

Využití
pravidlové
disambiguace

johanka

Intro

Syntaktické
pokusy

O co nám jde
Jak to děláme
Znechucený
závěr

Mezihra

Hybridní
pokusy

Znechucený
úvod
Co bychom tak
možná mohli
Co opravdu
můžeme

Závěr

Využití pravidlové disambiguace

(Jak disambiguátoři přicházejí o iluze)

johanka

April 16, 2008

Výchozí podmínky

Využití
pravidlové
disambiguace

johanka

Intro

Syntaktické
pokusy

O co nám jde
Jak to děláme
Znechucený
závěr

Mezihra

Hybridní
pokusy

Znechucený
úvod
Co bychom tak
možná mohli
Co opravdu
můžeme

Závěr

Co máme k dispozici?

- Jazyk LanGR + poloboha Pavla Květoně
- Pravidla pro (částečnou) morfologickou disambiguaci (Niki Petkevič, Tomáš Jelínek)

O co se snažíme?

- Něco z toho dostat (ne nutně morfologickou disambiguaci)

Proč syntax?

Využití
pravidlové
disambiguace

johanka

Intro

Syntaktické
pokusy

O co nám jde
Jak to děláme
Znechucený
závěr

Mezihra

Hybridní
pokusy

Znechucený
úvod
Co bychom tak
možná mohli
Co opravdu
můžeme

Závěr

- Mnohá disambiguační pravidla se v ní stejně vrtají a pak získanou informaci (zbytečně) zahodí
- Některá jsou "jasná" (identifikace podmětu a přísudku, předložkové fráze...)
- Jiná lze využít nepřímo či kolektivně (antecedent vztazného zájmena, cokoli v koordinaci..)
- LanGR snadno umožňuje i psaní ryze syntaktických pravidel

Přesná specifikace úlohy

Využití
pravidlové
disambiguace

johanka

Intro

Syntaktické
pokusy

O co nám jde
Jak to děláme
Znechucený
závěr

Mezihra

Hybridní
pokusy

Znechucený
úvod

Co bychom tak
možná mohli
Co opravdu
můžeme

Závěr

- Ověření, zda lze stávající disambiguační pravidla využít pro parsing (úplný či částečný)
- Menší úpravy možné, doplňková pravidla možná, ale neměla by tvořit většinu díla
- V žádném případě nepsat od začátku nový parser!
(Takových už je dost a lepších.)

Jak funguje disambiguace? (138. opakování)

Využití
pravidlové
disambiguace

johanka

Intro

Syntaktické
pokusy

O co nám jde
Jak to děláme
Znechucený
závěr

Mezihra

Hybridní
pokusy

Znechucený
úvod
Co bychom tak
možná mohli
Co opravdu
můžeme

Závěr

- Načítá text po větách, provede či načte morfologickou analýzu
- Na každou větu pouští v cyklu pravidla, dokud se něco děje (ubývají tagy)
- Pravidla mají část konfigurační (kde se uplatní) a akční (co tam mají udělat)
- Pravidla se dělí na negativní (mažou nepřípustné tagy) a pozitivní (vybírají přípustné tagy)

Technické řešení syntaktické extenze

Využití
pravidlové
disambiguace

johanka

Intro

Syntaktické
pokusy

O co nám jde
Jak to děláme
Znechucený
závěr

Mezihra

Hybridní
pokusy

Znechucený
úvod

Co bychom tak
možná mohli
Co opravdu
můžeme

Závěr

- Syntax běží zároveň s disambiguací (záleží ovšem na konkrétních pravidlech)
- LanGR nebuduje žádné interní datové struktury, ale umí "vyhodit hlášku"
- Vyhodíme tedy hlášku, kdykoli máme (na základě namatchované konfigurace) pocit, že nějaká dvě slova jsou v určitém syntaktickém vztahu
- Následně sebereme všechny hlášky pro danou větu a zkusíme z nich něco postavit

