreference jsou přidány ke koreferenčním anotacím.

Nyní jsou pro každou skupinu kandidátních anotací s překrývajícími se frázemi škálovány hodnoty kontextových a apriorních skóre tak, aby ležely v intervalu $\langle 0,1\rangle$. Z takto normalizovaných hodnot již lze vypočítat finální skóre $v(m_i,e_j)$ pro každou kandidátní anotaci. Dále metoda pracuje již pouze s anotacemi, které mají v rámci skupiny nejvyšší finální skóre – tímto byly zjednoznačněny.

Zbývá vyřešit koreference. Pro některé fráze m_i známe informace, které umožňují stanovit, zda je fráze m_i kompatibilní s určitou anotací. Může být známo, zda se jedná o zájmeno bezrodé, mužského nebo ženského rodu, příslovce místa atd. V případě, že tato informace chybí (koreference pochází z *figa*), za kompatibilní anotaci považujeme takovou, která obsahuje frázi koreference jako podřetězec ve své frázi. Poté koreferenci přiřadíme tak, že iterujeme přes kandidátní anotace doleva od pozice fráze koreference, dokud nenarazíme na první kompatibilní anotaci (anotace *null* je vždy kompatibilní) nebo nepřesáhneme velikost kontextu danou uživatelem (ta je stejná jako pro výpočet velikosti kontextu m_k^c). Pokud jsme narazili na kompatibilní anotaci, přiřadíme ji ke koreferenci. Každá anotace s entitou *null* má přiřazeno unikátní číslo v rámci dokumentu – to umožňuje vytvořit koreferenci na tuto anotaci. V následující ilustraci lze vidět koreferenci zájmenem *who* na neznámou entitu označovanou frází *Alexandra,* která je s touto frází spárována pomocí identifikátoru *id* nabývajícího hodnoty jedna*:*

... with a girl named Alexandra *(? id=1)*, who *(coref id=1)* rejected ...

Takto vyřešené koreference jsou přidány ke kandidátním anotacím a je možno vytvořit finální výsledek – navrátit dle požadavku buď pouze zjednoznačněné anotace, nebo ponechat i kandidátní anotace (s odpovídajícím nižším skóre). Je-li to specifikováno v požadavku, podrobné informace o výpočtu všech skóre jsou přidány ke všem anotacím. Výstup i s podrobnými informacemi je v 3.3.10.

3.3.9 Parametry programu

Systém provádí dvě logicky zcela odlišné činnosti – buduje statistiky, anebo za pomocí nich řeší úlohu NED. Je proto rozdělen na dva separátní programy (se stejným konfiguračním souborem a argumentem, viz níže) – program *nerdp* pro NED a program *stats* pro budování statistik. Program *stats* čte na standardním vstupu data a z nich vytváří potřebné statistiky, které uloží (dle konfiguračního souboru) do výstupních souborů. Program *nerdp* dle konfigurace tyto statistiky načte a následně běží jako server a řeší požadavky.

Programy přijímají jediný argument *-c FILE*, který specifikuje cestu ke konfiguračnímu souboru. Konfigurační soubor je ve formátu JSON a obsahuje konfigurace různých modulů: *logging* pro cestu k separátní konfiguraci pro logování, *recognizer* pro cestu ke konečnému automatu modulu *figa, communication* se specifikací adresy, na které má systém naslouchat (je možno použít protokol *ipc* pro sockety nebo *TCP* pro komunikaci přes síť) a konečně *stats* s nastavením ovlivňujícím zpracování dat:

include_mention *true* pro zahrnutí samotné fráze do kontextu

include_kb_description *true* pro zahrnutí popisu entity v bázi znalostí jako kontextu

min_denotations minimální počet, kolikrát musí fráze v trénovacích datech označovat entitu, aby byl tento vztah fráze-entita brán v potaz při zjednoznačňování (toto nastavení pomáhá odfiltrovat překlepy ve frázi a raritní případy)

min_idf a max_idf tokeny mimo specifikovaný rozsah IDF jsou během trénování zahozeny a při zjednoznačňování tedy ignorovány (toto umožňuje odfiltrovat běžná slova jako *the, of, a, an* a raritní tokeny jako *00bc7d81be, aechitecture, Kropachyov)*

Zjednodušená ilustrace konfiguračního souboru:

```
{
    "logging" : {
        "conf" : "conf/logging.conf"
    },
    "recognizer": {
        "fsa_path": "nerd/local/results/automata.fsa"
    },
    "communication": {
        "bind": "ipc:///tmp/nerdp"
    },
    "stats": {
        "tokens": "stats_fbkb_tokens.tsv",
        "entities": "stats_fbkb_tokenvector.tsv",
        "phrases": "stats_fbkb_phrases.tsv",
        "include_mention" : true, "include_kb_description": false,
        "min_denotations" : 15,
        "min_idf":1.6, "max_idf":5.7
    }
}
```

3.3.10 Formát vstupu a výstupu

Komunikace se serverem probíhá textově. Při každém požadavku je možno serveru zadat parametry. Z důvodu výkonnosti je specifikován hybridní formát: první řádek požadavku obsahuje parametry ve formátu JSON a zbytek požadavku je text určený ke zpracování ve formátu UTF-8. Požadavek může vypadat následovně:

```
1 {"corefs": true, "context_size": 50, "apriori_weight": 0.5}
2 In some withdrawn, unpublic mead
3 Let me sigh upon a reed,
4 Or in the woods, with leafy din,
5 Whisper the still evening in
```

Volby požadavku. V hlavičce požadavku s JSON parametry jsou přijímány následující volby:

keep_candidates (true/false) Určuje, zda mají být v odpovědi ponechány i nevítězné kandidátní entity.

append_msgs (true/false) Nastavuje, zda má být v odpovědi u každé kandidátní entity sekce *_msg* s dodatečnými informacemi o procesu zjednoznačňování.

apriori_weight $\langle 0,1 \rangle$ Nastavuje apriorní váhu. Při hodnotě jedna není vůbec uvažován kontext a výsledek záleží pouze na apriorní pravděpodobnosti kandidátních entit pro danou frázi.

min_phrase_score $\{0,1,\ldots\}$ Entity s menším skóre pro danou frázi jsou zahozeny. Vhodnou hodnotu pro toto nastavení je potřeba empiricky určit buď na základě automatizovaných testů, nebo manuálně analýzou informací v odpovědích v sekci *_msg*.

min_context_score ($\mathbb{R}_0^+$) Entita s nižším kontextovým skóre pro danou frázi je zahozena. Vhodná hodnota se určuje podobnou metodou jako u *min_phrase_score* výše.

context_size $\{0,1,\ldots\}$ Udává velikost kontextu m_i^c, který se bere v potaz při zjednoznačňování fráze m_i. Počet je v tokenech, a to na každou stranu od fráze (pro hodnotu $context\_size = 50$ tak může platit $m_i^c \in \{0,\ldots,100\}$ dle pozice fráze v textu a velikosti textu). Hodnota nula značí neomezenou velikost kontextu.

dates (true/false) Nastavuje, zda mají být detekována kalendářní data.

corefs (true/false) Určuje, zda mají být detekovány koreference tvořené zájmeny a příslovci.

ookb_context (true/false) Povoluje aplikování *ookb* heuristiky pro určování *null* entit představené v podkapitole 3.2.

Formát odpovědi serveru je JSON následující struktury:

_errors Jedná se o možný seznam chyb.

_meta Obsahuje informace o verzi programu a jeho nastavení.

stats Obsahuje cesty k souborům se statistickými informacemi nutnými pro zjednoznačňování.

recognizer Popisuje cestu ke konečnému automatu pro modul *figa.*

request_settings Zobrazuje nastavení použitá při zpracovávání požadavku.

annotations Jedná se o výsledný seznam detekovaných pojmenovaných entit; každá anotace nese tyto informace:

aphrase Označuje frázi detekovanou v textu.

begin Označuje počáteční pozici detekované fráze v textu.

end Označuje koncovou pozici detekované fráze v textu.

entities Jde o seznam hodnot, které daná fráze může označovat (pokud je v požadavku specifikováno *keep_candidates: False,* pak seznam obsahuje pouze nejlepší zvolené řešení); u hodnot nalézáme tato pole:

type Specifikuje typ hodnoty – *NamedEntity* pro entitu, *Date* pro datum a *Coref* pro koreferenci.

score Označuje přiřazené skóre v rozsahu $\langle 0,1 \rangle$.

wikipedia Pro entitu uvádí odkaz na článek na Wikipedii, který entitu charakterizuje.

date Pro datum obsahuje hodnotu data; pozice dnů a měsíců může být nulová (např. pro text „in 2007“ je hodnota pole „2007-00-00“, protože informace o měsíci a dni nejsou k dispozici).

_msg Obsahuje volitelné informace (pokud požadavek obsahuje *append_msgs: true*) např. o apriorním skóre entity, kompatibilitě kontextu a o příspěvku slov ke kompatibilitě kontextu.

Uveďme nyní zkrácenou ukázku odpovědi serveru (plná ukázka odpovědi je v příloze D):

```
{
  "_errors": [],
  "_meta":{
    "git_tag":"v0.2",
    "global_settings":{
      "communication":{
        "bind":"ipc:///tmp/nerdp"
      },
      "recognizer":{
        "fsa_path":"nerd/local/results/automata.fsa"
      },
      "stats":{
        "phrases":"nerd/local/results/stats_fbkb_phrases.tsv",
        "tokens":"nerd/local/results/stats_fbkb_tokens.tsv"
      }
    },
    "request_settings":{
      "append_msgs":true,
      "apriori_weight":0.4,"context_size":50,"min_context_score":0,
      "corefs":true, "dates":true, "keep_candidates":true
    },
  },
```

```
23    "annotations":[
24      {
25        "aphrase":"Ford",
26        "begin":0, "end":4,
27        "entities":[
28          {
29              "name":"Ford Motor Company",
30              "score":0,
31              "type":"NamedEntity",
32              "wikipedia":"http://en.wikipedia.org/wiki/
                   Ford_Motor_Company"
33          },
34          {
35              "_msg": {
36                  "context_bow_score": {
37                      "USA": 0.0010147,
38                      "president": 0.00961624
39                  },
40                  "context_score": 0.00303708,
41                  "context_score_norm": 1,
42                  "phrase_score": 91,
43                  "phrase_score_norm": 0.0743464
44              },
45              "freebase": "/m/0c_md_",
46              "kb_id": 82322,
47              "name": "Gerald Ford",
48              "score": 0.629739,
49              "type": "NamedEntity",
50              "wikipedia": "http://en.wikipedia.org/wiki/Gerald_Ford"
51          }
52        ]
53      }
54    ]
55  }
```

3.4 Testovací prostředí

Testovací prostředí představené v článku [4] bohužel není vhodné pro naše účely. Umí vyhodnocovat pouze pojmenované entity zjednoznačněné pomocí Wikipedia URL a je velice pomalé kvůli častému dotazování na Wikipedia API. Autor této práce subjektivně odhadl úpravy tohoto frameworku psaného v jazyce Java za časově náročné a rozhodl se pro implementaci vlastního systému.

Testovací prostředí je implementováno v jazyce Python 2.7. Protože mnoho skriptů je určeno pouze jednomu specifickému účelu nebo není dostatečně zajímavých (skripty pro tvorbu statistik, pro čtení binárního formátu datové sady Wikilinks, ...), budeme se dále soustředit pouze na vybrané důležité části testovacího prostředí. Ty jsou zachyceny konceptuálním diagramem na obrázku 3.3. V něm můžeme číst následující části:

Corpus specifikuje rozhraní[3] pro testovací korpus. Toto rozhraní je pro každý korpus implementováno zvlášť z důvodu rozličných formátů, v jakých jsou korpusy uloženy.

[3] Rozhraní v jazyce Python bývají implementována pomocí tříd s abstraktními metodami.

