

# PLIN009 – Strojový překlad

## Pravidlový strojový překlad

**Vít Baisa**

jaro 2012

21. března 2013

## 1 Úvod

## 2 Tokenizace

## 3 Morfologická rovina

## 4 Lexikální rovina

## Rozdělení systémů

Úvod

Rule-based Machine Translation – RBMT

- lingvistické znalosti formou pravidel
  - pravidla pro analýzu
  - pravidla pro převod struktur mezi jazyky
  - pravidla pro syntézu

Knowledge-based Machine Translation – KBMT

- systémy využívající znalosti o jazyce
  - obecnější pojem

## Rozdělení systémů

# Knowledge-based MT

- je důležité správně analyzovat kompletní význam zdrojového textu
  - ne ovšem *totální* význam (všechny konotace, explicitní a implicitní informace)
  - dříve spíše význam systému využívajícího interlinguu
  - zde jako ekvivalent pravidlového systému

## Rozdělení systémů

## Rozdělení systémů KBMT

- přímý překlad
    - direct translation
    - nejstarší, 1 krok – transfer
    - Georgetown experiment, METEO
    - zájem o něj rychle opadl
  - systémy používající interlinguu
    - interlingua-based
    - dva kroky – analýza, syntéza
    - Rosetta, KBMT-89
  - transferové systémy
    - tři kroky (+ transfer)
    - PC Translator

Do 90. let pouze tyto dva typy systémů.

## Systém přímého překladu

- hledají se korespondence mezi zdrojovými a cílovými jazykovými jednotkami (slovy)
  - první pokusy s překladem EN-RU
  - všechny složky jsou striktně omezeny na konkrétní jazykový pár
  - typicky se skládá z velkého překladového slovníku a monolitického programu řešícího analýzu a syntézu
  - nutně dvojjazyčné a jednosměrné
  - pro překlad mezi  $N$  jazyky potřebujeme  $N \times (N - 1)$  přímých dvojjazyčných systémů / modulů

# Přístup pomocí interlinguy

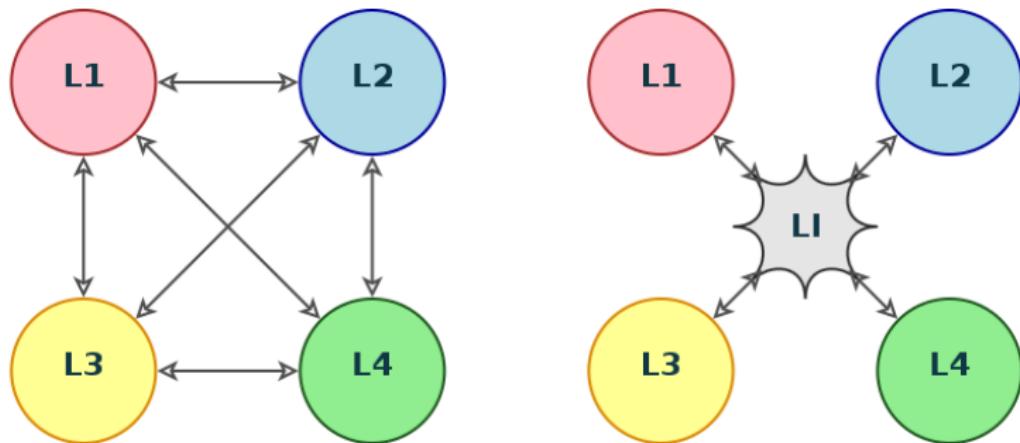
- předpokládá, že je možné SL konvertovat do sémanticko-syntaktické reprezentace, která je (částečně) nezávislá na jazyku
- interlingua musí být jednoznačná (unambiguous)
- z této podoby (interlingua) je generován TL
- analýza SL je jazykově závislá, ale nezávislá na TL
- analogicky syntéza TL
- SL a TL nepřijdou do styku
- pro překlad mezi  $N$  jazyky potřebujeme  $2 \times N$  modulů

# Transferové systémy strojového překladu

- provede se analýza po jistou úrovně
  - transferová pravidla převedou zdrojové jednotky na cílové
  - ne nutně na stejném úrovni
  - převod na (nejčastěji) syntaktické úrovni dovoluje zavádět kontextová omezení u přímých překladů nedostupná
  - na cílové straně se pak generuje cílový řetězec
  - systém linearizace
  - při hlubší analýze dochází ke stírání rozdílů mezi interlingua-based a transfer-based systémy
  - značná část obou systémů se může překrývat

