

Organizace předmětu IB030

Úvod do počítačové lingvistiky

Aleš Horák

E-mail: hales@fi.muni.cz
http://nlp.fi.muni.cz/poc_lingv/

Obsah:

- ▶ Organizace předmětu IB030
- ▶ Počítačová lingvistika
- ▶ Situace na FI MU

Hodnocení předmětu:

- ▶ závěrečná písemka (max 80 bodů)
 - dva řádky a jeden opravný termín
- ▶ průběžný úkol (max 20 bodů)
- ▶ hodnocení – součet bodů za písemku i úkol (max 100 bodů)
- ▶ rozdíly **zk**, **k**, **z** – různé limity
např.:

| | |
|---|----------|
| A | 80 – 100 |
| B | 73 – 79 |
| C | 65 – 72 |
| D | 58 – 64 |
| E | 50 – 57 |
| F | 0 – 49 |

| | |
|---|----------|
| K | 45 – 100 |
| Z | 40 – 100 |

Základní informace

- ▶ přednáška je nepovinná
- ▶ cvičení – občas doporučené malé úkoly
- ▶ jeden hodnocený úkol (viz další slajd)
- ▶ web předmětu – http://nlp.fi.muni.cz/poc_lingv/
- ▶ slajdy – průběžně doplňovány na webu předmětu
- ▶ kontakt na přednášejícího – Aleš Horák <hales@fi.muni.cz>
(Subject: IB030 ...)

Samostatný hodnocený úkol

- ▶ letošní úkol – použít některou z dostupných **jazykových knihoven pro češtinu**:
 - [NLTK – Natural Language Toolkit](http://nltk.sourceforge.net) <http://nltk.sourceforge.net>
 - [Field Linguist's Toolbox](http://alphaworks.ibm.com/tech/lrw) <http://alphaworks.ibm.com/tech/lrw>
 - [FreeLing](http://www.lsi.upc.es/~nlp/freeling) <http://www.lsi.upc.es/~nlp/freeling>
 - [Stanford University Natural Language Software](http://nlp.stanford.edu/software/) <http://nlp.stanford.edu/software/>
 - [IBM LanguageWare Resource Workbench](http://www.sil.org/computing/toolbox/) <http://www.sil.org/computing/toolbox/>
- ▶ k **odevzdání** je zapotřebí:
 - naprogramovaný vybraný algoritmus na češtině
 - dokumentace programu s ukázkami a návodem na instalaci/spuštění na serveru aurora.fi.muni.cz
 - vše odeslat v komprimovaném archivu e-mailem přednášejícímu
(Subject: IB030 – odevzdani ukolu) do **26. května 2008**
- ▶ **hodnocení** bude od 0 do 20 bodů podle:
 - složitosti vybraného algoritmu
 - kvality zpracování algoritmu i dokumentace

Literatura



Pala, Karel: **Počítačové zpracování přirozeného jazyka**, Brno FI MU, 2000. 190 s.



Allen, James: **Natural language understanding**, Redwood : Benjamin/Cummings Publishing, 1995, 654 s.



The Oxford handbook of computational linguistics, ed. by Ruslan Mitkov. Oxford University Press, 2003, 784 s.



Chomsky, Noam: **Syntaktické struktury**, Praha : Academia, 1966. 209 s.



Materna, Pavel - Štěpán, Jan: **Filozofická logika: nová cesta?**, Olomouc (Univerzita Palackého), 2000. 127 s.

[slajdy na webu předmětu](#)

Úvod do počítačové lingvistiky 1/11

5 / 14

Počítačová lingvistika

Náplň předmětu

- ▶ počítačové zpracování přirozeného jazyka (*Natural Language Processing, NLP*)
- ▶ roviny jazyka
- ▶ reprezentace morfologických a syntaktických struktur
- ▶ analýza a syntéza: morfologická, syntaktická, sémantická
- ▶ formy reprezentace znalostí o lexikálních jednotkách
- ▶ porozumění jazyku: reprezentace významu věty, inference a reprezentace znalostí

Co je "počítačová lingvistika"

Lingvistika:

- ▶ **jazykověda** (*lingua* = lat. *jazyk*)
- ▶ věda o jazyčích, jejich třídění, stavbě, zvukové i psané podobě
- ▶ zkoumá strukturu jazyka – slovotvorba, kombinace slov do vět, význam věty, ...

Počítačová lingvistika:

- ▶ od 60. let, *Computational linguistics*, často **NLP** (*Natural Language Processing*)
- ▶ spojení **umělé inteligence** (informatiky) a **lingvistiky** – jako jedna z **kognitivních věd**
- ▶ zkoumá problémy **analýzy** či **generování** textů nebo mluveného slova, které vyžadují určitou (ne absolutní) míru porozumění přirozenému jazyku strojem.
- ▶ tvoří **jazykové modely** – pojmy **algoritmus**, **datová struktura**, **(formální) gramatika**, ...

Úvod do počítačové lingvistiky 1/11

6 / 14

Počítačová lingvistika Historie počítačové lingvistiky

Turingův test

- ▶ z roku 1950, založen na tzv. **imitační hře**
- ▶ úkol – **program komunikující jako člověk**
- ▶ zahrnuje:
 - zpracování přirozeného jazyka (NLP)
 - reprezentaci znalostí (KRepresentation)
 - vyvozování znalostí (KReasoning)
 - strojové učení
 - (počítačové) vidění
 - (robotiku)
- ▶ od 1991 – **Loebnerova cena** (*Loebner Prize*) → každý rok \$3.000 za "nejlidštější" program, nabízí \$100.000 a zlatá medaile za složení celého Turingova testu



Úvod do počítačové lingvistiky 1/11

7 / 14

Úvod do počítačové lingvistiky 1/11

8 / 14

Eliza, Parry, ...

- ▶ **Eliza** – Joseph Weizenbaum, MIT, 1964–66
- ▶ program napodobující chování psychoterapeuta:

young woman: *Men are all alike.*
 eliza: *In what way?*
 young woman: *They're always bugging us about something.*
 eliza: *Can you think of a specific example?*
 young woman: *Well, my boyfriend made me come here.*
 eliza: *Your boyfriend made you come here?*
 young woman: *He says I'm depressed much of the time.*
 eliza: *I am sorry to hear you are depressed.*
 young woman: *It's true. I'm unhappy.*

- ▶ **Parry** (Kenneth Colby, 70. léta), protějšek Elizy – počítačová simulace pacienta postiženého paranoiou
- ▶ oba využívají spíš "triky" než analýzu
- ▶ praktický význam – tzv. **expertní systémy**

