
Frázový statistický překlad z angličtiny do češtiny

Ondřej Bojar
obo@cuni.cz

9. říjen, 2006

Osnova

- **Frázový statistický překlad krok po kroku**
 - Frázový překlad
 - Hledání nejlepší hypotézy (beam search decoding)
 - Ladění vah (minimum error rate training)
- Frázový statistický překlad o více faktorech
- Experimenty s překladem do češtiny
- Malý rozbor chyb
- Závěr
- O workshopu

Anglické části pocházejí z prezentací Philippa Koehna.

Translation

- Task: **translate this sentence** from German into English

er geht ja nicht nach hause

Translation step 1

- Task: translate this sentence from German into English


er geht ja nicht nach hause

er
he

- **Pick** phrase in input, **translate**

Translation step 2


- Task: translate this sentence from German into English



- Pick phrase in input, translate
 - it is allowed to pick words **out of sequence (reordering)**
 - phrases may have multiple words: **many-to-many** translation

Translation step 3


- Task: translate this sentence from German into English



- Pick phrase in input, translate


Translation step 4

- Task: translate this sentence from German into English




- Pick phrase in input, translate

Translation options




- **Many translation options** to choose from
 - in Europarl phrase table: **2727 matching phrase pairs** for this sentence
 - by pruning to the top 20 per phrase, **202 translation options** remain

Translation options





- The machine translation decoder does not know the right answer
→ **Search problem** solved by heuristic beam search



Decoding process: precompute translation options





Decoding process: start with initial hypothesis




Decoding process: hypothesis expansion




Decoding process: hypothesis expansion



Decoding process: hypothesis expansion



Decoding process: find best path



Complexity of search

- Search space is **exponential** with number of input words
- Pruning required
 - organize hypotheses in **stacks**
 - each stack contains all hypotheses with the **same number of input words** translated
 - only the **top n** hypothesis are kept in a stack (Moses default: 200)
 - only hypothesis **worse by factor α** are kept in the stack (default: 0.03)
 - when comparing hypotheses, **future cost** has to be considered
 - heuristic beam search is **polynomial** with sentence length
- Typically, a **reordering limit** is used (maximum movement)
 - search is **linear** with sentence length

Knowledge sources

- Many different **knowledge sources** useful
 - language model
 - reordering (distortion) model
 - phrase translation model
 - word translation model
 - word count
 - phrase count
 - drop word feature
 - phrase pair frequency
 - additional language models
 - additional features

Set feature weights


- Contribution of components p_i determined by weight λ_i
- Methods
 - **manual setting** of weights: try a few, take best
 - **automate** this process
- Learn weights
 - set aside a **development corpus**
 - set the weights, so that **optimal translation performance** on this development corpus is achieved
 - requires **automatic scoring** method (e.g., BLEU)

Learning task

- Task: **find weights**, so that feature vector of the correct translations **ranked first**

TRANSLATION	LM	TM	WP	SER
1 Mary not give slap witch green .	-17.2	-5.2	-7	1
2 Mary not slap the witch green .	-16.3	-5.7	-7	1
3 Mary not give slap of the green witch .	-18.1	-4.9	-9	1
4 Mary not give of green witch .	-16.5	-5.1	-8	1
5 Mary did not slap the witch green .	-20.1	-4.7	-8	1
6 Mary did not slap green witch .	-15.5	-3.2	-7	1
7 Mary not slap of the witch green .	-19.2	-5.3	-8	1
8 Mary did not give slap of witch green .	-23.2	-5.0	-9	1
9 Mary did not give slap of the green witch .	-21.8	-4.4	-10	1
10 Mary did slap the witch green .	-15.5	-6.9	-7	1
11 Mary did not slap the green witch .	-17.4	-5.3	-8	0
12 Mary did slap witch green .	-16.9	-6.9	-6	1
13 Mary did slap the green witch .	-14.3	-7.1	-7	1
14 Mary did not slap the of green witch .	-24.2	-5.3	-9	1
15 Mary did not give slap the witch green .	-25.2	-5.5	-9	1
rank translation	feature vector			

Learn feature weights



Osnova

- Frázový statistický překlad krok po kroku
- **Frázový statistický překlad o více faktorech**
 - Motivace: morfologie
 - Krok za krokem
 - Další nápady na využití více faktorů
- Experimenty s překladem do češtiny
- Malý rozbor chyb
- Závěr
- O workshopu

Motivace pro víc faktorů: zlepšit tvarosloví

- Statistický překlad do morfologicky bohatých jazyků funguje hůř než opačně.
Viz např. (Koehn, 2005).

