

Experimenty s frázovým statistickým překladem z češtiny do angličtiny

Ondřej Bojar
obo@cuni.cz

27. únor, 2006

Ondřej Bojar Experimenty s frázovým překladem 27. únor, 2006

2 Statistický překlad po slovech či frázích

- trénovací soubor **paralelních textů**
- zarovnání po slovech
- extrakce slovníku (překlady slov či frází)
- *decoding* (překlad) = hledání "nejhladší formulace"
nejhladší ~ 3-gramy v mé hypotéze až jsou v průměru (součin pstí) co nejběžnější (často spatřeny korpušu cílového jazyka, tzv. **jazykovém modelu**)



Ondřej Bojar Experimenty s frázovým překladem 27. únor, 2006

4 Ruční zarovnání po slovech

Anotováno: 2x 515 vět z dev. a test. dat PCEDT 1.0.
Typy spojení: žádné/jisté/možné/bez ekvivalentu a žádné/frázové.

Anotováno celkem 2x16 000=32 000 spojení.

Z toho 18 % (5 800) vytvořil jen jeden anotátor a druhý ne.


Pokud odhleďneme od typu spojení, neshoda klesne na 9 %.

Neshody zejména v:

- anotování součástí analytických predikátů (někdy je konstrukce paralelní, někdy ne)
- anglických členech v případech, kdy na české straně nelze určit řídicí podstatné jméno, např. proto, že při překladu byl změněn slovní druh
- interpunkci (zejména apozice, koordinace ad. v kombinaci)

Ondřej Bojar Experimenty s frázovým překladem 27. únor, 2006

6 Méně monotonné překlad



Ondřej Bojar Experimenty s frázovým překladem 27. únor, 2006

1 Osnova

- Statistický strojový překlad na 1 slide.
- Dostupná data.
- Zarovnávání po slovech: ruční a série experimentů se strojovým.
- Frázový statistický překlad: metrika, série experimentů.
- Souhrn a varování, výhled.
- Širší zamýšlení a "pracovní návyky".

Ondřej Bojar Experimenty s frázovým překladem 27. únor, 2006


3 Dostupná data pro překlad (říjen 2005)

Korpus a verze	Vět	Tokenů	Slovník	Lemat	Pozn.
Prague Cz-En Dep Tbk (PCEDT 1.0)	22k/49k	0.5M/1.2M	57k/30k	28k/25k	
Reader's Digest (PCEDT 1.0)	44k/44k	658k/755k	84k/36k	?	beletrie
Kačenka	128k/105k	1.5M/1.5M	102k/47k	39k/22k	beletrie
OPUS EU Constitution	11k/10k	127k/164k	?	?	špatná tok.
Kolovratník	107k/107k	1.3M/1.5M	190k/92k	?	netokeniz.

BEAST: komplikace č-a slovníků z webu (400k páru, 235k cs, 225k en hesel; pouze jednoslovňa hesla: 138k páru, 58k cs, 53k en)

Ondřej Bojar Experimenty s frázovým překladem 27. únor, 2006

5 Příklad téměř ideální



Ondřej Bojar Experimenty s frázovým překladem 27. únor, 2006

7 Metrika kvality zarovnání

Referenční data standardně neobsahují spojení frázového typu.
Referenční data jsme vytvořili sloučením obou anotací:

- oba anotátoři volí jisté spojení → jisté spojení
- jeden volí jisté a jeden nějaké jiné → jisté spojení
- alespoň jeden volí nějaké spojení → možné spojení

Automat nechť přiřazuje pouze jeden druh spojení (žádné/jisté).