Historie počítačové lingvistiky

- ▶ 1957 – rusko-anglický překlad
- ▶ Chomsky (60. léta) – generativní gramatika, vrozenost jazyka, ...
- ▶ strojový překlad není ani dnes dokonalý – potřebuje porozumět obsahu textu (Paretův zákon – pravidlo 80/20)
- ▶ problémy – víceznačnost, množství významů slov, různé způsoby užití slov k vyjádření významu, "Commonsense" a lidské uvažování
- ▶ Robert Wilensky: NLP je "AI-complete"
- ▶ 80. a 90. léta – rozvoj formalismů pro syntaktickou analýzu PJ (LFG, LTAG, HPSG)
- ▶ současně – zkoumání kvality statistických metod s rozsáhlými daty → srovnatelné výsledky!
- ▶ 90. léta až 200x – tvorba zdrojů vyšší úrovně (syntakticko-sémantické lexikony, wordnety, ...)
- ▶ stále není na obzoru splnění Turingova testu

Cíle počítačové lingvistiky

Významné úkoly v NLP:

- ▶ analýza přirozeného jazyka – morfologická, syntaktická, sémantická
- ▶ generování přirozeného jazyka
- ▶ syntéza a rozpoznávání řeči
- ▶ strojový překlad (*Machine translation*)
- ▶ odpovídání na otázky (*Question answering*)
- ▶ získávání informací (*Information retrieval*)
- ▶ korektura textu (*Spell-checking, Grammar checking*)
- ▶ extrakce informací (*Information extraction*)
- ▶ výtah z textu (*Text summarization*)
- ▶ určení typu dokumentu (*Text Classification/Clustering*)

Přednášky se vztahem k NLP na FI MU

- ▶ specializace **Zpracování přirozeného jazyka**, obor **Umělá inteligence a zpracování přirozeného jazyka**
- ▶ certifikát **Euromasters in Speech and Linguistics**
- ▶ vybrané přednášky:

| | | |
|-------|---|-----------------|
| IBO30 | Úvod do počítačové lingvistiky | Horák |
| IBO47 | Úvod do korpusové lingvistiky a počítačové lexikografie | Pala, Rychlý |
| IV029 | Logická analýza přirozeného jazyka | Materna |
| PB016 | Úvod do umělé inteligence | Horák |
| PB125 | Řečová komunikace a dialogové systémy | Bártek, Kopeček |
| PV056 | Vyhledávání znalostí v databázích | Popelinský |
| PV122 | Formální struktura přirozeného jazyka | Peňáz |

NLP lab – laboratoř ZPJ na FI MU

- ▶ sdružení lidí (studentů Bc., Mgr. a PGS i zaměstnanců) z oblasti NLP
- ▶ webový server nlp.fi.muni.cz
- ▶ fyzicky – 2 "skleníky" ve 2. patře budovy B:
 - 2 místnosti NLP – [laboratoře zpracování přirozeného jazyka](#) (doc. Pala)
 - část B203 pro LSD – [laboratoř vyhledávání a dialogu](#) (doc. Kopeček, prof. Zezula)
- ▶ vlastní laboratorní servery a stanice s OS Linux
- ▶ řeší několik velkých grantových projektů, pořádá [mezinárodní konference](#) (TSD, GWC, Lexicom, ...)
- ▶ práce studentů:
 - "malé projekty," které se využijí v rámci "velkých projektů"
 - bakalářské, diplomové i disertační práce
 - někdy i zaměstnanecký poměr
- ▶ **PV173 Seminář Laboratoře zpracování přirozeného jazyka** – pravidelná společná výměna informací

NLP projekty a SW na FI MU

Vybrané projekty:

- ▶ [ajka](#) – morfologický analyzátor
- ▶ [i.par](#) – editor morfologické databáze
- ▶ [synt, klara, zuzana](#) – syntaktické (a logický) analyzátor
- ▶ [GDW](#) (Grammar Development Workbench) – GUI pro vývoj gramatiky
- ▶ [VisDic](#) – editor wordnetů
- ▶ [DEB](#) – platforma pro XML databáze
- ▶ [VerbaLex](#) – slovník slovesných valencí
- ▶ [bonito, manatee, Word Sketches](#) – korpusový manažer
- ▶ [demosthenes, text2phone \(mbrola\)](#) – syntetizátory řeči
- ▶ [UIO](#) – inteligenční odpovídáč
- ▶ [Visual Browser](#) – grafické znázornění (sémantických) sítí
- ▶ korpusy, slovníky, encyklopédie, ...

Struktura jazyka

Roviny analýzy jazyka. Fonetika

Aleš Horák

E-mail: hales@fi.muni.cz
http://nlp.fi.muni.cz/poc_lingv/

Obsah:

- ▶ Roviny analýzy jazyka
- ▶ Fonetika a fonologie

Roviny analýzy jazyka

znalosti struktury jazyka jsou propojeny **hierarchicky**

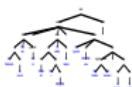


Roviny analýzy jazyka – pokrač.

- ▶ **fonetická** – postihuje vztahy mezi zvuky používanými v (mluveném) jazyce, jejich skládání do slabik a slov
- ▶ **foném** – nejmenší jednotka jazyka, která může **odlišit** význam nadřazených jednotek
kosit/nosit fonémy *k* a *n* odlišují dvě slova
- ▶ **často odpovídají znakům** → vždy ale označují **zvuky**
- ▶ **morfologická** – interní struktura slov, skládání slov z menších jednotek
- ▶ **morfém** – nejmenší jednotka, která může **nést** význam
pří-lež-it- *pří* – prefix (*blízko*)
-ost-n-ými: *lež* – lexikální kořen (*ležet*)
it – adjektivní derivační sufix (*ten, který*)
ost – substantivní derivační sufix (*ta skutečnost, že*)
n – adjektivní derivační sufix (*charakteristický pro*)
ými – gramatický afix (*instrumentál plurálu*)

Roviny analýzy jazyka – pokrač.

- ▶ **syntaktická** – struktura větných frází
popisuje, jak vypadá **gramaticky správná věta**, většinou pomocí **pravidel gramatiky**
- syntaktický analyzátor** – nástroj, který analyzuje vstup na základě gramatiky na výstup dává různé info, např. derivační stromy
- ▶ **sémantická** – význam výrazů přirozeného jazyka a jejich kombinací hodně závisí na zvolené **sémantické reprezentaci**
logická analýza věty – strukturní část sémantické analýzy
- ▶ **pragmatická** – zkoumá vztah mezi výrazy přirozeného jazyka a **kontextem**
často se do ní řadí znalost **komunikační situace, základní ontologie** a **jazykových metaznalostí**



Fonetika a fonologie

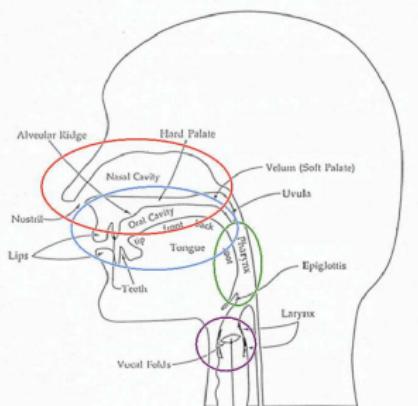
Fonetika:

- ▶ studuje **produkci, přenos a příjem** jazykových zvuků
- ▶ má klíčový význam např. pro oblast automatického **rozpoznávání a syntézy řeči**
- ▶ není tradičně chápána jako součást gramatiky jazyka

Fonologie:

- ▶ **fonologický systém** jazykových zvuků v *určitém jazyce*
- ▶ pracuje s **gramatikou** řečových zvuků
- ▶ pomocí gramatických pravidel popisuje historické změny i současné alternace

Kde vznikají jazykové zvuky?