Motivace pro překlad angličtina→čeština:


Běžné BLEU	25%
BLEU bez ohledu na slovní tvary ¹	33%

⇒ Dokonalým tvarováním slov by bylo možné zlepšit skóre o 8 bodů.

¹BLEU lematizovaného výstupu proti lematizovaným referencím.

Factored translation models

- **Factored representation** of words



- Benefits
 - **generalization**, e.g. by translating lemmas, not surface forms
 - **richer model**, e.g. using syntax for reordering, language modeling

Translation process: example

Input: Häuser → (Häuser, Haus, NNS)

1. **Translation step:** lemma ⇒ lemma
(?, house, ?), (?, home, ?)
2. **Generation step:** lemma ⇒ part-of-speech
(?, house, NN), (?, house, NNS), (?, home, NN), (?, homes, NNS)
3. **Translation step:** part-of-speech ⇒ part-of-speech
(?, house, NN), (?, house, NNS), (?, home, NN), (?, homes, NNS)
4. **Generation step:** lemma, part-of-speech ⇒ surface
(houses, house, NNS), (homes, home, NNS)

Pořadí překladových kroků je pevně určeno konfigurací.

Another idea: Subject-verb agreement

- Lexical n-gram language model would prefer

the paintings of the old man is beautiful

old man is is a better trigram than old man are

- Correct translation

the paintings of the old man are beautiful
- SBJ-plural - - - - V-plural -

- Special tag that tracks *count* of *subject* and *verb*

$p(-, \text{SBJ-plural}, -, -, -, \text{V-plural}, -) > p(-, \text{SBJ-plural}, -, -, -, \text{V-singular}, -)$


“skip” language model: $p(\text{SBJ-plural}, \text{V-plural}) > p(\text{SBJ-plural}, \text{V-singular})$

Osnova


- Frázový statistický překlad krok po kroku
- Frázový statistický překlad o více faktorech
- **Experimenty s překladem do češtiny**
 - Scénáře překladu
 - Jemnost morfologie
 - Více dat?
- Malý rozbor chyb
- Závěr
- O workshopu

Testované scénáře překladu


Pouze překlad (P)




Překlad+kontrola (P+K)



2*překlad+kontrola (P+P+K)



2*překlad+generování (P+P+G)



Výsledky scénářů

	Dev (std)	Dev (opt)	Test (opt)
Baseline: Pouze překlad (P)	25.68	29.24	25.23
2*překlad+generování (P+P+G)	23.93	30.34	25.94
2*překlad+kontrola (P+P+K)	25.12	30.73	26.43
Překlad+kontrola (P+K)	23.51	30.88	27.23

- ⇒ Přidání faktorů (a jazykových modelů) pro morfologii vždy pomohlo.
- ⇒ Čím složitější scénář, tím horší výsledek.

Důvodem jsou zřejmě chyby v hledání (search errors):

víc faktorů ⇒ větší prostor hypotéz (možná stejným povrchem) ⇒ hloubka zásobníku nemusí stačit

Míra detailu v reprezentaci morfologie (P+K)


Tagset	Typů viděno	Popis
plné zn.	1098	Plná morfologická značka, 15 pozic, teoreticky 4000 různých značek.
POS	173	Slovní druh a poddruh, u {N,A,P,R} navíc pád.
CNG01	571	Jako POS, ale {N,A,P,R} odlišují pád, číslo a rod.
CNG02	707	Pád, číslo a rod odlišen u {N,A,P,R,C,V}, lemma interpunkce přidáno ke značce.
CNG03	899	Jména a číslovky vyjadřují pád, číslo a rod, zvýrazněno zvratné <i>se/si</i> . Slovesa vyjadřují číslo, rod, čas a vid, zvýrazněno <i>být</i> . Předložky vyjadřují pád i lemma, lemma přidáno ke značce {Z,T,I}, tvar čísel u C=.