Konkrétní vykonaná činnost

Využití
pravidlové
disambiguace

johanka

Intro

Syntaktické
pokusy

O co nám jde
Jak to děláme
Znechucený
závěr

Mezihra

Hybridní
pokusy

Znechucený
úvod
Co bychom tak
možná mohli
Co opravdu
můžeme

Závěr

- Ohledána všechna pravidla (cca 2000), cca 400 z nich shledáno pro syntax vhodnými a rozšířeno, napsáno cca 80 vlastních "záchytných" ryze syntaktických pravidel
- Postprocessing (závěrečná "semílačka") v Perlu, poměrně netriviální
- Output: závislosti PDT a-layer compatible - ne nutně, hlavně kvůli evaluaci
- Přirozeným výsledkem je les, lze si vynutit ošklivý strom
- Evaluace, porovnání s jinými parsery + kombinovatelnost

Detailly posprocessingu

Využití
pravidlové
disambiguace

johanka

Intro

Syntaktické
pokusy

O co nám jde
Jak to děláme
Znechucený
závěr

Mezihra

Hybridní
pokusy

Znechucený
úvod
Co bychom tak
možná mohli
Co opravdu
můžeme

Závěr

- Na vstupu dostane hlášky typu *CONNECT 1 2 Desc: Subj, Dom: P [Opt: level bezpečnosti]*
- V závislostním pojetí bere řídící členy jako kandidáty na otce, ale výsledek není přímočará
- Některé závislosti vznikají z více vztahů (vztažná věta)
- Asi 30 různých dalších úprav (propagování vztahu skrz koordinaci apod.)
- Při sporu se méně bezpečné informace zahazují, ale ne hned
- Průběžná detekce cyklů
- Velká výhoda: zachování levelů bezpečnosti - každá výsledná závislost má stanovenou, jak moc jí věříme!

Čísla (PDT 1.0 etest)

Využití
pravidlové
disambiguace

johanka

Intro

Syntaktické
pokusy

O co nám jde
Jak to děláme
Znechucený
závěr

Mezihra

Hybridní
pokusy

Znechucený
úvod

Co bychom tak
možná mohli
Co opravdu
můžeme

Závěr

Data	Coverage	Rules	Charniak	Collins
All	100 %	65.37 %	84.24 %	82.29 %
Very Safe	35.64 %	93.35 %	93.65 %	93.07 %
Safe	22.69 %	80.42 %	86.72 %	85.26 %
Unsafe	21.45 %	50.63 %	79.86 %	77.73 %
Untouched	20.20 %	14.79 %	69.39 %	64.78 %

Proč je to úplně blbě? (I)

Využití
pravidlové
disambiguace

johanka

Intro

Syntaktické
pokusy

O co nám jde
Jak to děláme
Znechucený
závěr

Mezihra

Hybridní
pokusy

Znechucený
úvod
Co bychom tak
možná mohli
Co opravdu
můžeme

Závěr

- Pozitivní pravidla nepřinesou nic nového
 - Zdeněk má lepší :)
 - Všichni mají stejné problémy a statistika je vždy o krok napřed
- Negativní pravidla pozitivním nepomůžou
 - Lze je (případně) zkoumat jako hinty někomu jinému
 - Nebo jako Karlsson a jeho parta - zkoumat všechno a seškrťovat

Proč je to úplně blbě? (II)

Využití
pravidlové
disambiguace

johanka

Intro

Syntaktické
pokusy

O co nám jde
Jak to děláme
Znechucený
závěr

Mezihra

Hybridní
pokusy

Znechucený
úvod
Co bychom tak
možná mohli
Co opravdu
můžeme

Závěr

- Disambiguace má malé pokrytí - trvalý problém!
- Nepomůže ani vmezěření statistického taggeru
- Systém je regulární :((= jednopruhodový. Nelze vypustit rozpoznaný kus věty a znova začít ohledávat.)
- Na tohle každý parser jednou dojede (IMHO i tagger)
- Bezkontextovost lze dohackovat, ale dost brutálně a s nejistým výsledkem