Členění řečového proudu

Řečový proud:

- ▶ nejsou mezery mezi slovy
- ▶ nejsou žádné izolované zvuky
- ▶ přesto všechny jazyky pracují s lingvistickými jednotkami jako separátními

orofón – fráze, které zní stejně/podobně, ale mají jiný obsah

It's not easy to recognize speech.

It's not easy to wreck a nice beach.

Fonetické jednotky

► foném (phoneme)

- základní jednotka **zvukového systému** jazyka
- foném je *abstraktní věc*, koncretizuje se pomocí fónů (viz dále)
- např. v češtině – 37 fonémů:
 - a, a:, b, ts, tS, d, d', dz, dZ, e, e:, f, g, h\, x, i, i:, j, k, l, m, n, n', o, o:, p, r, r', s, S, t, t', u, u:, v, z, Z

► fón (phone)

- **čečový zvuk** z hlediska jeho **fyzikálních charakteristik** (zvuková vlna určitého tvaru)
- bez zařazení k zvukovému systému jazyka
- jeden **foném odpovídá množině fónů**
- **alofón** určitého fonému = jeden z množiny fónů tohoto fonému např. nosit, banka

Fonetická transkripcie

- jeden z nejpoužívanějších **nástrojů fonetiky**
- **převod čečového proudu do oddělených, lingvisticky významných symbolických jednotek**
- používá se standardních **fonetických abeced** (viz dále)
- **široká** × **úzká** (broad/narrow) transkripcie = převod do **fonémů/fónů**
- důvody pro tento převod:
 - nedostatečnost písmenného zápisu
 - jedno písmeno → různý zvuk vypít [v] / vpusit [f]
 - jeden zvuk → různá písmena chovat [x] / shánět [χ]
 - mezijsazkové variace v písmenném zápisu
 - 'k' → 'c' v latinském canis, 'ch' v italském Chianti
 - 'č' → 'ch' v anglickém cheat, 'ci' v italském ciao
 - jeden foném může být zaznamenán více písmeny
 - např. 'f': → 'f' v českém *fyzika*
 - 'gh' v anglickém *laugh*
 - 'ph' v řeckém *philosophia*

Fonetické abecedy IPA a SAMPA

IPA:

- *International Phonetic Alphabet*
- vznikl v roce 1886 v Paríži, od té doby mnoho revizí (poslední 1996)
- speciální znak pro vyjádření každého fónu
- mezinárodní **standardní zápis** – jsou k dispozici tabulky a fonty
- *Unicode* – speciální IPA znaky v rozsahu U+0250–02AD

SAMPA:

- *Speech Assessment Methods Phonetic Alphabet*
- vznikl v projektu SAM (Speech Assessment Methods) v letech 1987–89
- **strojově čitelná** fonetická abeceda
- <http://www.phon.ucl.ac.uk/home/sampa/>

IPA – souhlásky

v americké angličtině

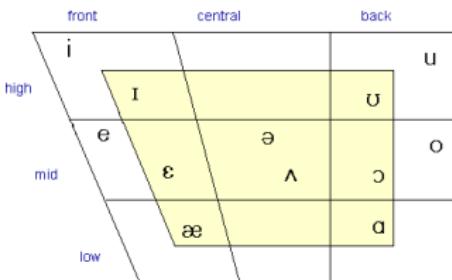
| | labial | labio-dental | interdental | alveolar | palatal | velar | glottal |
|---------------------------|--------|--------------|-------------|----------|----------|--------|---------|
| stops | p b | | | t d | | k g | |
| fricatives | | f v | θ ð | s z | ʃ ʒ | | h |
| affricates | | | | | tʃ dʒ | | |
| nasals | m | | | n | | ŋ | |
| liquids lateral retroflex | w | | | l | r | | |
| glides | | | | | j | | |

IPA – souhlásky ve slovech

- p plate, piece, spin, capital, stop, trap
- t trip, time, winter, retire, wait, front
- k kité, climb, character, rocket, back, sink
- b bill, brush, sober, ramble, sob, bulb
- d dark, drive, redder, ponder, head, hard
- g go, grease, rigor, anger, log, iceberg
- m man, mle, remorse, ample, climb, harm
- n nice, know, enough, cunning, sign, burn
- t finger, singer, drunk, rang, thing
- θ thank, three, ether, panther, path, birth
- ð then, these, feather, breathe
- f fit, fly, effort, perform, enough, Ralph
- v very, yew, every, prevail, love, starye

IPA – samohlásky

v americké angličtině

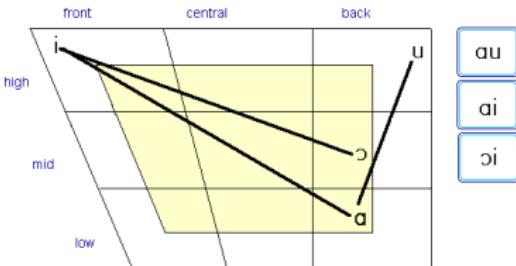


IPA – samohlásky ve slovech

- i heed, beat, believe, people, scary
- I hid, bit, injure, resist, finish
- e hate, bait, great, they, say, neighbor
- ɛ head, bet, friend, says, guest
- æ had, bat, laugh, calf, language
- ə above, ground, sofa, police
- ʌ bus, rush, under, gther
- ʊ food, boot, pool, through, who, sewer
- ɔ hood, book, yell, put, would
- ə hole, boat, sew, know, so
- ɔ bought, law, wrong, stalk
- ɑ pot, "la", stocking, father, rob

IPA – dvojhlásky

v americké angličtině



ai find, high, aisle, quiet, ride

au house, crown, around, flower, how

ɔɪ boy, enjoy, Freud, avoid, join

Prozodie

- ▶ tzv. **suprasegmentální rysy**
- ▶ popisuje řečový proud spolu s přepisem do fonémů
- ▶ vyjádřena pomocí dalších **lokálních fyzikálních charakteristik** výsledné zvukové vlny:
 - délka fonému
 - intonace věty – vzor pro hladinu **základní frekvence** (*pitch*)
 - tón – v některých (tzv. **tónových**) jazyčích určuje význam
 - přízvuk – v **přízvukových jazyčích** ovlivňuje délku, hlasitost a tón slov
- ▶ kvalitní výpočet prozodie = **přirozenost** syntetizované řeči