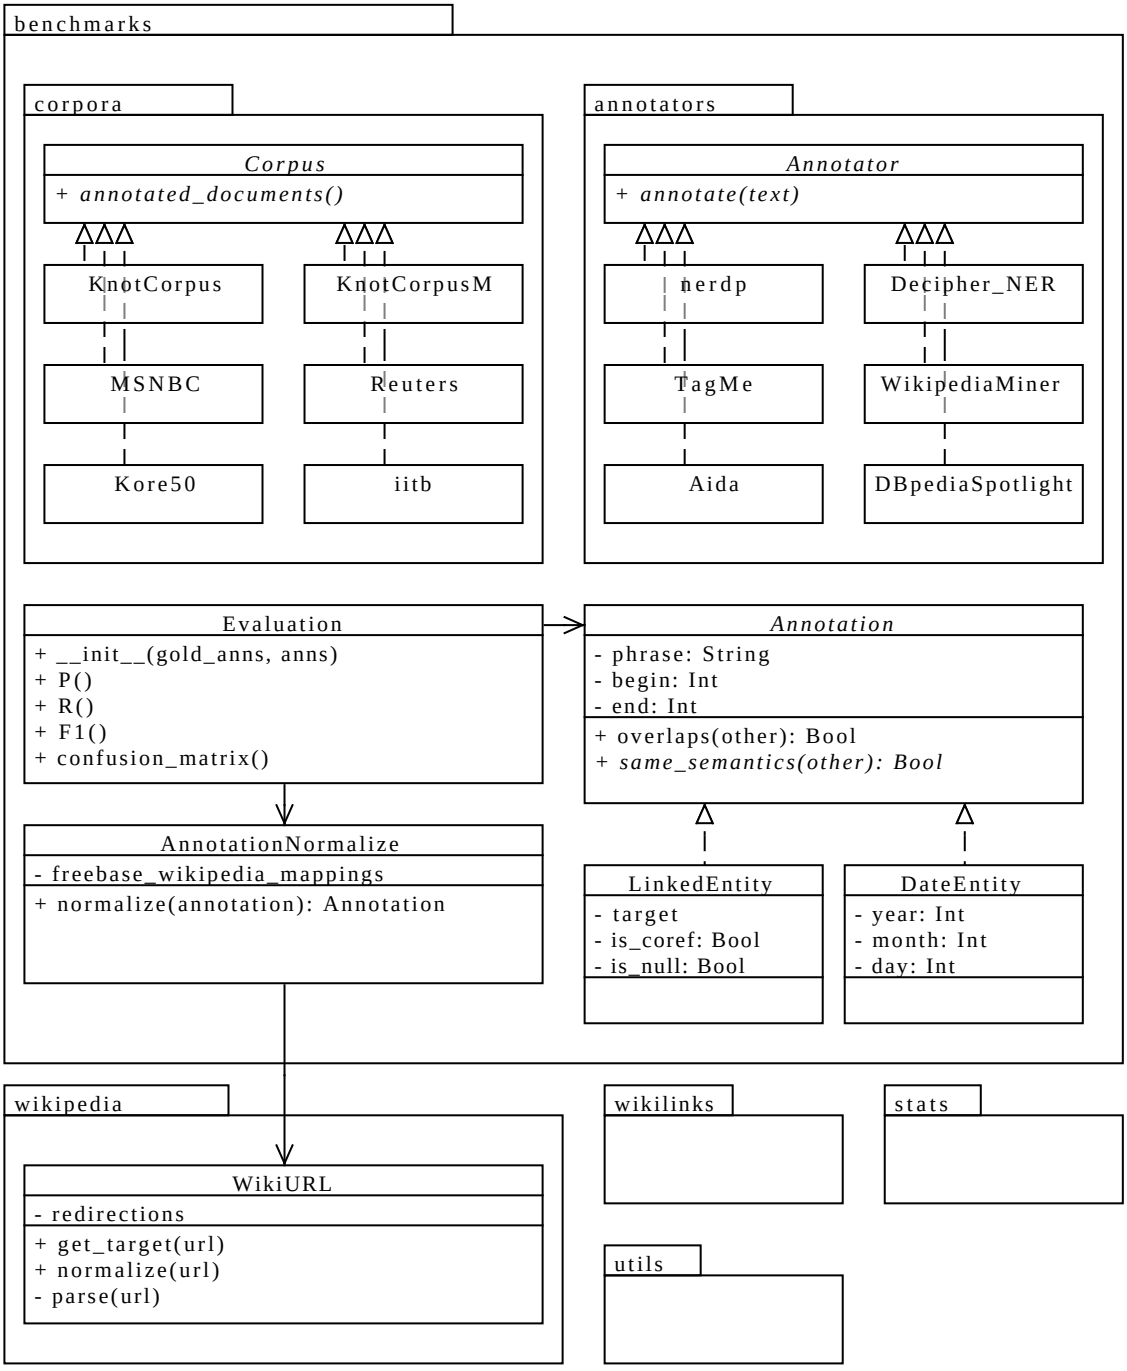

Obrázek 3.3: Konceptuální diagram balíčků a tříd testovacího prostředí

Annotator je rozhraním anotátoru. Každý anotátor musí implementovat metodu *annotate(text)*, která vrací seznam anotací *Annotation.*

Annotation představuje anotaci v textu. Ta nese vždy informace o frázi a jejím offsetu v textu. Třídní potomci nesou i hodnotové atributy – časový údaj nebo entitu. Třída *LinkedEntity,* představující zjednoznačněnou pojmenovanou entitu nebo koreferenci, může mít za cíl *target* např. Wikipedia URL, název článku na Wikipedii, Freebase identifikátor, DBpedia identifikátor apod. Cíle jsou různé, protože všechny korpusy a anotátory nepoužívají stejný identifikátor.

AnnotationNormalize je třída pro normalizaci anotací. Její odpovědností je normalizovat cíle anotací *LinkedEntity* na stejný typ hodnoty (Wikipedia URL). K tomu musí znát mapování mezi Wikipedia články a Freebase databází. Pomocí instance třídy *WikiURL* provádí i případné přesměrování (pokud cílem anotace je článek na Wikipedii, který je přesměrován na jiný článek, anotace je normalizována tak, aby používala cílovou stránku přesměrování).

WikiURL je třída pro pohodlnou práci s odkazy na Wikipedii. Zejména je schopna ověřit validitu odkazu, provést jeho konverzi na kanonickou formu a analyzovat jej. Analýzou je možné z odkazu získat jazyk článku, jeho název a typ (článek, diskuze k článku, stránka uživatele, ...).

Wikilinks, stats a utils jsou balíčky obsahující další málo významné třídy a skripty.

Výše uvedené třídy a balíčky jsou využívány skripty, které realizují konkrétní výstupy. Nejvýznamnějším je skript pro spuštění vybraných anotátorů nad vybranými datovými sadami, normalizaci jejich výstupů a uložení výstupů v podobě souborů v přehledné adresářové struktuře. Nad vytvořenými soubory je možno poté spustit skript pro výpočet všech skóre. Další skripty slouží k měření výkonnosti anotátorů, optimalizaci parametrů systému *nerdp,* výpočtu podobnosti systémů apod.

Testovací prostředí nyní demonstrujme na příkladu. Výpočet skóre F1 pro anotátor *nerdp* na prvním dokumentu testovací sady *MSNBC* vypadá v prostředí interaktivní konzole následovně:

```
>>> from benchmarks.corpora.msnbc import MSNBC
>>> from benchmarks.annotators.nerdp import Nerdp
>>> from benchmarks.evaluation import Evaluation
>>>
>>> annotator = Nerdp(options={"context_size" : 100})
>>>
>>> corpus = MSNBC()
>>> document = corpus.annotated_documents().next()
>>> (doc_name, text, gold_annotations) = document
>>>
>>> annotations = annotator.annotate(text)
>>> evaluation = Evaluation(gold_annotations,
...                         annotations,
...                         ignore_dates=True)
>>> print evaluation.F1()
0.0631578947368
```

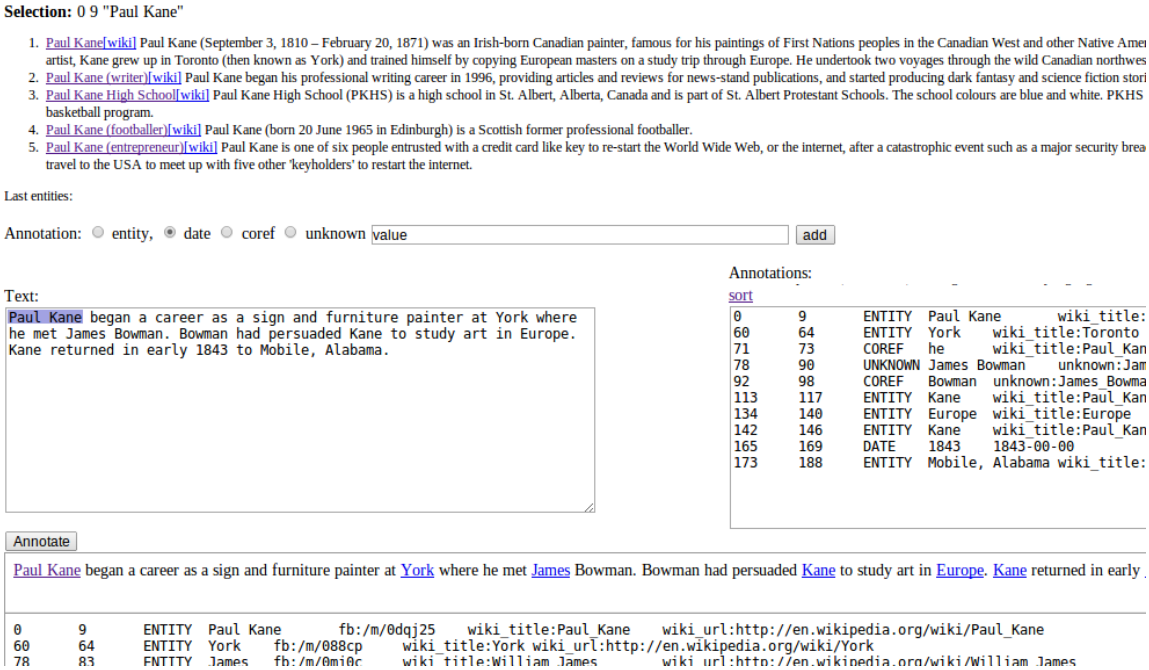

Obrázek 3.4: Editor *handy* pro usnadnění procesu anotování.

3.5 Podpůrné nástroje

Editor *handy* je jednoduchým editorem implementovaným jako HTML stránka s JavaScriptem, který usnadňuje anotování dat. Z obrázku 3.4 je patrné jeho spartánské rozhraní. Editor je dostupný na http://www.stud.fit.vutbr.cz/~xrylko00/KNOT/handy/.

Použití: Do textového pole *Text* se zadá anotovaný text, který je při anotování automaticky uzamknut a nelze již modifikovat (prevence nechtěného poškození textu a rozsynchronizování textu a offsetů). Samotná anotace probíhá tak, že je v textu zatržena fráze a vybrán správný druh anotace (*entity, date, coref* nebo *unknown* pro entitu *null*) a do políčka *value* je vložena správná hodnota. Po kliknutí na tlačítko *add* je vytvořena anotace a přidána do textového pole *Annotations,* které je možné ručně libovolně editovat a řadit tlačítkem *sort*; při kliknutí pravým tlačítkem myši na libovolnou anotaci je odpovídající fráze zatržena v textovém poli *Text.* Při ručním zatrhávání frází v poli *Text* se v horní části zobrazují návrhy entit získané z DBpedia Lookup API[4] – kliknutím na název entity se do pole *value* doplní vybraná entita, při kliknutí na odkaz *wiki* je otevřeno nové okno webového prohlížeče s článkem na Wikipedii o vybrané entitě. Při zatrhávání frází v textu editor heuristicky upraví hranice výběru – zejména odstraní mezery na okrajích výběru (toto opět usnadňuje používání a předchází chybám z únavy). Samotný seznam výsledných anotací v poli *Annotations* nelze uložit pomocí editoru – je nutno jej ručně zkopírovat a uložit poté do souboru.

Ilustrační vlastnost editoru: Po kliknutí na tlačítko *Annotate* se dole zobrazí Wikifikovaný text nástrojem *nerdp* a pod ním samotné anotace (z důvodu jednoduchosti je toto implementováno pomocí vloženého *iframe* s textem jako parametrem v adrese URL). Editor byl testován v prohlížeči Chrome.