$P \dots$ možná spojení, $S \subseteq P \dots$ jistá spojení, $A \dots$ navrhovaná spojení

$$\text{precision} = \frac{|A \cap P|}{|A|} \quad (\text{chyba uvést falešný, takový, který není ani možný})$$

$$\text{recall} = \frac{|A \cap S|}{|S|} \quad (\text{chyba zapomenout jistý})$$

$$\text{Alignment Error Rate, AER} = 1 - \frac{|A \cap P| + |A \cap S|}{|A| + |S|}$$

Ondřej Bojar Experimenty s frázovým překladem 27. únor, 2006

Více Dat? LM>paralelní korpus>slovník

	DEV-std	TEST-optbleu	TEST-std
pcedt5k ali:lemata	22.7	21.5	19.1
pcedt5k lmcedt ali:lemata	25.6	24	21.2
pcedt10k ali:lemata	26.6	23.7	21.2
baseline → pcedt20k ali:lemata	29.8	27.3	24.6
nik je horší → pcedt20k+dict ali:stem4	29.8	27.5	24.6
par. korp. → pcedt20k+stories ali:stem4	31.6	28	25.9
pcedt20k+dict lmcedt ali:stem4	32.7	29.6	26.9
a než LM → pcedt20k lmcedt ali:lemata	33.2	29.4	26.4
pcedt20k+stories lm600M4grKN ali:lemata	33.4	31.9	27.3
pcedt20k+stories lmcedt ali:stem4	35.9	32.3	29.7
pcedt 5k 10k 20k	základní paralelní korpus, různé množství trénovacích vět		
dict	nerozgenerovaný číslo slovník z webu, 116k hesel, 198/202k tokenů, 20k/30k vocab.		
stories	dodatečné paralelní texty, 85k vět, 1.7M tokenů, 118/44k vocab.		
lmcedt	LM v dané doméně (Čmejrek, Čufřín, a Havelka, 2003), n-gram vocab. 0.4:5:7M		
lm600M4grKN	"obecný" jazykový model, 600M tokenů, n-gram vocab. 1.7:26:38:63M		

Ondřej Bojar

Experimenty s frázovým překladem

27. únor, 2006

Pravidlové řešení vlastních jmen a čísel

Ponechat vlastní jména v originále ubližuje (skloňování a tokenizace).

Pravidlové ošetření čísel mírně pomáhá.

	DEV-std	TEST-optbleu	TEST-std
jména+čísla	25.1	23.4	21.3
jména+čísla+začítění čísel	25.5	24.9	22.9
jména	25.8	-	21.4
čísla	29.2	27.1	24.2
čísla+začítění čísel	29.7	28.6	25.8
baseline	29.8	27.3	24.6

vstup	do překladače	výstup
baseline	na 57.375 dolarech	na 57.375 dolarech at UNK .57.375 \$
řešení čísel	na 57.375 dolarech	na .NUM dolarech at \$ 57.375
čísla+začítění	na 57.375 dolarech	na .NUM dolarech at \$ 57.375

Ondřej Bojar

Experimenty s frázovým překladem

27. únor, 2006

Umělé rozšiřování trénovacích dat podle závislostí

Nápad vytvořit nové trénovací věty (věty s novými ngramy) promazáním listů v závislostních stromech ("redukce" vět).

- Off-line: vypíš všechny možné věty, které lze získat postupnými redukcemi trénovacích vět.
⇒ nepoužitelné, vede k explozi dat
- On-line: pro dané testovací zdrojové věty (tj. množinu "potřebných" ngramů)
 - Prohledej trénovací korpus s cílem najít *nesouvislé* ukázkové výskytu potřebných ngramů.
 - Označ nalezené uzly, alignované uzly v cílovém jazyce a též všechny sousedy v závislostních stromech tak, aby bylo dosaženo určité úrovně gramaticnosti.
 - Vypíš označené uzly (pokud nebyla nakonec označena celá věta).

Ondřej Bojar

Experimenty s frázovým překladem

27. únor, 2006

Celkový přínos metody je zanedbatelný

	pcedt 20k	pcedt 10k	pcedt 5k
Baseline	27.3	23.7	21.5
Rozšířená trénovací data	27.4	23.4	21.2
Rozšířená po odfiltrování "L.J. Hooker"	27.8	-	-

Zarovnání bylo vytvořeno pomocí sjednocení a lematizovaných vět. Výsledky jsou uvedeny na testovacích datech při optimalizaci na BLEU.