Text-to-Speech systémy

- ▶ **syntéza řeči** – převod psaného textu na (digitální) zvuk
- ▶ **TTS, Text-to-Speech**
- ▶ dvě hlavní části
 1. **jazykový modul**, NLP modul
 - vstup = text
 - výstup = fonémy + prozodická informace označována také jako TTP, *Text-to-Phoneme*
 2. **modul zpracování signálu**, DSP (Digital Signal Processing) modul
 - vstup = výstup z NLP modulu
 - výstup = zvukový soubor

Příklady dat pro českou syntézu s MBROLA

- ▶ pravidla pro přepis do fonémů

```

CLASS SA   [aáéééííóóúúýý]  # samohlásky
CLASS ZPS  [bdd'gvzzhČČ]    # znělé párové souhlásky
CLASS NPS  [ptt'kfssHcčč]   # neznělé párové souhlásky
[[ dě ]] → d' e
[[ b ]] (.|NPS|ZPS.) → p
[[ p ]] ZPS → b
  
```

- ▶ vstup pro MBROLU – text "shání tě též muž"

| | | |
|-------------|-------------|------------|
| - 200 0 132 | i: 93 0 114 | S 81 0 114 |
| z 57 0 115 | t' 27 0 120 | m 43 0 120 |
| h 45 | e 50 0 114 | u 61 |
| a: 137 | t 31 0 120 | S 110 |
| n' 75 0 132 | e: 102 | # |

- ▶ zvuková databáze cz2 – 37 fonémů, 1442 difónů
nutné ručně "nařezat" všechny difóny

Příklady TTS systémů

- ▶ české
 - **Epos** – z 90. let, Karlova univerzita a ČAV, nejlepší český open source slabiková syntéza, základní prozodie
 - **Demosthenes** – FI MU Brno, laboratoř LSD
 - **ARTIC** (ARTificial Talker In Czech) – ZČU Plzeň, **DEMO** obsahuje i "Talking head" vizuální část
 - **CS-Voice 97** – komerční, Frog Systems, pro Windows
- ▶ zahraniční
 - **Festival** – z Edinburghu, GPL, hodně jazyků, projekt Festival Czech
 - **MBROLA** – difónová syntéza MBR-PSOLA, řeší DSP část Mikuláš Piňos, DP 2000 – česká DB pro MBROLU, *text2phone* v Perlu
 - mnohé další – **HADIFIX**, **SVOX**, Bell Labs, **AT&T**, ...

Syntéza řeči

Syntéza a rozpoznávání řeči

Pavel Cenek, Aleš Horák

E-mail: hales@fi.muni.cz
http://nlp.fi.muni.cz/poc_lingv/

Obsah:

- ▶ Syntéza řeči
- ▶ Rozpoznávání řeči
- ▶ Související technologie

- ▶ Text to Speech, TTS
- ▶ Konverze textu do mluvené podoby
- ▶ V ideálním případě by měla syntetizovaná řeč znít tak, jako kdyby daný text přečetl člověk
- ▶ Probíhá obvykle ve 4 fázích
 - Normalizace textu
 - Fonetický přepis
 - Prozodický přepis
 - Akustické modelování

Normalizace textu

- ▶ Rozčlenění textu na věty
- ▶ Rozvinutí zkratek, měrných jednotek, čísel apod.

"130895" {

- číslo
- telefonní číslo
- datum
- ...

Fonetický přepis

- ▶ Převede předzpracovaný text do fonetické podoby (tj. do tvaru, který popisuje výslovnost daného textu)
- ▶ Mezinárodní fonetická abeceda (IPA) – v češtině cca 40 fonémů
- ▶ Fonetický přepis češtiny musí zohlednit např.
 - Spodoba znělosti (**včela/fčela, dub/dup**)
 - Krajevé zvuky (např. **shoda/zhoda** nebo **schoda**).
- ▶ Problémy přináší přepis cizích vlastních jmen a cizích slov obecně (např. **faux pas** nebo francouzská vlastní jména)
- ▶ Dvě základní metody
 - Fonetický přepis založený na pravidlech (např. pro češtinu funguje dobré)
 - Fonetický přepis pomocí výslovnostních lexikonů
- ▶ Obě metody lze kombinovat

Prozodický přepis

- ▶ Prozodie je důležitá pro **přirozenost řeči**, ale např. u *tonálních jazyků* silně ovlivní i porozumění
- ▶ Obohacení textu o informace (viz SSML dále), které zajistí, že výsledná řeč bude znít přirozeně
- ▶ Zejména popis intonace, tempa řeči, pauz a informace o lexikálním přízvuku
- ▶ Emoce
 - člověk je při projevu používá
 - výzkum syntézy s emocemi je o dost složitější

Speech Synthesis Markup Language (SSML)

- ▶ Doporučení W3C (jako HTML, XML, ...) – standardní způsob pro doplnění fonetiky a prozodie do textu
- ▶ Pokrývá první 3 fáze syntézy řeči (normalizace, fonetický přepis, prozodie)
- ▶ **<say-as>** – explicitní určení typu dat (viz Normalizace)
- ▶ **<phoneme>** – fonetický přepis textu
- ▶ **<voice>** – změna hlasu (atributy *věk*, *muž*/*žena*, ...)
- ▶ **<emphasis>** – přidání/odebrání důrazu
- ▶ **<break>** – vložení/zrušení pauzy
- ▶ **<prosody>** – ovlivnění prozodie (výška hlasu, kontura, rychlosť, hlasitost atd.)

Speech Synthesis Markup Language (SSML) – příklad

```
<?xml version="1.0" encoding="UTF-8"?>
<vxml version="2.0" xmlns="http://www.w3.org/2001/vxml">
<form>
<block>
<prompt>
  <voice gender="male"><emphasis>Hello</emphasis> Jane.</voice>
  <voice gender="female"><emphasis>Hello</emphasis> Mike,
    how <emphasis>are</emphasis> you?</voice>
  <voice gender="male">I am fine. And how are
    <emphasis>you</emphasis> Jane?</voice>
  <voice gender="female">Not bad.</voice>
  <voice gender="male">OK, Goodbye.</voice>
  <voice gender="female"><emphasis>Goodbye</emphasis>
    Mike.</voice>
</prompt>
</block>
</form>
</vxml>
```

Akustické modelování

- ▶ Generování výsledného akustického signálu z předzpracovaného textu
- ▶ Dva základní přístupy
 - syntéza řeči v časové oblasti
 - syntéza řeči ve frekvenční oblasti