Mezihra

Využití
pravidlové
disambiguace

johanka

Intro

Syntaktické
pokusy

O co nám jde
Jak to děláme
Znechucený
závěr

Mezihra

Hybridní
pokusy

Znechucený
úvod
Co bychom tak
možná mohli
Co opravdu
můžeme

Závěr



Drtivá disambiguační čísla

Využití
pravidlové
disambiguace

johanka

Intro

Syntaktické
pokusy

O co nám jde
Jak to děláme
Znechucený
závěr

Mezihra

Hybridní
pokusy

Znechucený
úvod

Co bychom tak
možná mohli
Co opravdu
můžeme

Závěr

Opáčko z minulého týdne (únor 2006, PDT 2.0 d-test):

- morfologie: precision 25.72 %, recall 99.40 %
- root (bezpečná pravidla): precision 54.95 %, recall 98.84 %
- všechna pravidla: precision 70.11 %, recall 97.94 %
- perceptron Anny K.: accuracy 95.50 %

Jak použít disambiguaci k disambiguaci?

Využití
pravidlové
disambiguace

johanka

Intro

Syntaktické
pokusy

O co nám jde
Jak to děláme
Znechucený
závěr

Mezihra

Hybridní
pokusy

Znechucený
úvod

Co bychom tak
možná mohli
Co opravdu
můžeme

Závěr

- Samotná nic moc (k "ryzí homonymii" má výsledek daleko)
- Zvednutí čísel v konečném čase nereálné (výkonnost systému je stabilizovaná s občasnými drobnými výkyvy směrem k vyšší precision či recallu)
- Heuristiky zklamaly očekávání (chybuje příliš a uplatňuje se málo)
- Jediná naděje je v kombinaci :)
- Nutná, ale nikoli postačující podmínka: musíme umět různé věci!

Jak mohou pravidla pomoci statistice?

Využití
pravidlové
disambiguace

johanka

Intro

Syntaktické
pokusy

O co nám jde
Jak to děláme
Znechucený
závěr

Mezihra

Hybridní
pokusy

Znechucený
úvod

Co bychom tak
možná mohli

Co opravdu
můžeme

Závěr

Možnosti není zase tolik:

- Pustíme předem
- Pustíme zadem
- Sdrátujeme dohromady
- Ještě něco jiného?

Předení a drátování

Využití
pravidlové
disambiguace

johanka

Intro

Syntaktické
pokusy

O co nám jde
Jak to děláme
Znechucený
závěr

Mezihra

Hybridní
pokusy

Znechucený
úvod

Co bychom tak
možná mohli
Co opravdu
můžeme

Závěr

- Všichni pořád básní o "ručně psaných featurách"
- Efektivně to ale znamená skoro totéž jako "pustit předem" (jen bychom tagy nemazali, ale označili)
- A má to i stejný zádrhel - velmi nízké uplatnění pravidel na zcela nedisambiguovaném (tedy defaultním) vstupu
- Tedy puštění předem funguje, nechybuje, ale nic moc nedělá (dle výběru pravidel od nepatrného zlepšení po patrné zhoršení :))
- Potěšující pozorování: Annin tagger není citlivý na redukování tagů na vstupu, netřeba přetrénovávat (naopak)

Pravidla po statistice

Využití
pravidlové
disambiguace

johanka

Intro

Syntaktické
pokusy

O co nám jde
Jak to děláme
Znechucený
závěr

Mezihra

Hybridní
pokusy

Znechucený
úvod
Co bychom tak
možná mohli
Co opravdu
můžeme

Závěr

- Hodně chyb oprávněně chytí
- Víc jich ale nareportují neoprávněně a ještě víc neodhalí vůbec
- Proč 90 % chyb taggeru vůbec nenajdeme, toč otázka :)
(neznámá slova?)
- Smazaný tag téměř vždy znamená problém ve větě, ale ledva v polovině případů je to přímo na místě onoho tagu
(přecitlivělost na překlepy, gramatické chyby...)
- Pravidla po statistice nelze tedy v žádném případě použít jako automatický detektor a opravovač chyb

Co teď? - Úkoly hodné celých mužů

Využití
pravidlové
disambiguace

johanka

Intro

Syntaktické
pokusy

O co nám jde
Jak to děláme
Znechucený
závěr

Mezihra

Hybridní
pokusy

Znechucený
úvod
Co bychom tak
možná mohli
Co opravdu
můžeme

Závěr

1. Proč se pravidla v preprocessingu nechytají?

- Kvůli slovnědruhové homonymii!
- No tak jim s ní pomůžeme, ne?