Výsledky P+K s různě jemnou morfologií

	Dev (std)	Dev (opt)	Test (opt)
Baseline: P (jediný faktor)	26.52	28.77	25.82
P+K, CNG01	22.30	29.86	26.14
P+K, POS	21.77	30.27	26.57
P+K, plné značky	22.56	29.65	27.04
P+K, CNG02	23.17	30.77	27.45
P+K, CNG03	23.27	30.75	27.62

- ⇒ Není chybou přidat detailní morfologii.
- ⇒ Lépe však funguje specifická sada značek opírající se o znalost jazyka i morf. systému.

Více dat ve scénáři P+K



m =malá data, 20k vět v doméně

m^+ =malá data, 20k vět v doméně, ale navíc oddělené jazykové modely (840k vět mimo doménu)

v =velká data, 20k vět v doméně a 840k vět mimo ni, oddělené jazykové modely vět

mix=velká data, 20k vět v doméně a 840k vět mimo, smíšeno do společného jazykového modelu

Osnova

- Frázový statistický překlad krok po kroku
- Frázový statistický překlad o více faktorech
- Experimenty s překladem do češtiny
- **Malý rozbor chyb**
- Závěr
- O workshopu

Dosáhli jsme cíle zlepšit morfologii?

- Na malých datech dosaženo významného zlepšení:
English→Czech: 20k vět, BLEU zvýšeno z 25.82% na 27.62% nebo až na 28.12% při použití dodatečných dat.
- Stále nedosahujeme úrovně lematizovaného BLEU (35%).
- Lokální shoda je již celkem dobrá:
Mikrostudie: shoda přídavného a podstatného jména
74% adjektiv ve shodě, 2% v neshodě, (v dalších případech chybělo subst. ap.)
⇒ Kde tedy zůstávají chyby v morfologii?

Mikrostudie chyb v překladu angličtina→čeština

Mikrostudie na nejlepším dosaženém výstupu (BLEU 28,12%), intuitivní metrika:

- studováno 15 vět, z celk. počtu 77 dvojic sloveso-slovesné doplnění ve *vstupním* textu:

překlad	... zachoval význam	... nebyl srozumitelný	... úplně chyběl
slovesa	43%	14%	21%
doplnění	79%	12%	6%

Navíc z případů, kdy sloveso i doplnění byly přeloženy správně, mělo 44% negramatickou nebo nesprávnou vazbu.

Ukázkové chyby

Vstup:	Keep on investing.
Výstup MT:	Pokračovalo investování. (grammar correct here!)
Glosa:	Continued investing. (Meaning: The investing continued.)
Správně:	Pokračujte v investování.

⇒ jazykový model vyhrál neprávem ⇒ nutno zohlednit valenci na zdrojové straně.

Vstup:	brokerage firms rushed out ads . . .
Výstup MT:	brokerské firmy vyběhl reklamy
Glosa:	brokerage firms _{pl.fem} ran _{sg.masc} ads _{pl.nom,pl.acc,pl.voc,sg.gen}
Správná možnost 1:	brokerské firmy vyběhly s reklamami _{pl.instr}
Správná možnost 2:	brokerské firmy vydaly reklamy _{pl.acc}

Data na cílové straně možná dost bohatá k identifikaci: vyběhnout–s–instr

Určitě nebudou dost bohatá pro všechny morfologické a lexikální varianty:

vyběhl–s–reklamou, vyběhla–s–reklamami, vyběhl–s–prohlášením, vyběhli–s–oznámením, . . .

Osnova

- Frázový statistický překlad krok po kroku
- Frázový statistický překlad o více faktorech
- Experimenty s překladem do češtiny
- Malý rozbor chyb
- **Závěr**
 - Porovnání s angličtinou
 - Návrat do reality (ukázka překladu)
 - Shrnutí
 - Celkové poučení
- O workshopu

Porovnání s angličtinou a lidmi

	Do angličtiny	Do češtiny	Rozdíl
Lidé	55.3±6.0	46.3±4.3	-9.0
P, 20k vět	28.50	25.23	-3.27
P+K, 20k vět	28.66	27.23	-1.43
P, 860k vět, směs domén	34.12	25.40	-8.72