Syntéza řeči v časové oblasti

- ▶ = konkatenativní syntéza
- ▶ Výsledná řeč se skládá z vybraných, dopředu namluvených segmentů řeči (difónů, trifónů, slabik apod.)
- ▶ Relativně jednoduché na implementaci
- ▶ Nutnost vytvoření rozsáhlé databáze segmentů (koartikulace, např. 'á' zní jinak v tát a máma):
 - difóny – t á t a
 - trifóny – t á t a
 - kombinace – heterogenní segmenty (někdy difóny, trifóny i celá slova)
- ▶ Dochází k deformaci segmentů jejich spojováním a aplikací prozodických pravidel – "tajemství" komerčních aplikací

TTS systémy ve světě

nejčastější použití – telefonní systémy

- ▶ ©Nuance (<http://www.nuance.com/>) [+ DEMO](#)
- ▶ ©Loquendo (<http://www.loquendo.com/>) [+ DEMO](#)
- ▶ ©Acapela group (<http://www.acapela-group.com/>) [+ DEMO](#)
 - založena v roce 2004 třemi společnostmi, jedna z nich autor Mbroly
- ▶ ©IBM (<http://www.research.ibm.com/tts/>)
- ▶ ©AT&T (<http://www.research.att.com/projects/tts/>)
- ▶ Festival (<http://www.cstr.ed.ac.uk/projects/festival/>)
- ▶ Mbrola (<http://tcts.fpms.ac.be/synthesis/mbrola.html>)
- ▶ FreeTTS (<http://freetts.sourceforge.net/>)

Syntéza řeči ve frekvenční oblasti

2 hlavní přístupy:

- ▶ Modelování hlasového ústrojí
 - Generovaný zvuk závisí na parametrech tohoto hlasového ústrojí.
 - ⊕ Velká flexibilita (nový hlas lze vytvořit pouhou změnou parametrů)
 - ⊖ Veličina náročné výpočty (řeší se fyzikální rovnice modelující situaci ve vokálním traktu, diferenciální rovnice, větš. degradují na válce/koule, ale stejně moc náročné) ⇒ v praxi se téměř nepoužívá
- ▶ Formantová syntéza
 - Modelování (jen) hlavních akustických rysů řečového signálu
 - Zdroj/filtr model – zdroj generuje základní tón pro znělé části řeči a šum pro neznělé části řeči a filtry modifikují zvukové spektrum a napodobují tak hlavní funkce lidského vokálního traktu
 - Zdroj a filtr jsou řízeny množinou fonetických pravidel → syntéza založená na pravidlech
 - Lze počítat v reálném čase
 - Mnohem menší data než u konkatenativní syntézy → vhodné i pro PDA

České TTS systémy

- ▶ EPOS TTS (<http://sourceforge.net/projects/epos>) [+ DEMO](#)
 - Česká akademie věd + Karlova univerzita
- ▶ Demosthenes, Popokatepetl
 - LSD FI
- ▶ ERIS TTS (<http://www.speechtech.cz/>), heterogenní segmenty [+ DEMO](#)
 - SpeechTech, s.r.o. + katedra kybernetiky FAV ZČU
 - verze je nejlepší český
- ▶ Český hlas pro Mbrolu
 - Mikuláš Piňos, NLP lab FI

Rozpoznávání řeči

- ▶ Automatic Speech Recognition, ASR
- ▶ Konverze řeči na text
 - Výstupem je většinou množina hypotéz spolu s pravděpodobností správnosti dané hypotézy. K výběru správné hypotézy se běžně využívají jazykové modely
- ▶ Lze zhruba rozdělit na
 - Rozpoznávání izolovaných slov – slyšitelná pauza mezi slovy
 - Rozpoznávání kontinuální řeči – plynulá řeč (řeč školeného mluvčího nebo čtený text)
 - Rozpoznávání spontánní řeči – přeřeky, pauzy, začátky vět (*false-starts*)

Rozpoznávání řeči pokrač.

- ▶ Diktovací stroje (např. Dragon Naturally Speaking)
 - Schopné rozpoznat cokoliv
 - *N*-gramové statistické jazykové modely
 - Závislé na mluvčím (je potřeba je natrénovat)
- ▶ Rozpoznávače založené na gramatikách
 - Rozpoznají jen fráze popsané (regulární) gramatikou (gramatika = jazykový model)
 - $S \rightarrow "Jedu do " MESTO$
 - MESTO $\rightarrow "Prahy" \mid "Brna"$
 - Nezávislé na mluvčím – telefonní aplikace
 - Speech Recognition Grammar Specification (SRGS)
 - standard W3 konzorcia, à la BNF
 - existují 2 notace – XML a šípková pro čtení
 - dá se do ní dát i "význam" vstupu

Rozpoznávání řeči pokrač.

Probíhá obvykle ve 3 fázích:

1. Vstup signálu
 - Amplituda akustického vlnění je snímána v pravidelných intervalech a uložena ve formě celého čísla (digitalizace a vzorkování signálu)
2. Vytvoření akustických charakteristik signálu (akustické vektory)
 - Snižuje variabilitu a odstraňuje redundanci (řeč 300 000 × redundantní)
 - Počítají se rozdělením na segmenty 10–40 ms, ze kterých se odečítají charakteristiky jako je počet průchodu nulou nebo prvních 12 koeficientů FFT (cca 40 čísel, není přesně dané které, ale výběr velice ovlivní výsledek)
3. Porovnávání vektorů parametrů
 - K získané sekvenci vektorů parametrů se hledá co nejpodobnější sekvence známých, předem naučených, vektorů reprezentující např. fonémy, trifóny, slabiky, celá slova apod.

Porovnávání vektorů parametrů

- ▶ Algoritmus borcení časové osy (dynamic time warping, DTW)
 - odstraňuje časové nerovnoměrnosti v akustickém signálu
- ▶ Skryté Markovovy modely (*Hidden Markov Models, HMM*)
 - Pravděpodobnostní konečné automaty
 - V každém okamžiku je haslové ústrojí v určitém stavu a může s určitou pravděpodobností přejít do jednoho z následujících stavů
 - Jako doplněk se mohou využít neuronové sítě
 - Je nejprve potřeba natrénovat za pomocí dat z řečového korpusu

ASR systémy ve světě

- ▶ ©Nuance (<http://www.nuance.com/>)
- ▶ ©Loquendo (<http://www.loquendo.com/>)
- ▶ ©LumenVox (<http://www.lumenvox.com/>)
- ▶ ©IBM ViaVoice
(<http://www306.ibm.com/software/voice/viavoice/>)
- ▶ Sphinx (<http://cmusphinx.sourceforge.net/>)