Rozdělení systémů

# Interlingua vs. transferové KBMT



Od řetězce ke slovu

# Tokenizace

1 Úvod

2 Tokenizace

3 Morfologická rovina

4 Lexikální rovina

# Tokenizace

## Co to je?

- rozdělení vstupního řetězce do tokenů
- token = řetězec znaků
- výstup *tokenizace* = seznam tokenů
- slouží jako vstup pro další zpracování
- označení hranic vět

## Problémy

- don't: do\_n't, do\_n\_‐t, don\_‐t, ?
- červeno-černý: červeno\_-\_černý, červeno-černý, červeno-\_černý
- Zeleninu jako rajče, mrkev atd. ¶Petr nemá rád.
- Složil zkoušku a získal titul Mgr. ¶Petr mu dost záviděl.

# Tokenizace – jak se to dělá?

V drtivé většině případů heuristika. (`unitok.py`)

## Dělení na tokeny

- pro jazyky používající hlásková písma: dělení podle mezer
- a podle dalších interpunkčních znamének
- ?!., -()/:;

## Dělení na věty

- MT v naprosté většině případů pro věty
- u plaintextu: podle seznamu interpunkčních znamének
- problém: Měl jsem 5 (sic!) poznámek.
- výjimky: zkratky (aj., atd., etc.), tituly (RNDr., prof.)
- někdy (HTML) lze využít strukturní značky

## Úvod

# Morfologická rovina

1

Úvod

2

Tokenizace

3

Morfologická rovina

4

Lexikální rovina

# Morfologická rovina

- druhé patro v překladovém trojúhelníku
- je nutné eliminovat obrovský počet slovních variant
- převod slovní formy na základní tvar  
*give, gives, gave, given, giving* → *give*  
*dělá, dělám, dělal, dělaje, dělejme, ...* → *dělat*
- analýza gramatických kategorií slovních tvarů  
*dělali* → *dělat + minulost + průběh + plurál + 3. osoba*  
*did* → *do + minulost + dokonavost + osoba ? + číslo ?*  
*Robertovým* → *Robert + pád ? + adjektivum + číslo ?*

## Morfologická analýza

# Morfologická analýza

- pro každé slovo získáme základní tvar, gramatické kategorie, případně segmentaci
- Co je to základní slovní tvar? Lemma.
- jména: singulár, nominativ, positiv, maskulinum
- *bycha* → bych?, *nejpomalejšími* → pomalý  
*neschopný* → schopný?
- slovesa: infinitiv
- *nerad'* → radit?, *bojím se* → bát (se)
- Proč infinitiv? nejčastější tvar slovesa
- lemma souvisí s rozsahem/obsahem použitého slovníku

## Morfologická analýza

# Morfologické značky, tagset

- silně závislé na jazyce (různé morfologické kategorie)
- brněnský atributový systém: dvojice kategorie-hodnota  
*maminkou* → k1gFnSc7  
*udělány* → k5eAaPmNgFnP
- pražský poziční systém: 16 pevných pozic  
*kontury* → NNFP1-----A----  
*zdají* → VB-P---3P-AA---
- Treebank tagset (angličtina): omezená množina značek  
*faster* → RBR  
*doing* → VBG
- a další (němčina)  
*gigantische* → ADJA.ADJA.Pos.Acc.Sg.Fem  
*erreicht* → VVPP.VPP.Full.Psp

# Problém s víceznačností

- v mnoha případech: více morfologických značek
- víceznačnost mezi slovními druhy (více lemmat)  
*jednou* → k4gFnSc7, k6eAd1, k9  
*ženu* → k1gFnSc4, k5eAaImIp1nS
- víceznačnost v rámci slovního druhu
- typicky (čeština): nominativ = akuzativ  
*víno* → k1gNnSc1, k1gNnSc4, ...  
*odhalení* → 10 značek

## Morfologická disambiguace

- nutno vybrat *jednu* značku a *jedno* lemma
- ke slovu přichází *morfologická disambiguace*
- nástroj *tagger*
- překladová víceznačnost je něco jiného  
*pubblico* → *Öffentlichkeit*, *Publikum*, *Zuschauer*
- drtivá většina metod využívá kontext
- okolní slova a jejich značky