Souhrnný dojem: rozšiřování korpusu podle závislostí mírně pomáhá, pokud

- zajistíme gramaticnost dogenerovaných vět (pravidla závislá na jazyce)
- získané věty ještě pečlivě filtrovujeme od podezřelých vzorků

Ondřej Bojar

Experimenty s frázovým překladem

27. únor, 2006

Oprava evidentních prohřešků proti referencím

	DEV-std	TEST-optbleu	TEST-std
pcedt5k	22.7	21.5	19.1
pcedt5k s opravou	24.5	22.2	20
pcedt20k	29.8	27.3	24.6
pcedt20k s opravou	31.6	28.2	25.6
pcedt20k lm600M4grKN	33.4	31.9	27.3
pcedt20k lm600M4grKN s opravou	35.1	32.9	28.4

"Oprava" je přitom jen čtevce pevných náhrad:

„ „	→ „ „
„ „	→ „ „
L. J. Hooker	→ L. J. Hooker
the U.S.	→ the United States

Ondřej Bojar

Experimenty s frázovým překladem

27. únor, 2006

Detail o rozšiřování trénovacích dat

263 testovacích vět obsahuje 5146 bigramů.

- 60 % má v trénovacích datech alespoň jeden nesouvislý výskyt
- 33 % nemá žádný výskyt
- 7 % má jen souvislé výskytu.

Z celkem 440 tisíc ohledaných příkladů je:

- 20 % ignorováno (jsou souvislé)
- 60 % spíše náhodné souvisekty (příliš vzdálené v závislostním stromě)
- Zbývajících 20 % (93 tisíc) se zdá být k užitku.

Po dodání užlů nutných pro zlepšení gramaticnosti ovšem 92 % z 93 tisíc příkladů svou užitečnost ztrácí, protože se stanou opět nesouvislými. Nakonec je tedy použito 7800 částí vět (jen 2000 unikátních) jako dodatečná trénovací data.

Ondřej Bojar

Experimenty s frázovým překladem

27. únor, 2006

Příčiny nízkého skóre BLEU

Nejvýznamnější chybějící bigramy:	Nejvýznamnější nadbytečné bigramy:
19 „ „	26 „ „
12 of the	12 „ , which
10 Radio Free	8 Svobodná Evropa , when
6 L.J. Hooker	7 the state , who
6 in the	7 J. Hooker , L. J.
6 the strike	7 company GM , firm Hooker
5 , a	7 radio Svobodná spokesman for
5 margin calls	6 the company , tokens , types
4 28 tokens , 7 types	5 35 tokens , 7 types
3 54 tokens , 18 types	4 40 tokens , 10 types
2 94 tokens , 47 types	3 117 tokens , 39 types
1 698 tokens , 698 types	2 342 tokens , 171 types
	1 3214 tokens , 3214 types

Chybějící bigram = obsažen ve všech referencích, ale ne hypotéze

Nadbytečný bigram = obsažen v hypotéze, ale v žádné z referencí

Ondřej Bojar

Experimenty s frázovým překladem

27. únor, 2006

Souhrn série experimentů: co zlepšuje BLEU

zarovnání jiné než průnikové	+1.5 až +2.0
morfologické předzpracování (stemming)	+1.0
morfologické předzpracování (plná lematizace)	+1.5
přidání nepředzpracovaného slovníku	+0.2
dodatečné paralelné texty, použity i v jazykovém modelu	+0.7 až +1.7
větší jazykový model v doméně	+2.1 až +3.4
ještě větší, ale obecný jazykový model	+4.6
dodatečné paralelné texty, ale jazykový model (větší) v doméně	+5.0 až +6.0
pravidlové zpracování číselných výrazů	+0.5
umělé zvětšování trénovacích dat na základě syntaktické struktury	+0.5
oprava evidentních prohřešků proti referenčním překladům	+1.0 až +1.5
sjednocení tokenizace v hypotéze a referenčních překladech	+10.0

Ondřej Bojar

Experimenty s frázovým překladem

27. únor, 2006

Shrnutí a varování

- Od začátku pracuj od konce.
Jinak se plýtvá časem na minoritní problémy.
- Dilčí metrika podúlohy nemusí korelovat s celkovým hodnocením.
AER doporučuje průnik alignmentů, BLEU říká, že průnik překladu škodí.
- BLEU je příliš citlivé na detaily.
⇒ pomáhá "normalizace" dat (Leusch et al., 2005).
- PCEDT není realistický zdroj dat pro překlad z češtiny do angličtiny.
Čeština je příliš anglická, překlad do angličtiny nespravedlivě snadný.
- Komunikujte! Komunikujte! Komunikujte!
Ruční zarovnání po slovech na stejných datech nezávisle a současně dělala Ivana Kruijff-Korabayová a Klára Chvátalová, aniž bychom o sobě věděli.