České ASR systémy

- ▶ Laboratoř počítačového zpracování řeči na Fakultě mechatroniky Technické univerzity v Liberci (<http://itakura.kes.vslib.cz/kes/>)
- ▶ ERIS ASR (<http://www.speechtech.cz/>)
 - SpeechTech, s.r.o. + katedra kybernetiky FAV ZČU
- ▶ Speech@FIT VUT Brno
(<http://www.fit.vutbr.cz/research/groups/speech/>)
 - keyword spotting – jestli se vyskytlo dané slovo v běžné řeči

Související technologie

- ▶ Dialogové systémy
 - Počítačové systémy komunikující s uživatelem pomocí přirozeného jazyka
 - Využívají ASR a TTS jako své komponenty
- ▶ Rozpoznávání mluvčího
 - identifikace mluvčího – určení, který z registrovaných mluvčích pronesl danou větu
 - verifikace mluvčího – akceptování nebo odmítnutí identity mluvčího
- ▶ Identifikace mluveného jazyka
 - fonémicko-fonetický rozpoznávač pro každý rozpoznávaný jazyk – sledují se foném specifické pro každý jazyk
 - daná promluva je zpracována všemi rozpoznávači a jako jazyk dané promluvy je zvolen jazyk, jehož rozpoznávač dosáhl nejvyššího skóre

TTS Demo

- ▶ <http://www.nuance.com/realspeak/demo/>
- ▶ <http://actor.loquendo.com/actordemo/default.asp?language=en>
- ▶ <http://demo.acapela-group.com/>
- ▶ <http://epos.ure.cas.cz/>
- ▶ <http://speechtech.cz/demo.php>

Morfologie

Morfologie, morfologická analýza

Aleš Horák

E-mail: hales@fi.muni.cz
http://nlp.fi.muni.cz/poc_lingv/

Obsah:

- ▶ Morfologie
- ▶ Morfologická analýza

- ▶ nauka o stavbě a tvorbě slov (v daném jazyce)
- ▶ **morfém** – nejmenší jednotka, která může **nést** význam

pří-lež-it-ost-n-ými

základní tvar = **přiležitostný**
 příd. jméno, rod muž. živ., neživ., žen. nebo stř., 7. pád., mn. č.

pří – prefix (*bлизко*)
lež – lexikální kořen (*лежат*)
it – adjektivní derivační sufix (*ten, který*)
ost – substantivní derivační sufix (*та скuteчност, že*)
n – adjektivní derivační sufix (*charakteristický pro*)
ými – gramatický afix (*instrumentál plurálu*)

Dělení morfémů

dělení používané zejména v analytických jazycích (angličtina):

- ▶ morfémy **obsahové** (*content*) × **funkční** (*function*)
- ▶ morfémy **volné** (*free*) × **vázané** (*bound*)

dělení používané zejména ve flektivních jazycích (českina):

- ▶ **kořeny** – nesamostatné morfémy nesoucí elementární lexikální významy
- ▶ **afixy**, které se dále dělí
 - podle funkce:
 - gramatické/flekční
 - slovotvorné/derivační
 - podle postavení vzhledem ke kořeni:
 - prefixy – morfém stojící před kořenovým morfémem (*pod-*, *anti-*, *v-*)
 - sufaxy – morfémy připojované za kořenové morfemy (*-ik*, *-izmus*, ...)
 - postfixy – slovotvorné morfémy připojované až za gramatický sufix (*kdoši*, *kohokoli*, ...)
 - circumfix – morfém připojované "kolem" základu, není v češtině
 - infix, interfix – morfémy vsazované dovnitř slova (*mal-il-inký*, *velk-o-město*, ...)

Základní lingvistické termín v morfologii

- ▶ slovní druh – podstatné jméno (*substantivum*), přídavné jméno (*adjektivum*), sloveso (*verbum*), příslovec (*adverbium*), ...
- ▶ pád – *nominativ*, *genitiv*, *dativ*, *akuzativ*, *vokativ*, *lokál*, *instrumentál*
- ▶ číslo – *singulár*, *plurál*
- ▶ rod – 4 rody, mužský (*masculinum*) životný a neživotný (*animativní* a *inanimativní*), ženský (*femininum*) a střední (*neutrum*)
- ▶ slovotvorba – předpona (*prefix*), přípona (*sufix*), předpona nebo přípona (*afix*)
- ▶ základní tvar slova – *lemma* (mn.č. *lemmata*)
- ▶ ohýbání slov (*flexe*) – skloňování (*deklinace*) a časování (*konjugace*)
- ▶ odvozování – *derivování*

Procesy tvoření slov

dělení podle třech základních procesů tvoření slov:

- **flektivní morfologie** – popisuje strukturu slovních tvarů pomocí flexe (ohybání – skloňování a časování)

| | | | |
|--------------|----------------|--------------|-------|
| 1 pes | 2 psa | 3 psovi, psu | 4 psa |
| 5 pse | 6 psovi, psu | 7 psem | |
| 1 psové, psi | 2 psů | 3 psum, psům | 4 psy |
| 5 psové, psi | 6 psách, psech | 7 psy, psama | |

- **derivativní (derivační) morfologie** – zkoumá odvozování slov

mýdlo: mydl-ář, mydl-ina, mýdel-ný, mydl-it, mýdél-ko

- **kompoziciální (kompoziční) morfologie** – zachycuje tvoření slov pomocí skládání

ohni-vzdorný, pravdě-podobný, oka-mžik
tlako-měr, vodo-pád, děje-pis
samo-obsluha, malo-město, býlo-žravý

Derivační morfologie – vztah fundace

- **slovotvorný svazek/hnízdo** – souhrn slov fundovaných jedním slovem
mýdlo → mydl-ář, mydl-ina, mýdel-ný, mydl-it, mýdél-ko

- **slovotvorná čled'** – souhrn všech příbuzných slov (se stejným kořenem)

les

- pra-les → pra-les-ní
- les-ní
 - lesn-ík → lesnic-ký → lesnic-tví
 - lesn-ice
 - nad-lesní
- les-ík → lesíč-ek

Derivační morfologie – vztah fundace

fundace – základní slovotvorný vztah

- slova neutvořená, prvotní, **fundující** – nemůžeme vysvětlit pomocí jiných slov jazyka
voda, hlava, vejce
- slova utvořená, **fundovaná** – opírájí se o slova základová
trávník, růžový, učitel
- **fundace** – spojení slova základového se slovem utvořeným
mladý → mladík
- **slovotvorná řada** – opakováné odvození až k prvotnímu slovu
rybníkářský → rybníkář → rybník → ryba

Morfologická analýza

- rozpoznávání slovních tvarů
- nástroj se nazývá **morfologický analyzátor** (*Part-of-Speech tagger*)
- provádí **lemmatizaci** – přiřazuje k rozpoznaným slovním tvarům **základní tvar (lemma)**
- charakterizuje morfo-syntaktické vlastnosti nalezených slovních tvarů:
příležitostného
- 1. <s> příležitostn-ého (mladý GcAa)
 - <l> příležitostný
 - <c> adje Man sg #4
 - <c> adje Man,Min,Neu sg #2
- kvalita morfologické analýzy ovlivňuje všechny následující analytické roviny

Lexikální a gramatické kategorie

Morfologie klasifikuje (značkuje, tag) slovní tvary jednotlivých kategorií.