[4] Více informací na http://wiki.dbpedia.org/lookup/

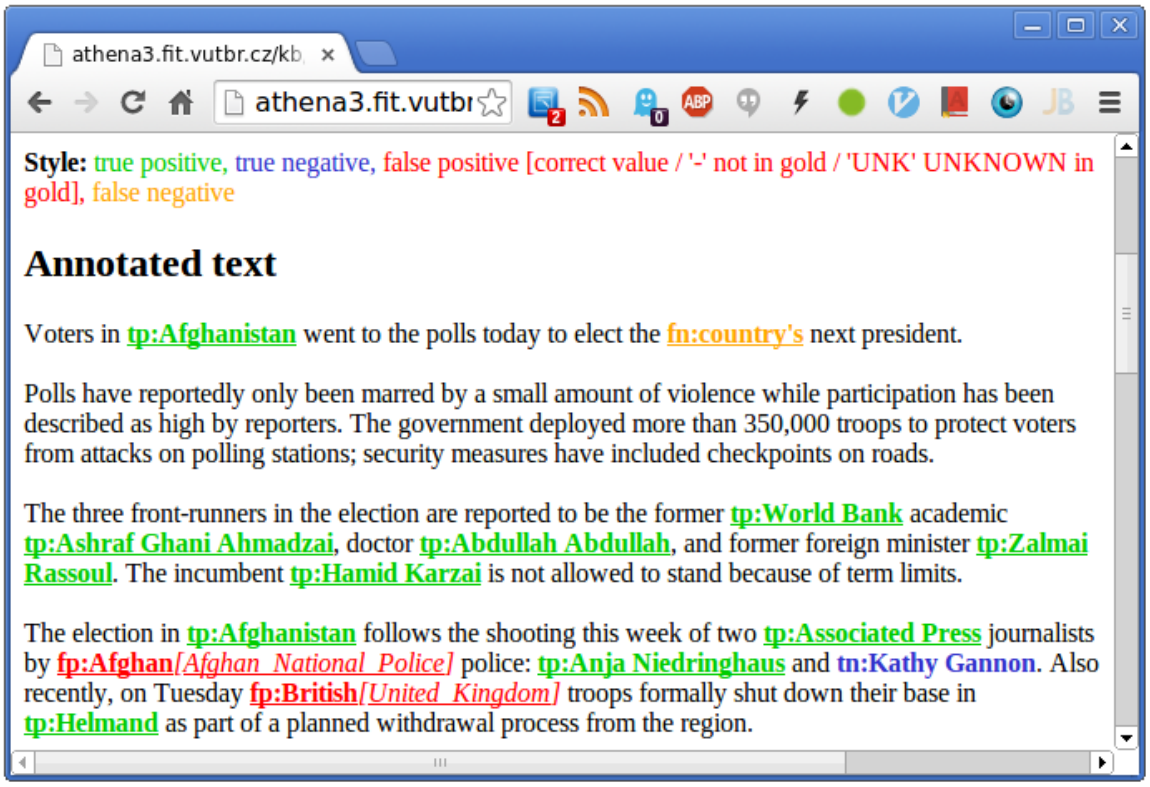

Obrázek 3.5: Vizualizace anotací

Vizualizace anotací je důležitá pro pohodlné sledování výsledků testů, které je nedílnou a časově náročnou činností při vývoji, zlepšování a porovnávání systémů NED. Vizualizace anotací na testovacích datech je implementována pomocí kolekce skriptů v jazyce Python a Bash. Výstupem je kolekce html dokumentů se zvýrazněnými správně i chybně určenými pojmenovanými entitami; vzhled je ilustrován obrázkem 3.5. Testovací datové sady anotované systémy nerdp, Decipher NER, Aida, DBpedia Spotlight, TagMe a WikipediaMiner jsou dostupné na http://athena3.fit.vutbr.cz/kb/ner_results/.

Rozhraní pro *nerdp* v jazyce Python umožňuje pohodlně využívat služeb běžícího serveru *nerdp* z jazyka Python. V požadavcích je možno specifikovat všechny atributy zjednoznačňování. Rozhraní vytvoří korektní požadavek pro server a umožňuje transformaci JSON odpovědi serveru na seznam anotací.

Ostatní skripty slouží zejména k tvorbě statistik nad datovými sadami, transformacím dat a podobně. Většina pomocných skriptů je implementována v jazyce Python. Snazší transformace a statistiky jsou prováděny pomocí Bash skriptů a standardních unixových nástrojů (sort, sed, awk, grep, cut, join, ...). Závislosti mezi datovými soubory jsou zachyceny v zdrojových kódech a v případě složitějších závislostí pomocí Makefile souboru, který umožňuje i velice efektivní aktualizaci souborů.

Kapitola 4

Experimenty a testování

V této kapitole jsou popsány experimenty, které mají za cíl prozkoumat vlastnosti vyvinutého anotátoru *nerdp* a ověřit splnění požadavků na něj kladených. Prvně jsou popsány znalostní báze, které jsou systémem *nerdp* podporovány. Dále „trénovací“ data, ze kterých systém vytváří statistiky potřebné pro svou činnost. Následuje popis testovacích dat, pomocí kterých se vyhodnocuje správnost systémů. V podkapitole 4.4 jsou zkoumány parametry implementovaného systému a jejich vliv na jeho celkovou úspěšnost. Konečně v podkapitole 4.5 jsou srovnány vybrané systémy, a to co do jejich přesnosti, úplnosti, správnosti, výkonnosti a podobnosti. Následuje krátké představení soutěže, do které je implementovaný anotátor zapojen. Kapitola končí zkoumáním časové a prostorové složitosti implementace.

4.1 Znalostní báze

Znalostní báze determinuje, které entity bude systém schopen rozpoznávat a jaké údaje o těchto entitách bude mít k dispozici. Lze použít dvě znalostní báze: *Decipher KB,* která obsahuje asi dva miliony entit rozpoznatelných systémem, včetně dodatečných informací o těchto entitách, a *ERD 2014 KB,* která byla vytvořena dle specifikace soutěže ERD 2014 a obsahuje na 2,35 milionu entit z Wikipedia a Freebase identifikátory bez dodatečných informací. Protože znalostní báze *Decipher KB* obsahuje dodatečné informace o entitách, systém s ní umí řešit koreference zájmen a příslovcí. V experimentech níže je použita znalostní báze *ERD 2014 KB,* protože tento druh koreferencí není potřeba pro srovnání se systémy, které jej neřeší.

4.2 Trénovací data

Pro úlohu řešenou statistickými metodami jsou vhodná data důležitým faktorem úspěchu. Data můžeme rozlišit na neanotovaná data pro výkonnostní testování systému a manuální zkoumání jeho výstupů, dále na data ručně anotovaná sloužící jako zlatý standard pro vyhodnocení správnosti systému a nakonec data získaná automatickým způsobem, která začínají být v poslední době populární pro nízké náklady na jejich pořízení a jež slouží jak k trénování, tak vyhodnocování systému na velkých datech. Bohužel se při bližším manuálním zkoumání často ukazuje, že takto automaticky pořízená data jsou v praxi nepoužitelná – což ovšem náklady na zajištění odpovídající kvality těchto dat navyšuje.

4.2.1 Wikilinks

Datová sada Wikilinks [26] obsahuje 9,5 milionů webových stránek s téměř 3 miliony entit a 40 miliony instancí. Datová sada byla vytvořena stažením webových stránek obsahujících odkaz na Wikipedii. Stažené webové stránky nejsou stránkami Wikipedie, čímž se liší od dřívějších podobných datových sad běžně používaných pro trénování NED systémů [18, 14]. Pojmenovanou entitou je chápán text odkazu a entitou označovanou touto frází je odkaz na Wikipedii. Pro ilustraci, v odkazu *prezident České republiky* je pojmenovanou entitou text *prezident České republiky,* který identifikuje entitu *http://cs.wikipedia.org/wiki/Miloš_Zeman* – tedy jednoznačně odkazuje na konkrétní osobu „Miloše Zemana". Datová sada obsahuje pouze takové pojmenované entity, které se podobají (mají společné alespoň jedno slovo) názvu označované entity (nebo názvu jejího přesměrování).

Datová sada je v binárním formátu a vyžaduje ke čtení použití frameworku Apache Thrift[1], který umožňuje přenositelnost datové sady a její zpracování ve všech běžně dostupných programovacích jazycích (včetně jazyků Python, Java a Scala).

Provedené úpravy. Na datové sadě byla provedena normalizace odkazů. Byly odstraněny odkazy, které nesměřují na existující článek na anglické Wikipedii a v případě potřeby bylo provedeno přesměrování. Tímto postupem bylo značně sníženo množství unikátních entit (na 55 % původního množství), avšak množství pojmenovaných entit se snížilo nepatrně (pouze o 2,3 %), protože odstraněné entity nebyly používány často nebo se jednalo pouze o přesměrování.

Statistiky. Na tomto místě podáme vysvětlení statistik zanesených v tabulce 4.1.

V datové sadě Wikilinks je jednoznačných 94,87 % ze všech unikátních pojmenovaných entit; ty však tvoří *pouze* 57,11 % výskytů pojmenovaných entit v textu (zřejmě proto, že se jedná o specifické fráze, neobvyklé fráze nebo vyznačené celé věty, popř. výrazy s chybou, např: *2 billion tons of iron ore* nebo *Wikipedia on the the history and nature of conservative support for Obama in 2008*). Příkladem běžně se vyskytujících víceznačných pojmenovaných entit jsou *Monte Carlo* (metoda, město, film z roku 2011, model automobilu Chevrolet), *English* (jazyk, angličané, v amerických textech Američané s britskými kořeny, ...), *Greek* (jazyk, antické období řeckých dějin, ...), *Bush* (George W. Bush, George H. W. Bush, populární kapela), *Latex* (tekutina, nesprávně psaný LaTeX) apod.

Nejednoznačné pojmenované entity s dominantním významem v textech převažují. Pojmenovaná entita má dominantní význam, pokud jej označuje alespoň v 90 % svých výskytů. Pokud dominantní význam není přítomen, klesá úspěšnost zjednoznačňování na základě apriorní pravděpodobnosti (přiřazováním nejčastějšího významu).

Případy, kdy neplatí *one sense per discourse* (termín je definován v 2.2), a je tedy jednou pojmenovanou entitou v textu identifikováno více různých entit na různých místech textu, nastávají zřídka. Příkladem je slovo *Greek, které* v jednom dokumentu označuje jak etnikum *Greeks,* tak i na dalším místě dokumentu jazyk *Greek language.* Nejčastěji se však jedná o sémanticky velmi podobné entity (např. *Basketball* vs. *College basketball, Chicken* vs. *Chicken (food)* apod).

[1] http://thrift.apache.org/

počet	popis
2 933 659	unikátních entit
40 323 863	výskytů označkovaných pojmenovaných entit v textu
4 643 105	unikátních výskytů pojmenovaných entit
1,3 TB	velikost datové sady na disku

(a) Původní datová sada

počet	popis
1 623 341	unikátních entit
39 391 408	výskytů označkovaných výrazů v textu
4 310 036	unikátních výrazů
16 893 983	výskytů nejednoznačných slovních výrazů
221 232	unikátních nejednoznačných slovních výrazů
6 321 483	výskytů nejednoznačných slovních výrazů bez dominantního významu
167 073	unikátních nejednoznačných slovních výrazů bez dominantního významu
71 312	dvojic unikátní výraz-dokument porušujících *one sense per discourse*

(b) Normalizovaná datová sada

Tabulka 4.1: Statistiky datové sady Wikilinks [26]

4.2.2 ClueWeb12 a FACC1

ClueWeb12[2] je kolekcí 733 019 372 textových dokumentů stažených z internetu (o velikosti 27 TB v nekomprimované podobě). Datová sada FACC1[3] [9] je poté sada značek ke ClueWeb12 vytvořená automaticky s cílem vysoké přesnosti (odhadovaná míra přesnosti je 80-85 % a úplnosti 70-85 %). Sada FACC1 identifikuje přes 6 miliard pojmenovaných entit ve více než 647 milionech dokumentů (každý dokument tedy obsahuje průměrně 13 pojmenovaných entit). Cílové entity jsou reprezentovány identifikátory báze znalostí Freebase [2].

4.3 Testovací data

Pojetí pojmenovaných entit se u jednotlivých datových sad liší, a je tedy nutné pro správnou interpretaci výsledků datové sady popsat podrobněji a uvést reprezentativní příklady. Stručný přehled korpusů je v tabulce 4.2. *Enamex* anotace jsou anotace označující ne-*null* entity pomocí jmen (ostatní anotace jsou tedy anotace označující *null* entitu, datum nebo koreferenci pomocí zájmen, příslovcí apod.). Důvodem pro toto rozlišení je, že většina systémů nepodporuje označování dat, zájmenných koreferencí apod., a proto je z důvodu srovnatelnosti výsledků nutné provádět experimenty na *enamex* anotacích.