Ondřej Bojar Experimenty s frázovým překladem 27. únor, 2006


Výhled / přání

- Referenční překlady do češtiny. (Např. PCEDT.)
Pokouším se vytvořit společně se studenty na FJFI, ale kvalita bude nevalná.
- Hledá se lepší metrika.
Hodnotit chyby v závislostech, specificky hodnotit chyby ve slovním tvaru. Odstranit přílišnou citlivost na detaily (určitého typu). Kontrolovat konzistence věty jako celku.
- Hledají se data pro vyhodnocení kvality metriky.
Je potřeba soubor řady lidských hodnocení nad možnou referenčními překladů. Dobrá metrika je taková, která kandidátské/referenční překlady uspořádá podobně jako lidé.

Ondřej Bojar Experimenty s frázovým překladem 27. únor, 2006

CzEng (pre-release)

Paralelní korpus, který jsme shromázdili se Zdeňkem Žabokrtským.



Ondřej Bojar Experimenty s frázovým překladem 27. únor, 2006

Širší zamýšlení

Modelový lingvista usiluje o popis jazyka, vysvětlení toho, co se děje, když si lidé rozumějí.

Modelový statistik usiluje o řešení dané úlohy s co nejmenší chybou.

- statistik potřebuje úlohu
- statistik potřebuje metriku
- statistik ctí princip Occamovy břitvy
- statistik zohledňuje zákon klesajícího zisku
- povaha práce na SMT je velmi jiná, řeší se zejména inženýrské problémy, jak rychle zpracovat velké množství dat ⇒ více informatiky než lingvistiky.

Ondřej Bojar Experimenty s frázovým překladem 27. únor, 2006

Pracovní návyky (jak se dělá špičkový ústav)

- Odborně vysoce fundovaný ředitel, mírně psí režim.
- "Žádný krok mimo".
- Lidé maximálně využívají strojové síly. (Makra na každém kroku.)
- Práce nad společným softwarovým dílem, všichni přispívají.
- Komplexní nástroj téměř zcela vlastní provenience (i vlastní FSA).
⇒ lze velmi rychle adaptovat a testovat nové věci.
- Kvalitní implementace (rychlá a úsporná):
⇒ umožňuje mnoho vývojových cyklů za jednotku času
- Výsoko kvalitní infrastruktura.
Paralelní výpočty s minimální režií: rychlý síťový souborový systém, uživatel nerozhoduje, na kterém počítači se úloha spustí.

Jednoduché je krásné. Kratší je lepší.

Ondřej Bojar Experimenty s frázovým překladem 27. únor, 2006

Literatura

- Čmejrek, Martin, Jan Čuřín, and Jiří Havelka. 2003. Czech-English Dependency-based Machine Translation. In *EACL 2003 Proceedings of the Conference*, pages 83–90. Association for Computational Linguistics, April. MSM113200006, LN00A063.
- Leusch, Gregor, Nicola Ueffing, David Vilar, and Hermann Ney. 2005. Preprocessing and Normalization for Automatic Evaluation of Machine Translation. In *Proceedings of the ACL Workshop on Intrinsic and Extrinsic Evaluation Measures for Machine Translation and/or Summarization*, pages 17–24, Ann Arbor, Michigan, June. Association for Computational Linguistics.
- Matusov, E., R. Zens, and H. Ney. 2004. Symmetric Word Alignments for Statistical Machine Translation. In *Proceedings of COLING 2004*, pages 219–225, Geneva, Switzerland, August 23–27.
- Och, Franz Josef and Hermann Ney. 2003. A systematic comparison of various statistical alignment models. *Comput. Linguist.*, 29(1):19–51.

Ondřej Bojar Experimenty s frázovým překladem 27. únor, 2006