Kategorie pro účely analýzy můžeme dělit na dvě skupiny:

- **lexikální kategorie** – pojmenovávají věci, akce, myšlenky podstatná jména, slovesa, přídavná jména, příslovce, ...
- **gramatické kategorie** – vyjadřují vztahy mezi ostatními větnými členy předložky, spojky, částice, anglické členy, ...

jazyky s jednoduchou morfologií (angličtina) – několik desítek kategorií (POS – *Part of Speech* – slovní druhy)
bohatou morfologií – hierarchický systém, kde vedle základních slovních druhů určujeme nejrůznější subklasifikace (pád, číslo, rod, osoba, druhy příslovce, ...) – celkově tisíce značek

Anglické gramatické morfemy

| | |
|------|---|
| -s | 3. osoba, jedn.č., přítomný čas |
| -ed | minulý čas |
| -ing | průběhový |
| -en | přičestí minulé trpné |
| -s | množné číslo |
| -'s | přivlastnění |
| -er | 2. stupeň přídavného jména (komparativ) |
| -est | 3. stupeň přídavného jména (superlativ) |

Brillův značkovač

- učí se podle trénovacích dat:
 1. přiřadí nejčastější značku
 2. zkонтroluj, kde jsou chyby (podle trénovacích dat)
 3. ohodnotí pravidla pro opravu chyb → vyber nelepší → oprav zpětně chybné značky
 4. opakuj, dokud se daří odvozovat dobrá pravidla
- používá učení založené na transformacích (*transformation-based learning*)
- analogie – malování obrazu: nejprve pozadí a pak přes něj stále drobnější detaily
- značkuje 36 různých POS značek
- úspěšnost – přes 90 %

Brillův značkovač – příklad

| věta: | zlatý standard: | podle frekvence: | P1: | P2: |
|----------------|-----------------|------------------|-----|-----|
| The | at | at | | |
| President | nn-tl | nn-tl | | |
| said | vbd | vbd | | |
| he | pps | pps | | |
| will | md | md | | |
| ask | vb | vb | | |
| Congress | np | np | | |
| to | to | to | | |
| increase | vb | nn | vb | |
| grants | nns | nns | | |
| to | in | to | to | in |
| states | nns | nns | | |
| for | in | in | | |
| vocational | jj | jj | | |
| rehabilitation | nn | nn | | |
| . | . | . | . | . |

P1: Replace nn with vb when the previous word is to

P2: Replace to with in when the next tag is nns

Brillův značkovač – příklad

Loading tagged data...

Training unigram tagger: [accuracy: 0.820940]

Training Brill tagger on 37168 tokens...

Iteration 1: 1482 errors; ranking 23989 rules;

Found: "Replace POS with VBZ if the preceding word is tagged PRP"

Apply: [changed 39 tags: 39 correct; 0 incorrect]

Iteration 2: 1443 errors; ranking 23662 rules;

Found: "Replace VBP with VB if one of the 3 preceding words is tagged MD"

Apply: [changed 36 tags: 36 correct; 0 incorrect]

Iteration 3: 1407 errors; ranking 23308 rules;

Found: "Replace VBP with VB if the preceding word is tagged TO"

Apply: [changed 24 tags: 23 correct; 1 incorrect]

...

Iteration 21: 1128 errors; ranking 20569 rules;

Found: "Replace VBD with VBN if the preceding word is tagged VBD"

[insufficient improvement; stopping]

Brill accuracy: 0.835145

Algoritrický popis české formální morfologie

v češtině nestaří pravidla podle obecných morfémů – je potřebné mít **lexikon**, který ke každému **kmenu** obsahuje jeho přiřazení ke vzoru

morfologické (tvaroslovné) **paradigma** – soubor tvarů ohebného slova vyjadřující **systém** jeho **mluvnických kategorií**

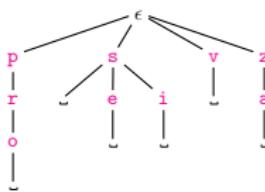
vzor – reprezentace tvaroslovného paradigmatu paradigmatem určitého konkrétního slova

Algoritrický popis:

1. definice **koncovkových množin**
 2. definice vzoru prostřednictvím **vzorových slov** rozdelených na:
 - neměnná část vzorového slova – **kmenový základ**
 - proměnlivé části vzorového slova – **intersegmenty**
 - **koncovkové množiny** obsahující utřízené seznamy všech přípustných koncovek vzorového slova spolu s jejich gramatickými významy
- popis vzoru** = formální pravidlo, které specifikuje přípustné kombinace těchto komponent (segmentů) ohebného slova

Efektivní implementace morfologického lexiku – trie struktura **trie**:

- ▶ uspořádaný strom nad danou abecedou **A**
- ▶ v každém uzlu je různé písmeno z abecedy **A**
- ▶ klíč je v trie uložen jako cesta od kořene
- ▶ výhody:
 - sdílení **společných prefixů**
 - v každém případě nalezení **nejdelšího shodného prefixu**



Eliminace cest v trie



Jiná efektivní implementace ML – konečný automat

- ▶ BP, Radovana Štancela
- ▶ použití mírně pozměněných knihoven pro práci s KA od Jana Daciuka
- ▶ vstupní data se generují ze slovníku **ajky** převedeného do tvaru "slovo<TAB>lemma<TAB>značka" (cca 33 mil. řádků)

| | | |
|-----------|----------|----------|
| Abcházce | Abcházec | k1gMnPc4 |
| Abcházce | Abcházec | k1gMnSc2 |
| Abcházce | Abcházec | k1gMnSc4 |
| Abcházcem | Abcházec | k1gMnSc7 |
| Abcházci | Abcházec | k1gMnPc1 |
| Abcházci | Abcházec | k1gMnPc5 |
| Abcházci | Abcházec | k1gMnPc7 |
| Abcházci | Abcházec | k1gMnSc3 |
| Abcházci | Abcházec | k1gMnSc6 |

...