Formát níže uváděných ukázek je následující: podtržená je fráze, následovaná označovaným údajem v závorkách sázeným *italikou*. Fráze, která by systémem neměla být označena (nebo by měla být označena entitou *null*) je označena otazníkem v závorkách *(?)*. Koreference je odlišena značkou *coref*. Např. ve větě „Alexander *(Alexander_the_Great)* was tutored by the philosopher Aristotle *(Aristotle)* until the age of 16.“ slovo „Alexander“ označuje článek na Wikipedii s identifikátorem Alexander_the_Great umístěným na adrese http://en.wikipedia.org/wiki/Alexander_the_Great. Koreference na frázi, která označuje

[2] http://lemurproject.org/clueweb12/
[3] http://lemurproject.org/clueweb12/FACC1/ a
http://googleresearch.blogspot.cz/2013/07/11-billion-clues-in-800-million.html

korpus	doku-mentů	slov	slov / dokument	anotací	*enamex* anotací	anotací / dokument	anotací / 100 slov
iitb	104	66 520	639,6	18 304	11 059	176,0	27,5
KnotCorpus	89	15 073	169,4	1 751	1 269	19,7	11,6
KnotCorpusM	4	10 577	2644,2	1 281	776	320,2	12,1
NewsGold	500	15 501	31,0	999	523	2,0	6,4
Reuters	128	15 842	123,8	880	880	6,9	5,6
MSNBC	20	10 877	543,9	747	747	37,4	6,9
AQUAINT	50	11 024	220,5	727	727	14,5	6,6
dbpedia-spot.	10	1 661	166,1	325	325	32,5	19,6
Kore50	49	706	14,4	147	143	3,0	20,8
průměr	106	16 420,	505,8	2 795	1 827	68,0	13,0

Tabulka 4.2: Přehled testovacích datových sad (seřazeno dle počtu anotací)

entitu *null,* je spárována pomocí *id* unikátního v rámci dokumentu (pouze v datové sadě KnotCorpus). V případě, že se jedná o jinou entitu než Wikipedia, je zobrazena formátem identifikátor=hodnota, např. *ulan_id=694*. Je nutné upozornit, že Wikipedia je dynamický projekt a níže uvedené identifikátory mohou být zastaralé – smazané nebo přesměrované – a jisté anotace tak v současnosti nemusí odpovídat původně zamýšleným.

4.3.1 iitb

Datová sada iitb (nebo IITB), zveřejněná v článku [15], je kolekcí ručně anotovaných dokumentů z různých populárních webů na téma sport, zábava, věda a technologie a zdraví. Datová sada byla vytvářena tak, že texty byly automaticky anotovány a šest výzkumníků poté vybíralo správnou z navržených kandidátních entit (v průměru každá fráze označuje 5,3 kandidátních entit). Důraz byl kladen i na označování *null* entit (asi 40 %) a na maximální možnou hustotu anotací (patrno i z tab. 4.2 – sada iitb má nejvyšší hustotu – sloupec *anotací / 100 slov*).

Ukázka When Richard Garriott *(Richard Garriott)* blasts off into space on October 12 *(?)*, he will become the world *(World)*'s first second-generation *(Generation)* astronaut *(Astronaut)*, following *(?)* in the spacewalking *(?)* footsteps *(?)* of his father, NASA *(NASA)* pioneer Owen Garriott *(Owen K. Garriott)*...

4.3.2 KnotCorpus

Jedná se o korpus vytvořený v rámci této práce. Obsahuje ručně anotované části článků rozličných témat z Wikipedie, Wikinews a zprávy z Twitteru za pomocí nástroje *handy.* Cílem korpusu je pestrost co do témat, délky textů a hustoty anotací – díky tomu je korpus obzvláště vhodný k manuálnímu zkoumání výstupu anotátorů. Obsahuje explicitní anotace entity *null*, koreference pomocí zájmen a příslovcí a jako jediný korpus i anotace kalendářních dat. Většina dokumentů neobsahuje anotace běžných podstatných jmen (srov. s opačným přístupem u iitb (4.3.1) a u dbpedia-spotlight-nif (4.3.7)).

Ukázka běžného dokumentu Nobel *(Alfred_Nobel)* travelled for much of his *(coref Alfred_Nobel)* business life, maintaining companies in various countries in Europe *(Europe)*

and North America *(North_ America)* and keeping a permanent home in Paris *(Paris)* from 1873 *(1873-00-00)* to 1891 *(1891-00-00)*. He *(coref Alfred_ Nobel)* remained a solitary character, given to periods of depression. Though Nobel *(Alfred_ Nobel)* remained unmarried, his *(coref Alfred_ Nobel)* biographers note that he *(coref Alfred_ Nobel)* had at least three loves. Nobel's *(coref Alfred_ Nobel)* first love was in Russia *(Russia)* with a girl named Alexandra *(? id=1)*, who *(coref id=1)* rejected his *(coref Alfred_ Nobel)* proposal...

Ukázka zprávy z Twitteru Venezuela *(Venezuela)*: Arrest of local mayor signals potential "witch hunt" | Amnesty International *(Amnesty_ International)* http://ow.ly/uOqWW

4.3.3 KnotCorpusM

Jedná se o interní korpus výzkumné skupiny z FIT VUT. Obsahuje pouze několik dokumentů, které jsou konkatenací kratších textů, zejména z kulturní oblasti. Obsahuje explicitní anotace pro entitu *null* a koreference pomocí zájmen a přísloví. Korpus byl ručně anotován jedním výzkumníkem.

Ukázka Claude *(Claude_ Monet)*'s landscapes are never records of actual places; rather they are idealised memories of the golden age of antiquity *(Classical_ antiquity)*, like this episode from Ovid *(Ovid)*'s Metamorphoses *(Metamorphoses)*, which *(coref Metamorphoses)* he *(coref Claude_ Monet)* imbues with a romantic and nostalgic spirit of the antique world...

4.3.4 NewsGold

Data NewsGold tvoří společně s datovou sadou Reuters datovou kolekci *N^3 collection*[4] prezentovanou v článku [25] (součástí kolekce je i datová sada článků v němčině, kterou vynecháváme; původní název datové sady je RSS-500). V článku jsou tyto datové sady porovnávány se sadami Kore50 a dbpedia-spotlight-nif.

Korpus je vytvořen na základě RSS zdrojů hlavních světových zpravodajských serverů a je tvořen dokumenty zaměřenými na různá témata, které byly náhodně vzorkovány a vybrané věty byly ručně anotovány jedním výzkumníkem. Věty byly zvoleny tak, aby obsahovaly relace typu „..., who was born in ...". Počet anotací, jak vidno v ukázce, je poněkud nižší a soustředí se především na jména.

Ukázka The U.S. Patent Office allows genes to be patented as soon as someone isolates the DNA by removing it from the cell , says ACLU *(American_ Civil_ Liberties_ Union)* attorney Sandra Park *(?)*.

4.3.5 Reuters

Korpus Reuters (původně Reuters-128) byl vytvořen v rámci kolekce N^3 popsané výše v kapitole 4.3.4. Pojmenované entity byly v dokumentech detekovány automaticky a poté byly zjednoznačňovány dvěma výzkumníky. Shoda výzkumníků byla pouhých 74 %, což naznačuje obtížnost úlohy. Po prvotní neshodě výzkumníků však často došlo při dalším prozkoumání problému k následné shodě.

[4] Data lze stáhnout z https://github.com/AKSW/n3-collection

Ukázka Paxar Corp *(Avery_ Dennison)* said it has acquired Thermo-Prin GmbH *(?)* of Lohn *(?)*, West Germany *(West_ Germany)*, a distributor of Paxar *(Avery_ Dennison)* products, for undisclosed terms.

4.3.6 MSNBC

Datová sada MSNBC představená v článku [5] byla vytvořena stažením zpravodajských článků z msnbc.com v kategoriích byznys, U.S. politika, zábava, zdraví, sport, technika a věda, cestování, TV zprávy, U.S. zprávy a světové zprávy.

Ukázka Home Depot *(Home_ Depot)* CEO Nardelli *(Robert_ Nardelli)* quits Home-improvement retailer's chief executive had been criticized over pay.

ATLANTA *(Atlanta,_ Georgia)* - Bob Nardelli *(Robert_ Nardelli)* abruptly resigned Wednesday as chairman and chief executive of The Home Depot Inc.*(Home_ Depot)* after a six-year tenure that saw the world's largest home improvement store chain post big profits but left investors disheartened by poor stock performance...

4.3.7 dbpedia-spotlight-nif

Datová sada *dbpedia-spotlight-nif*[5] byla použita při testování systému DBpedia Spotlight v článku [18]. V závislosti na konfiguraci by měl tento nástroj dosahovat skóre F1 od 45,2 % do 56,0 %, což je v souladu s výsledky experimentů prezentovaných v tabulce 4.3g. Z dat je zřejmé, že se sada snaží o vysokou hustotu anotací.

Ukázka To the rites *(Ritual)* of middle age *(Middle_ age)* passage, some families *(Family)* are adding another: buying marijuana *(Cannabis_ (drug))* for aging parents *(Parent)*. Bryan, 46, a writer *(Writer)* who lives in Illinois *(Illinois)*, began supplying *(Illegal_ drug_ trade)* his parents *(Parent)* about five years *(Year)* ago, after he told them about his own marijuana *(Cannabis_ (drug))* use. When he was growing up, he said, his parents *(Parent)* were very strict about illegal drugs *(Illegal_ drug_ trade)*...

4.3.8 AQUAINT

Jedná se o podmnožinu padesáti dokumentů z datové sady *AQUAINT korpus*[6] – kolekce novinových článků New York Times, Xinhua News Service a Associated Press. Datová sada AQUAINT[7] obsahuje vybrané dokumenty délky 250-300 slov, které byly ručně anotovány. Datová sada je představena v článku [21]. Z ukázky je zřejmá vyšší hustota anotací.

Ukázka THAILAND

MORE and more people are dying or suffering from fatal diseases such as brain tumours *(Brain_ tumor)* , mammarian or breast cancer *(breast_ cancer)* and brain haemorrhage *(Bleeding)* due to a lack of proper medical care. However, things may change as the Srisiam Hospital in Bangkok *(Bangkok)* has now established the first ever Radio Surgery *(Radiosurgery)* Institute in Thailand *(Thailand)* – (there are presently more than 100 radio surgery centres around the world)...

[5] Ve variantě dostupné z http://yovisto.com/labs/ner-benchmarks/
[6] Celý AQUAINT korpus je dostupný za 300 dolarů z http://catalog.ldc.upenn.edu/LDC2002T31
[7] Staženo z http://cogcomp.cs.illinois.edu/page/resource_view/4

4.3.9 Kore50

Sada Kore50[8] představená v článku [13] sestává z padesáti (z technických důvodů je v této práci používáno 49) dokumentů-vět, které byly ručně anotovány. Věty tematicky zaměřené na svět celebrit, hudby, podnikání, sportu a politiky byly vybrány tak, aby byly krátké a náročné na zjednoznačňování, aby obsahovaly málo významné entity (dle analýzy odkazů na Wikipedii) a silně víceznačné fráze (dle původního článku fráze v průměru odpovídají 631 kandidátním entitám). Často se vyskytují osoby označované pouze křestním jménem a osobnosti mimo svou domovinu málo. Autoři v článku dosahují přesnosti $P = 62{,}6$.

Ukázka David *(David_Beckham)* and Victoria *(Victoria_Beckham)* named their children Brooklyn *(?)* , Romeo *(?)* , Cruz *(?)* , and Harper Seven *(?)* .

4.4 Určení optimálních parametrů

Určení apriorní váhy A. Protože ve výpočtu výsledného skóre entity a fráze figuruje apriorní váha A, která udává, nakolik má být systém citlivý ke kontextu a nakolik k apriorním pravděpodobnostem entit, je nutné ji vhodně určit. Na testovacích datových sadách byla jako nejvhodnější empiricky určena apriorní váha $A = 0{,}5$, jak vidno v obrázku 4.1a.

Určení velikosti kontextu. Velikost kontextu m_i^c, který se bere v úvahu při zjednoznačňování fráze m_i, ovlivňuje výsledné skóre F1. Protože v praxi převážně platí hypotéza o jednom významu fráze m_i v rámci jednoho dokumentu, jako nejvhodnější byla empiricky určena neomezená velikost kontextu, jak je patrné z obrázku 4.1b.

Heuristika *ookb*. Heuristika *ookb* popsaná v podkapitole 3.2 zvyšuje přesnost z 0,298 na 0,433 a současně snižuje úplnost z 0,470 na 0,321. To znamená, že tato heuristika zvyšuje celkové skóre F1 na všech datových sadách z 0,310 na 0,331.

4.5 Experimenty

Na testovacích datových sadách popsaných v podkapitole 4.3 byly provedeny experimenty za pomoci nástrojů představených v podkapitole 2.5. Způsob vyhodnocování experimentů je popsán v podkapitole 2.4. Není-li uvedeno jinak, byla počítána skóre prvně pro každý dokument korpusu a poté byla tato skóre zprůměrována ve výsledné skóre korpusu. Tento postup byl zvolen, protože většina korpusů je konzistentních v délce dokumentů (výjimku tvoří KnotCorpus) a také protože je v literatuře běžnější.

Všechny systémy byly dotazovány s jejich výchozími parametry. Systém *nerdp* používá statistiky získané z normalizované datové sady Wikilinks, znalostní bázi *ERD 2014 KB* a *optimální* parametry dle podkapitoly 4.4 – neomezenou velikost kontextu, apriorní váhu 0,5 a heuristiku *ookb*.