# Statistická disambiguace

- nejpravděpodobnější posloupnost značek  
*Ženu je domů.*  
k5|k1, k3|k5, k6|k1  
*Mladé muže*  
gF|gM, nS|nP
- těžká situace: *dítě škádlí lvíče*
- strojové učení na ručně značkovaných datech
- různé metody: Brill, TreeTagger
- pro češtinu: Desamb (hybridní)
- je nutné mít k dispozici trénovací data (korpus)

# Pravidlová disambiguace

- pokud není k dispozici anotovaný korpus – nutné
- pravidla vyžadují dobrou znalost jazyka
- většinou se používá jako filtr před použitím statistického taggeru
- pravidla mohou zachytit širší kontext
- typicky: shoda v pádu, čísle a rodu ve jmenných frázích  
*malému* (c3, gIMN) *chlapci* (nPc157, nSc36, gM)
- sofistikovanější: valenční struktura věty  
valence: *vidět koho/co*  
*vidím stůl* → c4
- systémy DIS, VaDIS

## Morfologická segmentace

# Morfologická segmentace

- proč místo lemmatu (např. infinitiv) nepoužít kořen slova?
- existují i systémy, které provádí segmentaci automaticky na základě seznamu slov pro daný jazyk
- problém: *mít, měj, mám, měl, mívá, ...* – různé podoby téhož morfému
- problém: *i, ové, a, y* – stejná gramatická funkce, různé morfemy
- *bychom* → bych?
- gramatické kategorie mají konkrétní formu (gramémy)  
*nad-měr-ný, ne-patr(n)-ně, vid-ím, ne-chci, čtyř-i-cet, po-po-sun-out, u-děl-al-i*
- nutné pokud nemáme morfológický analyzátor k dispozici

## Morfologie – závěrem

slovo	analýzy	disambiguace
Pravidelné	k2eAgMnPc4d1, k2eAgInPc1d1, k2eAgInPc4d1, k2eAgInPc5d1, k2eAgFnSc2d1, k2eAgFnSc3d1, k2eAgFnSc6d1, k2eAgFnPc1d1, k2eAgFnPc4d1, k2eAgFnPc5d1, k2eAgNnSc1d1, k2eAgNnSc4d1, k2eAgNnSc5d1, ... (+ 5)	k2eAgNnSc1d1
krmení	k2eAgMnPc1d1, k2eAgMnPc5d1, k1gNnSc1, k1gNnSc4, k1gNnSc5, k1gNnSc6, k1gNnSc3, k1gNnSc2, k1gNnPc2, k1gNnPc1, k1gNnPc4, k1gNnPc5	k1gNnSc1
je	k5eAalmP3nS, k3p3gMnPc4, k3p3gInPc4, k3p3gNnSc4, k3p3gNnPc4, k3p3gFnPc4, k0	k5eAalmP3nS
pro	k7c4	k7c4
správný	k2eAgMnSc1d1, k2eAgMnSc5d1, k2eAgInSc1d1, k2eAgInSc4d1, k2eAgInSc5d1, ... (+ 18)	k2eAgInSc4d1
růst	k5eAalmF, k1glnSc1, k1glnSc4	k1glnSc4
důležité	k2eAgMnPc4d1, k2eAgInPc1d1, k2eAgInPc4d1, k2eAgInPc5d1, k2eAgFnSc2d1, k2eAgFnSc3d1, k2eAgFnSc6d1, k2eAgFnPc1d1, k2eAgFnPc4d1, k2eAgFnPc5d1, k2eAgNnSc1d1, k2eAgNnSc4d1, k2eAgNnSc5d1, ... (+ 5)	k2eAgNnSc1d1

# Universal POS tags

Počet značek se v různých jazycích značně liší → snaha o zjednodušení.

<b>TAG</b>	<b>význam</b>
VERB	verbs (all tenses and modes)
NOUN	nouns (common and proper)
PRON	pronouns
ADJ	adjectives
ADV	adverbs
ADP	adpositions (prepositions and postpositions)
CONJ	conjunctions
DET	determiners
NUM	cardinal numbers
PRT	particles or other function words
X	other: foreign words, typos, abbreviations
.	punctuation

Morfologie – závěrem

# Odhadování POS na základě gramémů

EN	CZ	význam
-s	-á	3. os., j. č., přít.
-ed	-al, -l, -en.	minulý čas
-ing	-(ov)ání	průběhový čas
-en	-en(.)	příčestí minulé
-s	-y, -i, -ové, -a	množné číslo
's	ov(o, a, y)	přivlastňování
-er	-ší	komparativ
-est	nej-, -ší	superlativ

Problém: *myší, west, fotbal, ...*

Morfologie – závěrem

## Tomáš Hanák – Sám v lese II

Když jsi sám v lese,  
ano, sám-li v lese's,  
však skutečně, v lese sám's-li.  
Zkrátka v lese sám-li's.