- BLEU lidí počítáno 5x a průměrováno
- větší rozptyl do angličtiny, protože i původní text sloužil jako jedna z referencí
- nižší skóre do češtiny může ukazovat na větší tvaroslovnu a slovoslednou volnost, ale také možná jen, že do angličtiny překládali přímočařejí
- P+K podle očekávání pomohlo více do češtiny
- do angličtiny pomohlo více dat a překvapivě nevadilo smísit domény

Ukázka překladu do češtiny (BLEU 28,12)

jsme asi navštívit , pokud reklama funguje .

těžko na patách pátečního propadu akciového 190-point a nejistota , že to následovalo , několik velkých brokerských firem , které jsou kolébat nové reklamy , že známá zpráva : pokračovalo investování , trh je docela dobře .

jejich posláním je , aby udrželi klienti prchají z trhu , jako individuální investoři udělali v droves po krachu v říjnu

právě dny po krachu v roce 1987 , hlavní brokerské firmy vyběhl reklamy na klidné investory . tentokrát kolem , jsou pohybující ještě rychlejší .

We are about to see if advertising works .

Hard on the heels of Friday 's 190-point stock-market plunge and the uncertainty that 's followed , a few big brokerage firms are rolling out new ads trumpeting a familiar message : Keep on investing , the market 's just fine . Their mission is to keep clients from fleeing the market , as individual investors did in droves after the crash in October

Just days after the 1987 crash , major brokerage firms rushed out ads to calm investors .

This time around , they are moving even faster .

Shrnutí

- Frázový překlad do češtiny není zcela beznadějný.
Podobně jako u jiných jazyků lokální shody přijatelné, problém celkové koherence.
- Kontrola morfologie ve vícefaktorovém překladu pomáhá (čj, nj, špaň.).
. . . a to i v případě unsupervised morfologie (třídy slov místo značek, čínšt.).
 - Efekt se snižuje při použití více dat (čj, špaň.).
 - Efekt se snižuje při užití složitějšího scénáře.
- Jiná testovaná využití více faktorů zatím příliš nepomohla.
 - aj→nj: celková “struktura” věty, shoda čísla slovesa a subjektu
 - aj→čj: povrchová valence
- Data mimo doménu mohou i ublížit.

Celkové poučení (znovu a znovu a znovu!)

1. Potřebuješ úkol a metriku kvality výstupu.
Čím blíž je úkol ke každodenním problémům, tím lépe.
2. Napřed zkus *nejjednoduší* způsob, jak problém řešit.
Čím víc jsi vzdělán/vychován, tím *těžší* bývá mít jednoduché nápady.
3. Testuj na málo datech, i když jich máš hodně.
Ladění očividných chyb je rychlejší.
Případné zlepšení bude markantnější ;-)
4. Opravuj chyby časté, nikoli chyby nápadné!
Mikroevaluace je velmi užitečná. Projdi 10 vzorků výstupu, pojmenuj chyby, posčítej.

Osnova

- Frázový statistický překlad krok po kroku
- Frázový statistický překlad o více faktorech
- Experimenty s překladem do češtiny
- Malý rozbor chyb
- Závěr
- **O workshopu**

Celkově o workshopu

Výsledky týmu SMT na workshopu: <http://www.clsp.jhu.edu/ws2006/>

- Moses: systém pro strojový překlad, zřejmě bude LGPL.
- Vícefaktorové modely pro frázový překlad.
- Confusion networks (aproximace slovních grafů) pro překlad víceznačného vstupu.

Budoucnost:

- Euromatrix:
 - Edinburgh: Další využití více faktorů (reordering, lepší modely celkové koherence).
 - ÚFAL: Stromečkový dekodér (navazuje na disertaci M. Čmejrka).
- MIT (M. Collins, B. Cowan):
 - “Překlad valenčních rámců”, doplnění pak frázově.
- RWTH Aachen, ITCirst:
 - Překlad mluvené řeči, confusion networks.

Jak dosáhnout úspěšného workshopu

Všechno musí být připraveno předem.

- Moses byl vyvíjen 9 měsíců předem, workshop "jen" ověřil použitelnost.
Přesto první dva tři týdny *neproběhl jediný experiment*.
- Data byla připravena předem.
Přesto se třetí týden ukázalo, že španělština má otazníky místo diakritiky a v češtině chybí půlka dat.

Literatura

Koehn, Philipp. 2005. Europarl: A Parallel Corpus for Statistical Machine Translation. In *Proceedings of MT Summit X*, September.