Experimenty byly prováděny na serverech FIT s výbornou internetovou konektivitou. Vyhodnocení probíhalo na serveru *athena3,* na kterém běžel i systém *nerdp*. Systém Decipher NER běžící na *knot09* byl dotazován přes REST API. Systém Aida běžel na serveru *knot07,* kde spotřebovával asi 8 GiB paměti ve stavu po experimentu a dalších 13 GiB využívala přidružená databáze PostgreSQL (velikost databáze používané systémem Aida je

[8] Dostupné z http://www.mpi-inf.mpg.de/yago-naga/aida/downloads.html

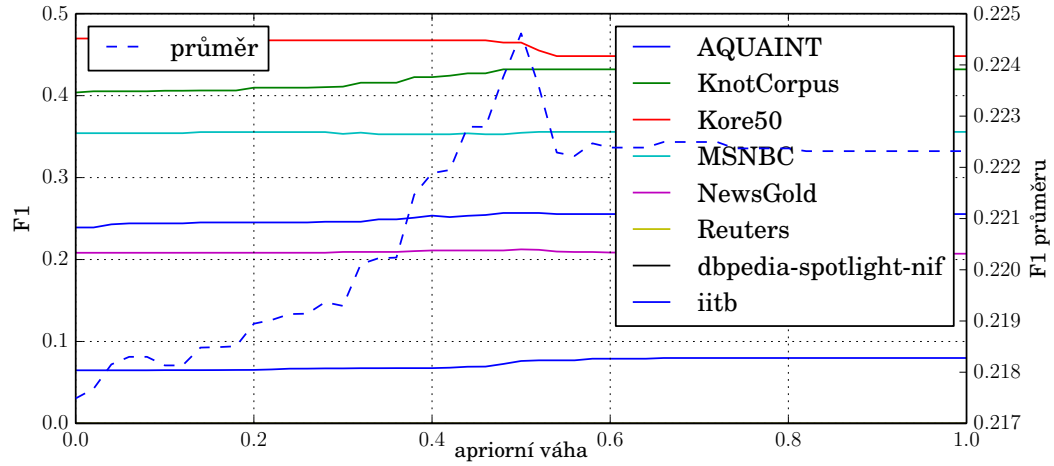

(a) Vliv apriorní váhy A na skóre F1 (při neomezené velikosti kontextu).

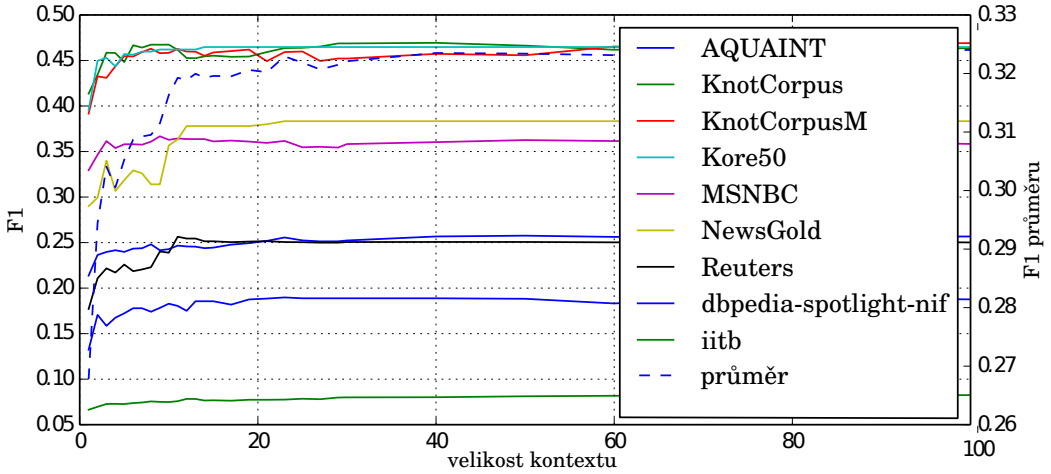

(b) Vliv velikosti kontextu na skóre F1 (při apriorní váze $A = 0{,}5$)

Obrázek 4.1: Vliv parametrů na skóre F1

95 GiB). Ostatní systémy byly dotazovány jako webové služby – to je nutno vzít v úvahu při interpretaci výsledků.

4.5.1 Správnost

Byla zkoumána přesnost, úplnost a skóre F1. Výsledky experimentů jsou v tabulkách 4.3 a 4.4. Celkově nejvyšší přesnosti dosahuje systém Aida, nejvyšší úplnosti TagMe a WikipediaMiner. Skóre F1 je nejvyšší u systému TagMe. Z šesti zkoumaných systémů má systém *nerdp* druhou nejvyšší přesnost, nejhorší úplnost a čtvrté nejvyšší skóre F1.

4.5.2 Výkonnost

Informace o výkonnosti jednotlivých systémů jsou zaneseny v tabulkách 4.5. Anotátory, které v tabulce chybí, byly pro měření příliš pomalé. Dokumenty pro vyhodnocení výkonnosti jsou náhodně vybrané články z anglické Wikipedie ve formě čistého textu (bez html značek).

Sada grafů 4.2 zachycuje závislost doby zpracování požadavku na počtu zjednoznačněných pojmenovaných entit ve vstupním textu. Metodika měření je následující: z datové sady Wikilinks jsou načtena čistá textová data dostatečné velikosti, z nichž je poté vybranému anotátoru iterativně zasílán postupně stále větší úsek k anotování, a to počínaje jedním slovem. Všechny anotátory byly spuštěny nad stejným textem, experiment byl však ukončen u různých anotátorů v různou dobu. Z grafů vyplývá lineární složitost většiny systémů; pouze Aida se zdá mít horší a TagMe mírně lepší složitost.

4.5.3 Podobnost

Podobnosti jednotlivých systémů jsou zaneseny v tabulce 4.6. Způsob výpočtu podobnosti dvou systémů je popsán v podkapitole 2.4. Hodnoty v tabulce byly vypočteny jako průměrné podobnosti systémů pro všechny dokumenty ze všech datových sad. Z tabulky je patrné, že skupinu podobných systémů tvoří WikipediaMiner, DBpediaSpotlight a TagMe. To je pochopitelné, protože všechny tři systémy se snaží produkovat maximální množství anotací, kdežto ostatní systémy se soustředí spíše na vlastní jména. Abychom vizualizovali podobnosti systémů, použijeme *Principal Coordinates Analysis (PCoA)*, která slouží ke snížení dimenze a následné vizualizaci matice podobností. Její výstup je znázorněn na obrázku 4.3, ze kterého je již dobře patrné, které systémy jsou si podobné.

4.6 Soutěž ERD 2014

Entity Recognition and Disambiguation Challenge (ERD 2014)[9] je soutěž pořádaná v rámci konference ACM SIGIR 2014. Organizátory jsou Microsoft Research, Google a Yahoo! Lab.

Úkolem *(long track)* soutěžících je vystavět REST API, které na textový požadavek odpoví seznamem nalezených a zjednoznačněných pojmenovaných entit v předepsaném formátu. Text požadavku je kódován v UTF-8 a offsety používané v odpovědi musí být v bytech. (Druhý úkol, *short track*, který není předmětem této práce, se zabývá interpretací dotazů ve vyhledávačích.)

Průběžné očekávané F1 skóre je počítáno na základě shody s datovou sadou FACC1 a je zobrazeno v tabulce 4.7. Finální F1 skóre bude počítáno na ručně anotovaných datech datové sady ClueWeb po uzavření soutěže dne 10. 6. 2014 a zveřejněno bude 20. 6. 2014.

[9] Web soutěže ERD 2014 je http://web-ngram.research.microsoft.com/erd2014/

Anotátor	P	R	F1
Aida	*0,397*	0,207	0,258
DBpediaSpotlight	0,150	0,727	0,243
Decipher_NER	0,292	0,342	0,285
TagMe	0,263	0,839	*0,392*
WikipediaMiner	0,228	*0,913*	0,359
nerdp	0,278	0,280	0,262

(a) AQUAINT

Anotátor	P	R	F1
Aida	*0,645*	0,592	*0,584*
DBpediaSpotlight	0,180	0,688	0,273
Decipher NER	0,538	0,503	0,487
TagMe	0,317	0,793	0,422
WikipediaMiner	0,268	*0,811*	0,377
nerdp	0,552	0,432	0,467

(b) KnotCorpus

Anotátor	P	R	F1
Aida			
DBpediaSpotlight	0,250	0,515	0,330
Decipher NER	*0,676*	*0,838*	*0,742*
TagMe	0,333	0,727	0,448
WikipediaMiner	0,298	0,771	0,428
nerdp	0,547	0,384	0,450

(c) KnotCorpusM

Anotátor	P	R	F1
Aida	*0,602*	0,633	*0,585*
DBpediaSpotlight	0,219	0,529	0,293
Decipher NER	0,112	0,121	0,103
TagMe	0,423	*0,711*	0,507
WikipediaMiner	0,303	0,441	0,333
nerdp	0,556	0,456	0,472

(d) Kore50

Anotátor	P	R	F1
Aida			
DBpediaSpotlight	0,184	0,662	0,280
Decipher NER	0,419	0,469	0,428
TagMe	0,280	*0,785*	0,388
WikipediaMiner	0,229	0,753	0,331
nerdp	*0,467*	0,482	*0,463*

(e) MSNBC

Anotátor	P	R	F1
Aida	*0,277*	0,487	*0,328*
DBpediaSpotlight	0,074	0,395	0,118
Decipher NER	0,156	0,262	0,174
TagMe	0,182	*0,553*	0,256
WikipediaMiner	0,132	0,491	0,197
nerdp	0,198	0,290	0,216

(f) NewsGold

Anotátor	P	R	F1
Aida	0,503	0,117	0,182
DBpediaSpotlight	0,383	0,757	0,507
Decipher NER	0,485	0,122	0,187
TagMe	0,547	0,491	0,507
WikipediaMiner	0,521	0,585	0,544
nerdp	0,564	0,116	0,185

(g) dbpedia-spotlight-nif

Anotátor	P	R	F1
Aida	0,417	0,312	0,357
DBpediaSpotlight	0,442	0,548	0,454
Decipher NER	0,337	0,119	0,160
TagMe	0,437	0,509	0,462
WikipediaMiner	*0,458*	*0,615*	*0,518*
nerdp	0,416	0,127	0,180

(h) iitb

Anotátor	P	R	F1
Aida	*0,346*	0,389	*0,347*
DBpediaSpotlight	0,064	0,558	0,110
Decipher NER	0,163	0,239	0,179
TagMe	0,131	0,575	0,203
WikipediaMiner	0,134	*0,617*	0,208
nerdp	0,315	0,318	0,281

(i) Reuters

Tabulka 4.3: Výsledky anotátorů na různých datových sadách (kalendářní data, zájmena a příslovce místa jsou ignorována)

Anotátor	P	R	F1	
Aida	*0,336*	0,482	*0,362*	12,27
DBpediaSpotlight	0,140	0,495	0,191	1,30
Decipher_NER	0,228	0,268	0,212	0,18
TagMe	0,239	*0,601*	0,313	0,15
WikipediaMiner	0,200	0,578	0,271	1,40
nerdp	0,304	0,300	0,266	0,11

(a) Průměr přes všechny dokumenty.