Však kde vlastně vzal ty tu's?  
Z meze-li v les's vlez?  
Či z nebes v les se snesl's?

Pověz, ach, tvář tvá perlí přívalem se slz.  
Teď rud's, zas bled's, co pivoňka's  
Snad tedy autem's tu, či kolmo's?

Mlčíš a slza tvá dál  
sama malá padá v mechu číš.

Ano, teď teprve snad poprvé sám svět's.

## Morfologie – závěrem

# Brillův tagger

- učení z trénovacích dat
  - transformation-based, error-driven
  - úspěšnost přes 90 %
- 
- ➊ inicializuj značkování (nejčastější značka)
  - ➋ porovnej s trénovacími daty
  - ➌ vytvoř sadu pravidel pro změnu značek
  - ➍ ohodnot' pravidla
  - ➎ aplikuj pravidlo a opakuj od 2. dokud je co zlepšovat

## Morfologie – závěrem

# Problémy s POS

- kvalita MA ovlivňuje všechny další roviny zpracování
- kvalita se liší pro různé jazyky (angličtina vs. maďarština)
- **chončaam** (tj) – můj malý dům (domek) (tádžičtina)
- **kahramoni** (tj) – jsi hrdina
- **legeslegmagasabb** (hu) – úplně nejvyšší
- **raněný** – SUBS / ADJ
- the big red **fire** truck – SUBS / ADJ?
- The Duchess was **entertaining** last night.
- Pokojem se neslo tiché **pšššš**

# Co s neznámými slovy?

- jde nám o *pokrytí*: analýza co nejvíce slov
- nová, přejatá slova
- řeší *guesser*
- sedm **dunhillék**
- bez **facebooku** strádám
- **třitisícedvěstědevadesátpět** znaků

## Morfologie – závěrem

# Morfologie – shrnutí

- první rovina, která zanáší do analýzy významné chyby
- snaha omezit počet slovních tvarů
- nahrazení slovního tvaru za dvojici **lemma + značka**
- pro angličtinu s 36 značkami snadné
- POS tagging dosahuje pro různé jazyky různé kvality
- typicky kolem 95 %

Úvod

# Slova a slovníky ve strojovém překladu

- 1 Úvod
- 2 Tokenizace
- 3 Morfologická rovina
- 4 Lexikální rovina

# Slovníky ve strojovém překladu I

- propojení mezi jazyky typicky na úrovni slov (slovníky)
- u transferových systémů i na úrovni syntaktických struktur
- pro KBMT systémy jsou slovníky nezbytné
- typicky 10k a více položek
- GNU-FDL slovník

Slovníky ve strojovém překladu III

- kolik položek ve slovníku potřebujeme / chceme?
    - pojmenované entity, slang
  - listém* – jazyková položka, kterou nelze odvodit na základě principu kompozicionality (*slaměný vdovec*)
  - v jakém tvaru mají být slova ve slovníku?
    - lemmatizace
  - jak odlišit jednotlivé významy pro potřeby strojového překladu?
    - budování slovníků pro strojový překlad
  - kolik různých významů má smysl rozlišovat?
    - granularita

# Problém s víceznačností

- slovům odpovídají významy
- co je ale význam? pro počítač potřebujeme formální popis
- počítač je diskrétní, význam je zřejmě spojitý
- *muž* – dospělý člověk mužského pohlaví
- co 17letý člověk mužského pohlaví?

## Víceznačnost

# Spojitost významu



špalek



?



židle

# Typy víceznačnosti

Víceznačnost se projevuje na více úrovních:

- morfologie (-s, viz výše)
- slova (oko)
- slovní spojení (bílá vrána)
- věty (I saw a man with a telescope.)
  
- homonymie: náhodný jev
  - úplná homonymie: líčit, kolej
  - částečná h.: los, stát
- polysémie je přirozená: oko, táhnout, ...

# Granularita

Kolik významů má slovo *kočka*?

- malá kočkovitá šelma chovaná v domácnostech
- malá nebo středně velká šelma s hustým kožichem
- samice kočkovité šelmy
- kožešina na límci, kolem krku nebo ramen
- kocovina
- věc připomínající vlastnost kočky
- druh důtek

Pro strojový překlad může stačit granularita překladového slovníku: slovo *x* má tolik významů jako má překladových ekvivalentů ve slovníku.