2. Dají se nějak využít přecitlivělá pravidla v postprocessingu?

- Dají. Třeba na odlišení slušně a méně slušně
vypadajících/označkovaných dat.

Pravidla po rozetnutí slovního druhu

Využití
pravidlové
disambiguace

johanka

Intro

Syntaktické
pokusy

O co nám jde
Jak to děláme
Znechucený
závěr

Mezihra

Hybridní
pokusy

Znechucený
úvod

Co bychom tak
možná mohli
Co opravdu
můžeme

Závěr

Pracovní postup (+ výsledky na d-testu):

- 1** Morfologická analýza (25.72 %/recall 99.40 %)
- 2** (opt) Pečlivě zvolená pravidla (zatím neděláme)
- 3** Tagger (95.50 %)
- 4** Vrátíme všechny tagy se stejným subposem, jako má vybraný tag (30.11 %, recall 98.87 %)
- 5** Pravidla (zatím root) (61.87 %/98.61 %) (vs. 54.95 %/98.84 %)
- 6** Tagger (95.73 % !) (vs. 95.50 %)

Ověření: pouze kroky: 1, 3, 4, 6 dávají jen 95.46 % - samotné rozfázování téměř nemá vliv

Pozorování: pokles recallu mezi 4 a 5 je nepatrný - není třeba redukovat množinu pravidel, naopak je možné zkoušet ji rozšiřovat

Unsupervised vize (náčelníkova :))

Využití
pravidlové
disambiguace

johanka

Intro

Syntaktické
pokusy

O co nám jde
Jak to děláme
Znechucený
závěr

Mezihra

Hybridní
pokusy

Znechucený
úvod
Co bychom tak
možná mohli
Co opravdu
můžeme

Závěr

Pracovní postup (+ výsledky na dtestu):

- 1** Ojetí hromady dat (SYN*) více taggery (3?)
(95.50/93.97/94.37)
- 2** Vybrání pouze těch vět, kde se všechny na všem shodnou
(33 % dat, 98.40 (m. recall 99.64))
- 3** (opt) Vyházení těch vět, kde se něco nelíbí pravidlům
(30 % dat, 98.64 (m. recall 99.71))
- 4** Použití výsledku jako nových trénovacích dat pro taggery
(???)

Postranní čísýlka

Využití
pravidlové
disambiguace

johanka

Intro

Syntaktické
pokusy

O co nám jde
Jak to děláme
Znechucený
závěr

Mezihra

Hybridní
pokusy

Znechucený
úvod
Co bychom tak
možná mohli
Co opravdu
můžeme

Závěr

Accuracy/podíl na datech:

- Morče + pravidla 96.1/80
- Morče + Hajič 97.94/43 (+pravidla 98.25/38)
- Morče + Krbec 97.77/47
- Hajič + Krbec 96.97/45
- alespoň dva taggery 95.89/89

K zamyšlení: Šlo by to i s parsery? A šlo by k tomu použít negativních pravidel?

Prozatímní závěry

Využití
pravidlové
disambiguace

johanka

Intro

Syntaktické
pokusy

O co nám jde
Jak to děláme
Znechucený
závěr

Mezihra

Hybridní
pokusy

Znechucený
úvod
Co bychom tak
možná mohli
Co opravdu
můžeme

Závěr

- Parsování pozitivními pravidly byl blbej nápad
- Negativní pravidla zatím čekají na možné syntaktické využití
- Pravidla nelze žádným triviálním způsobem využít ke zlepšení situace na poli taggerů
- Existují však způsoby netriviální :)
- Úkol do diskuse/ke kafi/na doma: Máte nějaké další nápady?