Anotátor	P	R	F1
Aida	*0,455*	0,391	0,377
DBpediaSpotlight	0,216	0,598	0,290
Decipher_NER	0,353	0,335	0,305
TagMe	0,324	*0,665*	*0,398*
WikipediaMiner	0,286	*0,666*	0,366
nerdp	0,433	0,321	0,331

(b) Průměr přes všechny datové sady (průměry průměrných skóre na datových sadách)

Tabulka 4.4: Průměrná skóre

Dokumentů	80
Slov	20 624
Průměrně slov na dokument	257
Celková velikost (KiB)	125,00

(a) Anotované dokumenty

systém	anotací	dokument (s)	100 000 slov	1 MiB textu	1 000 anotací
DBpediaSpotlight	4861	7,693	0:49:44,2	1:23:26,10	0:02:06,6
WikipediaMiner	5690	1,855	0:11:59,3	0:20:06,9	0:00:26,1
Decipher NER	2612	0,209	0:01:21,0	0:02:15,3	0:00:06,4
nerdp	3418	0,050	0:00:19,5	0:00:32,5	0:00:01,2
TagMe	3962	0,143	0:00:55,3	0:01:32,3	0:00:02,9

(b) Naměřené údaje (anotován každý dokument zvlášť)

systém	anotací	dokument (s)	100 000 slov	1 MiB textu	1 000 anotací
Decipher NER	2622	21,990	0:01:46,6	0:02:58,3	0:00:08,4
nerdp	2128	7,086	0:00:34,3	0:00:56,6	0:00:03,3

(c) Naměřené údaje (anotovány všechny dokumenty najednou po jejich konkatenaci)

Tabulka 4.5: Srovnání výkonnosti systémů

	Aida	DBpediaSpot.	Dec. NER	TagMe	WikipediaMiner	nerdp
Aida	100,0	15,1	22,7	27,7	24,7	27,5
DBpediaSpot.	15,1	100,0	10,0	35,8	41,1	18,5
Decipher NER	22,7	10,0	100,0	18,3	19,6	21,8
TagMe	27,7	35,8	18,3	100,0	49,2	24,8
WikipediaMiner	24,7	41,1	19,6	49,2	100,0	28,3
nerdp	27,5	18,5	21,8	24,8	28,3	100,0

Tabulka 4.6: Podobnosti systémů

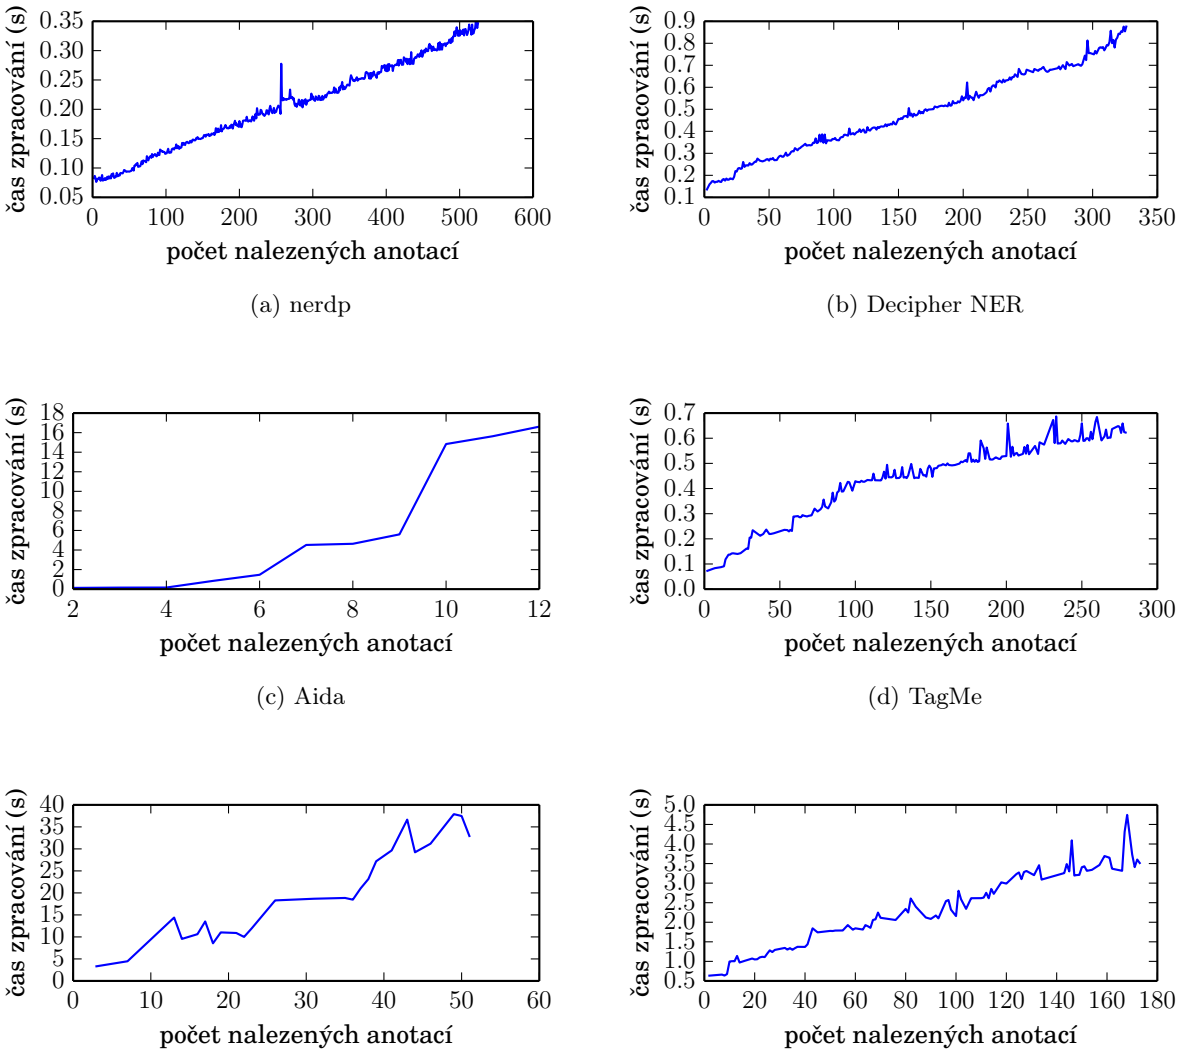

(a) nerdp

(b) Decipher NER

(c) Aida

(d) TagMe

(e) DBpediaSpotlight

(f) WikipediaMiner

Obrázek 4.2: Závislost doby zpracování požadavku na počtu nalezených pojmenovaných entit

pořadí	účastník	očekávané F1	latence
1	ExPoSe	0,688	1,1
2	NTUNLP	0,684	3,0
3	Acube Lab	0,578	0,5
4	WebSAIL	0,573	1,0
5	MLNS2	0,480	4,3
6	*nerdp*	*0,417*	*0,5*
7	MLNS	0,353	0,2
8	HITS	0,045	58,5
9	C3	0,024	0,5

Tabulka 4.7: Průběžné výsledky soutěže ERD 2014 (stav k 20. 5. 2014)

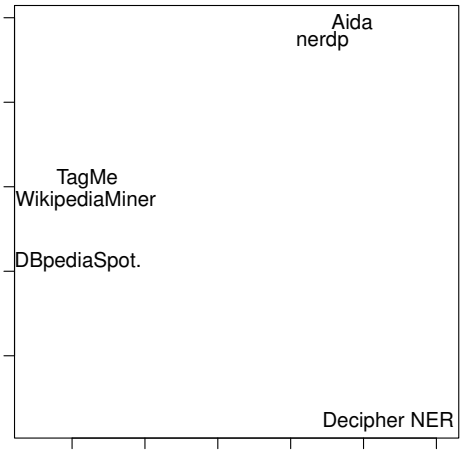

Obrázek 4.3: Podobnosti systémů po provedení PCoA analýzy

4.7 Profilování a spotřeba paměti

Systém byl profilován pomocí nástrojů Callgrind a KCachegrind. Samotný proces NED spotřebuje asi 34 % času tvorbou a kopírováním objektů a 25 % času jejich uvolňováním. Asi 16 % času odpovídá detekci pojmenovaných entit v textu, přičemž detekce kalendářních dat, zájmen a přísloví a tokenizace je výkonnostně zanedbatelná. Na samotný výpočet podobnosti kontextů připadá asi 10 % strojového času a tvorba informativní části odpovědi *(_msg)* stojí asi 13 % výkonu. Tvorba odpovědi ve formátu JSON trvá asi desetinu toho, co samotný proces NED.

Z výše uvedeného plyne, že největšími výkonnostními problémy je vysoký počet objektů a příliš podrobná odpověď. Doporučuje se tedy, aby uživatel v požadavku specifikoval minimální rozsah odpovědi (pokud to není nutné, aby nepožadoval podrobné informace o procesu zjednoznačňování *msg,* určení kalendářních dat a koreferencí a ponechávání kandidátů v odpovědi). Z hlediska optimalizace samotného systému se jako nejdůležitější jeví snížení počtu vytvářených objektů. Jedním ze způsobů, jak toho docílit, je změna datových struktur (např. přechodem ze *std::multimap* implementované jako červeno-černý strom na *std::vector,* který je implementován pomocí pole, a následným zajištěním potřebné funkce efektivněji na straně systému).

Spotřeba paměti záleží na použitých datech. Při datech získaných z Wikilinks se pohybuje kolem 7 GiB. Na vytvoření statistik z dat Wikilinks je potřeba asi 45 GiB paměti.

Kapitola 5

Závěr

V rámci diplomové práce byla nastudována problematika detekce, rozpoznávání a zjednoznačňování pojmenovaných entit a řešení koreference. V kapitole 2 byla nastíněna historie zpracování pojmenovaných entit, různé přístupy řešení, několik existujících implementací a metodika vyhodnocování jejich úspěšnosti. V následující kapitole 3 byl popsán návrh a implementace vlastního systému, testovacího prostředí pro srovnávání systémů a podpůrné nástroje. Kapitola 4 obsahuje popisy znalostních bází, trénovacích a testovacích dat, včetně ukázek a různých statistik. Dále jsou v ní zahrnuty informace o prováděných experimentech s podrobnými tabulkami a grafy.

Praktickým výsledkem práce je implementovaný systém *nerdp* pro detekci a zjednoznačňování pojmenovaných entit, prostředí pro testování systému a srovnávání s alternativními implementacemi, kolekce podpůrných nástrojů pro analýzu výstupů a anotování dokumentů a rozsáhlý ručně anotovaný testovací korpus. Samotný systém je implementován jako server v jazyce C++ s jedním pracovním vláknem, který si drží potřebná statistická data v paměti a asynchronně vyřizuje požadavky. Vytvořené programové rozhraní v jazyce Python umožňuje snadno komunikovat se serverem. Testovací prostředí umožňuje práci s testovacími datovými sadami v různých formátech, poskytuje rozhraní k alternativním anotovacím systémům a umožňuje provádění experimentů popsaných v kapitole 4, tedy zejména zkoumání správnosti, výkonnosti a podobnosti systémů. Vytvořený korpus, pracovně nazývaný *KnotCorpus,* obsahuje 1 751 ručně vytvořených anotací nad texty rozličných domén a formátů. Jako jediný korpus obsahuje značky i pro většinu koreferencí a kalendářních dat.

Provedené experimenty v kapitole 4 ukazují, že vyvinutý systém je rychlý, přiměřených paměťových nároků a splňuje požadavky na přesnost a úplnost výstupu. Při zpracovávání dat po jednom dokumentu by byl systém schopen anotovat 1 GiB textu do deseti hodin. Pro svůj chod spotřebuje méně než 10 GiB paměti. Na testovacích datech dosahuje přesnosti 0,433, úplnosti 0,321 a skóre F1 0,331.

Implementovaný systém se účastní mezinárodní soutěže *Entity Recognition and Disambiguation Challenge 2014*, kde zaujímá průběžné šesté místo z devíti (údaj platí ke dni 19. 5. 2014; finální vyhodnocení proběhne 10. 6. 2014; viz podkapitola 4.6).

Pro další rozvoj projektu by bylo vhodné systém paralelizovat, k čemuž je zapotřebí identifikovat problematická místa v externích knihovnách a v samotném systému a ošetřit je. Dále by bylo možné systém urychlit, pokud bude sníženo množství vytvářených objektů na haldě (více v podkapitole 4.7). Protože systémy používající globální přístupy k zjednoznačňování jsou konzistentně úspěšnější, než systémy s lokálními přístupy, jako další krok se logicky jeví rozšíření algoritmu systému o globální metodu. To vyžaduje tvorbu dat, která by reflektovala sémantickou příbuznost entit. Dále použití Wikipedie, jako učících dat, spo-

lečně s Wikilinks by mohlo vést k zvýšení úspěšnosti. Užitečné by mohlo být další zkoumání datové sady Wikilinks a její propracovanější předzpracování (např. zahazování každé fráze, která na různých místech daného dokumentu označuje různé entity). V úvahu přichází i tvorba vlastní trénovací datové sady.

Literatura

[1] Bird, S.; Klein, E.; Loper, E.: *Natural language processing with Python*. O'reilly, 2009.

[2] Bollacker, K.; Evans, C.; Paritosh, P.; aj.: Freebase: A Collaboratively Created Graph Database for Structuring Human Knowledge. In *Proceedings of the 2008 ACM SIGMOD International Conference on Management of Data*, SIGMOD '08, New York, NY, USA: ACM, 2008, ISBN 978-1-60558-102-6, s. 1247–1250, doi:10.1145/1376616.1376746.
URL http://doi.acm.org/10.1145/1376616.1376746

[3] Bumbulis, P.; Cowan, D. D.: RE2C: A More Versatile Scanner Generator. *ACM Lett. Program. Lang. Syst.*, ročník 2, č. 1-4, Březen 1993: s. 70–84, ISSN 1057-4514, doi:10.1145/176454.176487.
URL http://doi.acm.org/10.1145/176454.176487

[4] Cornolti, M.; Ferragina, P.; Ciaramita, M.: A framework for benchmarking entity-annotation systems. In *Proceedings of the 22nd international conference on World Wide Web*, International World Wide Web Conferences Steering Committee, 2013, s. 249–260.

[5] Cucerzan, S.: Large-Scale Named Entity Disambiguation Based on Wikipedia Data.