# Granularita – oko

oko

- zrakový orgán
- klička, smyčka, kroužek z různého materiálu
- věc připomínající tvarem oko (morské oko)
- jednotka v kartách, loterii
- druh karetní hry

# Granularita – dát, SSJČ

dát (bez *se*)

- odevzdat do vlastictví, darovat, prodat
- vyžádat, způsobit (dá to mnoho práce)
- umístění něčeho
- doprát, dovolit, připustit (nedej pane)
- projevit nedostatek odporu (dát se ošidit)
- přikázat (dát něco udělat)

VerbaLex uvádí 32 (!) významů (nezvratné varianty).

# Granularita – malý

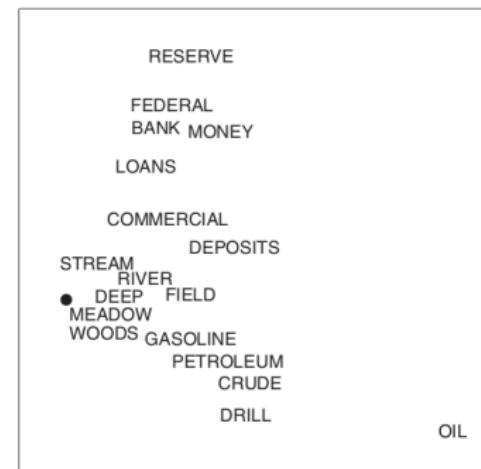
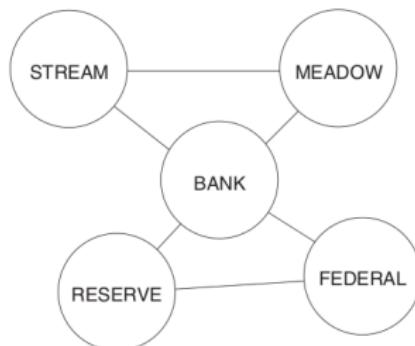
malý, malá

- neveliký rozměry, počtem, časovým rozsahem
- nedospělý
- slabý, nevydatný (malý rozhled)
- nevýznamný (malý pán)
- téměř (malý zázrak)
- děvčátko (malá)
- přihrávka vlastnímu brankáři (malá domů)

## Reprezentace významu

# Reprezentace významu

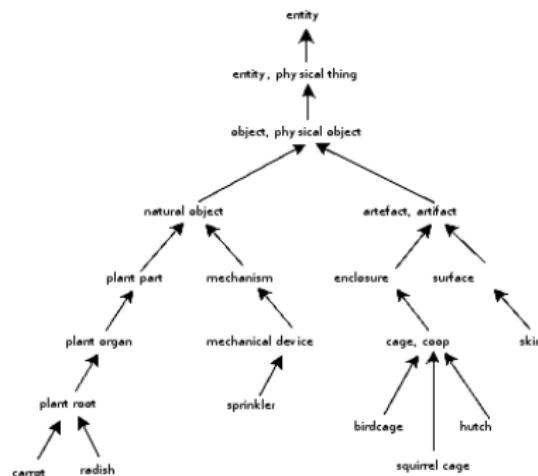
- nejčastější způsob: banka významů
- graf: významy jsou uzly, sémantické relace jsou hrany
- prostor: významy jsou body, podobné významy jsou prostorově blízko



## Reprezentace významu

## Sémantická síť – WordNet

- **literál** dát:8, **synset** louže:1, kaluž:1, tratoliště:1
- sémantické relace: hypero-, hypo-, holo-, meronymum
- 150k slov, 117k synsetů: n, adj, v a adv
- WN používán jako referenční banka významů



# VerbaLex

- WordNet neobsahuje syntaktické vazby, morfosyntaktické omezení
- synsety (6 256)  
atakovat:1, útočit:2, dorážet:3, napadnout:6
- valenční rámce (mačkat:1) a sloty (19 247)  
 $AG_{person:1}^{kdo1} + VERB + OBJ_{object:1}^{co4} + (PART_{hand:1}^V \ čem^6)$
- sémantické role
  - I: ABS, ISUB, AG, KNOW, PAT, VERB, ... (29)
  - II: abstraction:1, person:1, artifact:1, body part:1, ... ( $10^3$ )
- další omezení:  
předložkové pády, životnost, slovní druhy, obligatornost
- synsety napojeny na WordNet