[6] Daiber, J.; Jakob, M.; Hokamp, C.; aj.: Improving Efficiency and Accuracy in Multilingual Entity Extraction. In *Proceedings of the 9th International Conference on Semantic Systems (I-Semantics)*, 2013.

[7] Ferragina, P.; Scaiella, U.: TAGME: on-the-fly annotation of short text fragments (by wikipedia entities). In *Proceedings of the 19th ACM international conference on Information and knowledge management*, ACM, 2010, s. 1625–1628.

[8] Finkel, J. R.; Grenager, T.; Manning, C.: Incorporating Non-local Information into Information Extraction Systems by Gibbs Sampling. *Proceedings of the 43nd Annual Meeting of the Association for Computational Linguistics*, 2005: s. 363–370.

[9] Gabrilovich, E.; Ringgaard, M.; Subramanya, A.: FACC1: Freebase annotation of ClueWeb corpora, Version 1 (Release date 2013-06-26, Format version 1, Correction level 0). 2013.
URL http://lemurproject.org/clueweb12/

[10] Grishman, R.; Sundheim, B.: Message Understanding Conference-6: A Brief History. In *COLING*, ročník 96, 1996, s. 466–471.

[11] Han, X.; Sun, L.; Zhao, J.: Collective entity linking in web text: a graph-based method. In *Proceedings of the 34th international ACM SIGIR conference on Research and development in Information Retrieval*, ACM, 2011, s. 765–774.

[12] Hintjens, P.: *ZeroMQ: Messaging for Many Applications*. O'Reilly Media, Inc., 2013.

[13] Hoffart, J.; Seufert, S.; Nguyen, D. B.; aj.: KORE: Keyphrase Overlap Relatedness for Entity Disambiguation. In *Proceedings of the 21st ACM International Conference on Information and Knowledge Management*, CIKM '12, New York, NY, USA: ACM, 2012, ISBN 978-1-4503-1156-4, s. 545–554, doi:10.1145/2396761.2396832.
URL http://doi.acm.org/10.1145/2396761.2396832

[14] Hoffart, J.; Yosef, M. A.; Bordino, I.; aj.: Robust disambiguation of named entities in text. In *Proceedings of the Conference on Empirical Methods in Natural Language Processing*, Association for Computational Linguistics, 2011, s. 782–792.

[15] Kulkarni, S.; Singh, A.; Ramakrishnan, G.; aj.: Collective Annotation of Wikipedia Entities in Web Text. In *Proceedings of the 15th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, KDD '09, New York, NY, USA: ACM, 2009, ISBN 978-1-60558-495-9, s. 457–466, doi:10.1145/1557019.1557073.
URL http://doi.acm.org/10.1145/1557019.1557073

[16] Manning, C. D.; Schütze, H.: *Foundations of statistical natural language processing*, ročník 999. MIT Press, 1999.

[17] Mařík, V.: *Umělá inteligence 2*. Academia, 1997, 373 s.

[18] Mendes, P. N.; Jakob, M.; García-Silva, A.; aj.: DBpedia Spotlight: Shedding Light on the Web of Documents. In *Proceedings of the 7th International Conference on Semantic Systems*, I-Semantics '11, New York, NY, USA: ACM, 2011, ISBN 978-1-4503-0621-8, s. 1–8, doi:10.1145/2063518.2063519.
URL http://doi.acm.org/10.1145/2063518.2063519

[19] Mikulová, M.; Bémová, A.; Hajič, J.; aj.: Anotace Pražského závislostního korpusu na tektogramatické rovině: pokyny pro anotátory. Technická zpráva, ÚFAL MFF UK, Prague, Czech Republic, 2005.

[20] Milne, D.; Witten, I. H.: Learning to Link with Wikipedia. In *Proceedings of the 17th ACM Conference on Information and Knowledge Management*, CIKM '08, New York, NY, USA: ACM, 2008, ISBN 978-1-59593-991-3, s. 509–518, doi:10.1145/1458082.1458150.
URL http://doi.acm.org/10.1145/1458082.1458150

[21] Milne, D.; Witten, I. H.: Learning to link with wikipedia. In *Proceedings of the 17th ACM conference on Information and knowledge management*, ACM, 2008, s. 509–518.

[22] Nadeau, D.; Sekine, S.: A survey of named entity recognition and classification. *Lingvisticae Investigationes*, ročník 30, č. 1, 2007: s. 3–26.

[23] Okazaki, N.: Constant Quark Database. 2007.
URL http://www.chokkan.org/software/cqdb/

[24] Ratinov, L.-A.; Roth, D.; Downey, D.; aj.: Local and Global Algorithms for Disambiguation to Wikipedia. In *ACL*, ročník 11, 2011, s. 1375–1384.

[25] Röder, M.; Usbeck, R.; Hellmann, S.; aj.: N3-a collection of datasets for named entity recognition and disambiguation in the nlp interchange format.

[26] Singh, S.; Subramanya, A.; Pereira, F.; aj.: Wikilinks: A large-scale cross-document coreference corpus labeled via links to Wikipedia. Technická zpráva, Technical report, University of Massachusetts, 2012.

[27] Soon, W. M.; Ng, H. T.; Lim, D. C. Y.: A machine learning approach to coreference resolution of noun phrases. *Computational linguistics*, ročník 27, č. 4, 2001: s. 521–544.

[28] Suchanek, F. M.; Kasneci, G.; Weikum, G.: Yago: a core of semantic knowledge. In *Proceedings of the 16th international conference on World Wide Web*, ACM, 2007, s. 697–706.

[29] Ševčíková, M.; Žabokrtský, Z.; Krůza, O.; aj.: Zpracování pojmenovaných entit v českých textech. Technická zpráva, 2007.

Seznam použitých zkratek

ACM SIGIR	Association for Computing Machinery – Special Interest Group on Information Retrieval
CoNLL	Conference on Computational Natural Language Learning
CQDB	Constant Quark Database
DARPA	Defense Advanced Research Projects Agency
EL	Entity Linking
ERD 2014	Entity Recognition and Disambiguation Challenge 2014
HMM	Hidden Markov model
IE	information extraction
MUC	Message Understanding Conference
NE	named entity
NED	Named Entity Disambiguation
NER	named entity recognition
NIST	National Institute of Standards and Technology
NLP	natural language processing
PCoA	Principal Coordinates Analysis
TAC	Text Analysis Conference
TF-IDF	Term Frequency-Inverse Document Frequency

Příloha A

Ukázky anotací

V této kapitole jsou demonstrovány výstupy systému na několika dokumentech.

A.1 KnotCorpus – morales_legal_action.txt

The Bolivian President Evo Morales *(Evo_Morales)* announced Thursday *(Thursday_(band))* he will file legal charges against the United States *(United_States)* President Barack Obama *(Barack_Obama)* for crimes against humanity. President Morales announced he was preparing litigation after Venezuelan President Nicholas *(Nicholas_Hughes)* Maduro's plane was allegedly denied entry into U.S. airspace over Puerto Rico *(Puerto_Rico)*.

President Morales called Obama *(Barack_Obama)* a "criminal"violating international law. Morales called an emergency meeting of the Community *(Community_(TV_series))* of Latin American *(Latin_America)* and Caribbean *(Caribbean)* States (CELAC), made up of 33 member states *(States_and_union_territories_of_India)* including Argentina *(Argentina)*, Mexico *(Mexico)* and Chile *(Chile)*, and encouraged member states *(States_and_union_territories_of_India)* to remove their ambassadors from the U.S. to show their solidarity. He asked Bolivarian Alliance member states *(States_and_union_territories_of_India)* to boycott the next United Nations *(United_Nations)* meeting, to be held in New York *(New_York)* on September 24. He also said the U.S. had pursued a policy of "intimidation"and have a history of blockading presidential flights...

A.2 KnotCorpus – paul_kane.txt

Paul Kane *(Paul_Kane)* began a career as a sign and furniture painter at York *(York)* where he met James *(William_James)* Bowman. Bowman had persuaded Kane *(Kane_(wrestler))* to study art in Europe *(Europe)*.

Kane *(Kane_(wrestler))* returned in early 1843 *(1843-00-00)* to Mobile, Alabama *(Mobile,_Alabama)*.

He had intended to travel further west, but John *(John,_King_of_England)* Ballenden, an experienced officer of the Hudson's Bay Company *(Hudson's_Bay_Company)* stationed at Sault Ste. Marie *(Sault_Ste._Marie,_Ontario)*, told him of the many difficulties and perils of travelling alone through the western territories and advised Kane *(Kane_(wrestler))* to attempt such a feat only with the support of the company. Kane *(Kane_(wrestler))* made paintings of Indian *(Indian_Ocean)* lifestyle. Kane *(Kane_(wrestler))* departed by steamboat from Toronto *(Toronto)*. He continued by canoe and sailing boats, witnessing a

buffalo pound hunt along the way. He embarked with a canoe brigade *(Brigade)* to Jasper's House *(House_(TV_series))*. He stayed for two months in that area, traveling and sketching around the Juan de Fuca Strait and the Strait of Georgia *(Strait_of_Georgia)*...

A.3 KnotCorpus – rene_magritte.txt

The 1960s brought a great increase in public *(Public_space)* awareness of Magritte *(René_Magritte)*'s work. Thanks to his "sound knowledge of how to present objects in a manner both suggestive and questioning", his works have been frequently adapted or plagiarized in advertisements, posters, book covers and the like. Examples include album covers such as Beck *(Beck)*-Ola by The Jeff Beck Group *(The_Jeff_Beck_Group)* (reproducing Magritte *(René_Magritte)*'s The Listening Room), Alan Hull *(Kingston_upon_Hull)*'s 1972 *(1972-00-00)* album Pipedream which used The Philosopher's Lamp, Jackson Browne *(Jackson_Browne)*'s 1974 *(1974-00-00)* album Late for the Sky *(BSkyB)*, with artwork inspired by The Empire of Light, Oregon *(Oregon)*'s album Out *(Out_(magazine))* of the Woods referring to Carte Blanche, and the Firesign Theatre *(The_Firesign_Theatre)*'s album Just Folks... A Firesign Chat based on The Mysteries of the Horizon *(Horizon_(BBC_TV_series))*. Styx *(Styx_(band))*'s album cover of The Grand Illusion incorporated a special adaptation of the painting, The Blank Check, by Magritte *(René_Magritte)* as well...

A.4 KnotCorpus – ruzne_twitter.txt.1

@nmbrown85 You can bring onboard but only up to Brunei *(Brunei)*. It will be confiscated in Brunej because of the LAGs restriction (over 100ml).

A.5 MSNBC – Bus16451112.txt

Home Depot *(The_Home_Depot)* CEO Nardelli quits Home-improvement retailer's chief executive had been criticized over pay

ATLANTA - Bob Nardelli abruptly resigned Wednesday as chairman and chief executive of The Home Depot *(The_Home_Depot)* Inc. after a six-year tenure that saw the world *(World)*'s largest home improvement store chain post big profits but left investors disheartened by poor stock performance...

A.6 MSNBC – Tra16454203.txt

LONDON - Thousands of airline passengers still have not received their luggage after fog disrupted flights at London *(London)*'s Heathrow Airport *(London_Heathrow_Airport)* late last year *(Year)*, airline officials said Wednesday.

The chaos was compounded when faults developed with a baggage belt at Heathrow *(London_Heathrow_Airport)*'s Terminal *(Terminal_(OS_X))* 4, said British Airways *(British_Airways)*, the airline that was worst affected....

Příloha B

Metriky kódu

V tabulce B.1 jsou zaneseny metriky systému *nerdp* a jeho obálky v jazyce Python. Tabulka B.2 obsahuje metriky testovacího prostředí a ostatních pomocných skriptů (pro tvorbu statistik, vizualizaci, práci s datovými sadami jako je Wikilinks, obálky anotátorů, ...). Údaje jsou počítány programem *cloc*[1] s vynecháním externích knihoven.

počet souborů	jazyk	prázdných řádků	komentářů	řádků kódu
24	C++	346	357	4164
14	C/C++ Header	182	203	559
2	Python	42	30	359
1	make	46	35	108

Tabulka B.1: Metriky systému *nerdp* a jeho obálky v jazyce Python

počet souborů	jazyk	prázdných řádků	komentářů	řádků kódu
72	Python	869	1036	4740
12	Bourne Shell	52	30	256
1	make	32	13	94

Tabulka B.2: Metriky testovacího systému a pomocných skriptů

[1] Program *cloc* je volně k dispozici na http://cloc.sourceforge.net/

Příloha C

Ukázky zdrojových kódů

Testovací systém

Výpočet průměrného skóre anotátoru *nerdp* na testovací datové sadě *MSNBC* s ignorováním kalendářních dat a tiskem výsledků i pro jednotlivé dokumenty vypadá následovně:

```
1  from benchmarks.corpora.msnbc import MSNBC
2  from benchmarks.annotators.nerdp import Nerdp
3  from benchmarks.evaluation import Evaluation
4  import numpy
5
6  annotator = Nerdp(options={"context_size" : 100})
7  corpus = MSNBC()
8  F1s = []
9
10 for (doc_name, text, gold_annotations) in corpus.annotated_documents():
11     annotations = annotator.annotate(text)
12     evaluation = Evaluation(gold_annotations,
13                             annotations,
14                             ignore_dates=True)
15     F1s.append(evaluation.F1())
16     print doc_name, evaluation.F1()
17
18 print u"průměrná F1", numpy.mean(F1s)
```

Systém nerdp

Hlavní programová smyčka systému *nerdp*, zjednodušená pro vyšší přehlednost:

```
1  int main(int argc, char** argv) {
2      // nacti JSON konfiguracni soubor specifikovany argumentem -c
3      unique_ptr<ProgramOptions> options { new ProgramOptions(argc, argv) };
4
5      // ziskej nastaveni
6      string fsa_path{ options->get_option({"recognizer", "fsa_path"}).as_string()};
7      string term_db_path{options->get_option({"terms", "termdb"}).as_string()};
8      const JSON::Value bind_addr = options->get_option({"communication", "bind"});
9
10     // priprav podpurne nastroje
11     TermReader term_reader(term_db_path);
12     unique_ptr<KbWrapper> kb{new KbWrapper()};
13     unique_ptr<Recognizer> rec{new FigaWrapper(fsa_path)};
```

```
14      unique_ptr<TermReader> tr{new TermReader(term_db_path)};
15
16      // inicializuj anotator
17      PNERD nerd(rec.get(), kb.get(), tr.get(), options.get());
18
19      // priprav ZeroMQ kontext
20      zmq::context_t context(1);
21      zmq::socket_t server(context, ZMQ_REP);
22      try {
23          server.bind(bind_addr.as_string().c_str());
24      } catch (const std::exception& e) {
25          LOG(FATAL) << "Error binding server " << e.what();
26      }
27      LOG(INFO) << "Bind successfull";
28
29      // zachytavej signaly pro korektni ukonceni aplikace
30      s_catch_signals();
31
32      // hlavni programova smycka
33      while (1) {
34          // cekej na prichozi pozadavek
35          zmq::message_t msg;
36          LOG(INFO) << "Waiting on connection.";
37          try {
38              server.recv(&msg);
39          }   catch (zmq::error_t& e) {
40              LOG(WARNING) << "Interrupt received, processing... " << e.what();
41          }
42          if (s_interrupted) {
43              LOG(WARNING) << "Interrupt received, killing server...";
44              return 0;
45          }
46
47          JSON::Array errors;
48          JSON::Object jresponse;
49          JSON::Object meta;
50
51          // sestav odpoved
52          meta["global_settings"] = options->get_option({});
53          meta["git_tag"] = git_tag;
54
55          string request{static_cast<char*> (msg.data()), msg.size()};
56
57          // prvni radek obsahuje JSON volby, zbytek je text k anotaci
58          auto split = request.find('\n');
59          if (split == request.npos) {
60              LOG(ERROR) << "malformed request";
61              errors.push_back({"malformed request"});
62          }
63          if (errors.size() == 0) {
64              string settings = request.substr(0, split);
65              TextPtr text = request.c_str() + split + 1;
66              if (strchr(text, '\r') != nullptr) {
67                  errors.push_back({"text contains illegal \r charracter"});
68              }
69              LOG(DEBUG) << "TEXT: " << text;
70
71              if (errors.size() == 0) {
72                  LOG(DEBUG) << "Settings: " << settings;
```

```
73                  auto req_setts = parse_string(settings);
74
75                  // samotny proces anotovani
76                  auto oa = nerd.recognize(text, &req_setts, &errors);
77
78                  jresponse["annotations"] = annotations2json(oa, kb.get(), text);
79                  meta["request_settings"] = req_setts;
80              }
81          }
82
83          jresponse["_meta"] = meta;
84          jresponse["_errors"] = errors;
85
86          stringstream ss;
87          ss << jresponse;
88          string response{ss.str()};
89
90          // odesli odpoved
91          s_send(server, response);
92      }
93      return 0;
94  }
```

Příloha D

Ukázka odpovědi programu

Pro větu *„Ford was the best USA president.“* při požadavku na maximum informací odpovídá server *nerdp* následovně:

Výsledek

Ford *(Gerald_Ford)* was the best USA *(?)* president.

Nezkrácená odpověď serveru


```
{
  "_errors": [
  ],
  "_meta": {
    "git_tag": "v0.2",
    "git_version": "0f3b1353a20ac40a42bc11870653db08b7ef875b",
    "global_settings": {
      "communication": {
        "bind": "ipc:///tmp/nerdp"
      },
      "logging": {
        "conf": "/mnt/minerva1/nlp/projects/nerd/nerdp/conf/logging.conf"
      },
      "nerdp": {
        "keep_candidates": true
      },
      "nerdp_json": true,
      "recognizer": {
        "fsa_path": "/mnt/minerva1/nlp/projects/nerd/local/results/automata.fsa"
      },
      "stats": {
        "entities": "/mnt/minerva1/nlp/projects/nerd/local/results/
            stats_fbkb_entity2tokenvector.tsv",
        "include_kb_description": false,
        "include_mention": true,
        "max_idf": 5.7,
        "min_denotations": 15,
        "min_idf": 1.6,
        "phrases": "/mnt/minerva1/nlp/projects/nerd/local/results/stats_fbkb_phrases
            .tsv",
        "tokens": "/mnt/minerva1/nlp/projects/nerd/local/results/stats_fbkb_tokens.
            tsv",
        "tokens_db": "/mnt/minerva1/nlp/projects/nerd/local/results/
            stats_fbkb_tokens.db",
        "unknown_wikis": "/mnt/minerva1/nlp/projects/nerd/local/results/
            stats_fbkb_unknown_wikis.txt",
        "various": "/mnt/minerva1/nlp/projects/nerd/local/results/stats_fbkb_various
            .txt"
```

```
    },
    "terms": {
      "termdb": "/mnt/minerva1/nlp/projects/nerd/local/results/stats_fbkb_tokens.
          db"
    }
  },
  "prog": "nerdp",
  "request_settings": {
    "append_msgs": true,
    "apriori_weight": 0.4,
    "context_size": 50,
    "corefs": true,
    "dates": true,
    "doc_id": "19e1e17aff4b4a132243bca0fba8ad793bf04695",
    "keep_candidates": true,
    "min_context_score": 0,
    "min_phrase_score": 8,
    "ookb_context": true
  },
  "timestamp": "2014-05-18T00:51:13"
},
"annotations": [
  {
    "aphrase": "Ford",
    "begin": 0,
    "byte_begin": 0,
    "byte_end": 4,
    "end": 4,
    "entities": [
      {
        "_msg": {
          "context_bow_score": {
            "USA": 0.000153208
          },
          "context_score": -0.0004555,
          "context_score_norm": -0.14998,
          "disambiguation": "low context score",
          "phrase_score": 20,
          "phrase_score_norm": 0.0163399
        },
        "freebase": "/m/01pp3p",
        "kb_id": 94354,
        "name": "John Ford",
        "score": 0,
        "type": "NamedEntity",
        "wikipedia": "http://en.wikipedia.org/wiki/John_Ford"
      },
      {
        "_msg": {
          "context_bow_score": {
          },
          "context_score": -0.000506569,
          "context_score_norm": -0.166795,
          "disambiguation": "low context score",
          "phrase_score": 11,
          "phrase_score_norm": 0.00898693
        },
        "freebase": "/m/0dcxf",
        "kb_id": 1313542,
        "name": "Ford Madox Ford",
        "score": 0,
        "type": "NamedEntity",
        "wikipedia": "http://en.wikipedia.org/wiki/Ford_Madox_Ford"
      },
      {
        "_msg": {
          "context_bow_score": {
            "USA": 0.000887298,
```

```
      "president": 0.000768809
    },
    "context_score": 4.54663e-05,
    "context_score_norm": 0.0149704,
    "phrase_score": 1224,
    "phrase_score_norm": 1
  },
  "freebase": "/m/02zs4",
  "kb_id": 1797708,
  "name": "Ford Motor Company",
  "score": 0.408982,
  "type": "NamedEntity",
  "wikipedia": "http://en.wikipedia.org/wiki/Ford_Motor_Company"
},
{
  "_msg": {
    "context_bow_score": {
    },
    "context_score": -0.000506569,
    "context_score_norm": -0.166795,
    "disambiguation": "low context score",
    "phrase_score": 29,
    "phrase_score_norm": 0.0236928
  },
  "freebase": "/m/07ybx6",
  "kb_id": 1839124,
  "name": "Ford Models",
  "score": 0,
  "type": "NamedEntity",
  "wikipedia": "http://en.wikipedia.org/wiki/Ford_Models"
},
{
  "_msg": {
    "context_bow_score": {
      "USA": 0.00124608,
      "president": 0.000519075
    },
    "context_score": 8.18142e-05,
    "context_score_norm": 0.0269385,
    "phrase_score": 27,
    "phrase_score_norm": 0.0220588
  },
  "freebase": "/m/03gxm",
  "kb_id": 2325176,
  "name": "Henry Ford",
  "score": 0.0249866,
  "type": "NamedEntity",
  "wikipedia": "http://en.wikipedia.org/wiki/Henry_Ford"
},
{
  "_msg": {
    "context_bow_score": {
      "USA": 0.0010147,
      "president": 0.00961624
    },
    "context_score": 0.00303708,
    "context_score_norm": 1,
    "phrase_score": 91,
    "phrase_score_norm": 0.0743464
  },
  "freebase": "/m/0c_md_",
  "kb_id": 82322,
  "name": "Gerald Ford",
  "score": 0.629739,
  "type": "NamedEntity",
  "wikipedia": "http://en.wikipedia.org/wiki/Gerald_Ford"
},
{
```

```
      "_msg": {
        "context_bow_score": {
          "president": 0.000983793
        },
        "context_score": -0.000178638,
        "context_score_norm": -0.0588192,
        "disambiguation": "low context score",
        "phrase_score": 11,
        "phrase_score_norm": 0.00898693
      },
      "freebase": "/m/0kqrk",
      "kb_id": 9038,
      "name": "Ford Prefect",
      "score": 0,
      "type": "NamedEntity",
      "wikipedia": "http://en.wikipedia.org/wiki/Ford_Prefect_(character)"
    }
  ]
},
{
  "aphrase": "USA",
  "begin": 18,
  "byte_begin": 18,
  "byte_end": 21,
  "end": 21,
  "entities": [
    {
      "_msg": {
        "context_bow_score": {
          "president": 0.000523566
        },
        "context_score": -0.000332047,
        "context_score_norm": 0,
        "disambiguation": "low context score",
        "phrase_score": 18,
        "phrase_score_norm": 0.00608519
      },
      "freebase": "/m/03lp2g",
      "kb_id": 801704,
      "name": "Miss USA",
      "score": 0,
      "type": "NamedEntity",
      "wikipedia": "http://en.wikipedia.org/wiki/Miss_USA"
    },
    {
      "_msg": {
        "context_bow_score": {
        },
        "context_score": -0.000506569,
        "context_score_norm": 0,
        "disambiguation": "low context score",
        "phrase_score": 37,
        "phrase_score_norm": 0.0125085
      },
      "freebase": "/m/0kcdl",
      "kb_id": 1202047,
      "name": "USA Network",
      "score": 0,
      "type": "NamedEntity",
      "wikipedia": "http://en.wikipedia.org/wiki/USA_Network"
    },
    {
      "ookb_id": 1,
      "score": 1,
      "type": "Unknown"
    },
    {
      "_msg": {
```

```
            "context_bow_score": {
              "Ford": 0.000456163,
              "president": 0.000585993
            },
            "context_score": -0.000159184,
            "context_score_norm": 0,
            "disambiguation": "low context score",
            "phrase_score": 2958,
            "phrase_score_norm": 1
          },
          "freebase": "/m/09c7w0",
          "kb_id": 777097,
          "name": "United States of America",
          "score": 0,
          "type": "NamedEntity",
          "wikipedia": "http://en.wikipedia.org/wiki/United_States"
        }
      ]
    }
  ]
}
```

Příloha E

Obsah CD

Složka *nerdp* obsahuje zdrojové kódy systému *nerdp*. Složka *knot* obsahuje kódy testovacího prostředí a ostatní skripty. Složka *lyx* obsahuje DP ve formátu programu *LyX*. V *latex* jsou zdrojové kódy pro LaTeX exportované z programu *LyX*. Testovací data *KnotCorpus* jsou umístěna ve složce *knot_ corpus*.