Jiná efektivní implementace ML – konečný automat

- ▶ data se dále upravují pro KA – slovo+zkr. lemma+značky:
Abcházce+ACec+k1gMnPc4, k1gMnSc2, k1gMnSc4
Abcházcem+ADec+k1gMnSc7
Abcházci+ACec+k1gMnPc1, k1gMnPc5, k1gMnPc7, k1gMnSc3, ...
- ▶ v lemmatu – 1. písmeno je počet znaků, které se odtrhnou jako předpona, 2. písmeno je počet znaků, které se trhají od konce a ostatní znaky se přidají
- ▶ tím se sníží počet řádků na 6.7 mil. řádků, ze kterých se přímo generuje (a minimalizuje) konečný automat
- ▶ výsledný slovník má 4.3MB
- ▶ rychlosť je cca o 1/4 lepší než u trie, velikost řádově srovnatelná

České morfologické analyzátor

- ▶ **ajka**
 - Radek Sedláček, FI MU Brno
 - <http://nlp.fi.muni.cz/projekty/ajka/>
 - značky jsou řetězce dvojic **atribut–hodnota**
 - napsaný v C
 - využívá struktury **trie**
 - 390 000 základních tvarů, 6 300 000 různých slovních tvarů, 15 000 různých značek, slovník 3.13MB
 - rychlosť analýzy – cca 18 000 slov/s
 - data se v současnosti editují pomocí nástroje **i-par** od Marka Vebera
- ▶ **pražský morfologický analyzátor**
 - Barbora Hladká, Jan Hajčík a jeho tým, ÚFAL MFF UK Praha
 - <http://ufal.mff.cuni.cz/czech-tagging/>
 - používá **poziční značky**
 - "free" část napsaná v Perl, menší slovník (cca 76 000 základních tvarů, 6 000 koncovek)

Pražský morfologický analyzátor – pozici značky

| pozice | kategorie | anglicky | česky |
|--------|------------|--------------------------|-----------------|
| 1 | POS | Part of Speech | Slovní druh |
| 2 | SUBPOS | Detailed Part of Speech | Slovní poddruh |
| 3 | GENDER | Agreement Gender | Rod |
| 4 | NUMBER | Agreement Number | Číslo |
| 5 | CASE | Case | Pád |
| 6 | POSSGENDER | Possessor's Gender | Rod vlastníka |
| 7 | POSSNUMBER | Possessor's Number | Číslo vlastníka |
| 8 | PERSON | Person | Osoba |
| 9 | TENSE | Tense | Čas |
| 10 | GRADE | Degree of Comparison | Stupeň |
| 11 | NEGATION | Negation (by prefix) | Negace |
| 12 | VOICE | Voice | Slovesný rod |
| 13 | RESERVE1 | Reserved for future use | Rezerva |
| 14 | RESERVE2 | Reserved for future use | Rezerva |
| 15 | VAR | Variant, Style, Register | Varianta, styl |

Pražský morfologický analyzátor – příklad

► vstup:

Prezident rezignoval na svou funkci.

► výstup:

```
<csts>
<f cap>Prezident<MMl>prezident<MMt>NNMS1----A----
<f>rezignoval<MMl>rezignovat:T<MMt>VpYS---XR-AA---
<f>na<MMl>na<MMt>RR--4-----<MMt>RR--6-----
<f>svou<MMl>svůj-1_~(přivlast.)<MMt>P8FS4-----1
    <MMt>P8FS7-----1
<f>funkci<MMl>funkce<MMt>NNFS3----A----
    <MMt>NNFS4----A---<MMt>NNFS6----A---
<D>
<d>. <MMl>. <MMt>Z:-----
</csts>
```

Morfologický analyzátor ajka – příklad

► dávkově

Prezident <l>prezident <c>k1gMnSc1
 rezignoval <l>rezignovat <c>k5eApMnStMmPaI <c>k5eApInStMmPaI
 na <l>na <c>k7c4 <c>k7c6
 svou <l>svuj <c>k3xgfFnSc4p3 <c>k3x0FgFnSc7p3
 funkci <l>funkce <c>k1gFnSc3 <c>k1gFnSc6 <c>k1gFnSc4

► interaktivně

```
<s> ne=snesiteln=ého== (1023)
<l>snesitelný
<c>k2eNgMnSc2d1
<c>k2eNgMnSc4d1 ...
```

► všechny tvary (ajka -a)

```
<s> =p=es== (1148)
<l>pes
<c>k1gMnSc1
pes psům psů psovi psem psu psy psech pse psi psové
```

Morfologický analyzátor ajka – webové rozhraní

<http://nlp.fi.muni.cz/projekty/wwwajka/>

Výsledek morfologické analýzy - interaktivní režim

(*) - Vypiš všechny odvozené tvary

| Analyzovaný tvar: stát | | | |
|------------------------|------------|-------------|-----------|
| Základní tvar | Segmentace | Číslo vzoru | Kategorie |
| stát (*) | sgt=á=t= | 1422-stát | kSeAaInE |
| stát (*) | sgt=á=t= | 1587-vstát | kSeAaPnE |
| stát (*) | sgtát=t== | 874-most | kIgInSc1 |
| | | | kIgInSc4 |

Analyzuj text:

[Morfologická analýza - interaktivní režim](#) [Morfologická analýza - dílkový režim](#)

Syntaxe – gramatiky a syntaktické struktury

Aleš Horák

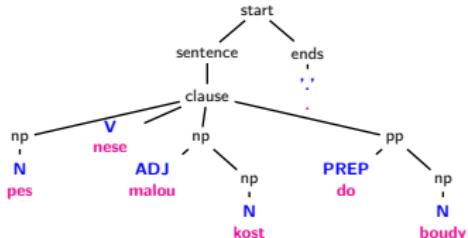
E-mail: hales@fi.muni.cz
http://nlp.fi.muni.cz/poc_lingv/

Obsah:

- ▶ Syntaxe, syntaktická analýza
- ▶ Základní termíny
- ▶ Specifikace gramatik
- ▶ Chomského teorie syntaxe
- ▶ Východiska syntaktické analýzy

Syntaxe, syntaktická analýza

- ▶ **syntaxe** – charakterizace dobré utvořených kombinací slovních tvarů do **věty** nebo **fráze**
- ▶ pomocí **gramatických pravidel**
- ▶ výstup ze syntaktické analýzy (např. derivační strom) tvoří často vstup pro analýzu sémantickou



Typy gramatik

gramatiky:

- ▶ **regulární** (regular) **neterminál** → **terminál[neterminál]**
 $S \rightarrow aS$ ekvivalentní sile **konečných automatů**,
 $S \rightarrow b$ neumí $a^n b^n$
 - ▶ **bezkontextové** (context-free) **neterminál** → **cokoliv**
 $S \rightarrow aSb$ ekvivalentní sile **zásnobníkových automatů**, umí $a^n b^n$, neumí $a^n b^n c^n$
 - ▶ **kontextové** (context-sensitive) – víc neterminálů na levé straně; na levé straně se jejich počet "zmenšuje"
 $ASB \rightarrow AAaBB$ umí $a^n b^n c^n$
 - ▶ **rekurzivně výčíslitelné** (recursively enumerable) – bez omezení
ekvivalentní sile **Turingova stroje**
- přirozený jazyk** byl dlouho pokládán za bezkontextový → nyní prokázáno, že obsahuje **kontextové prvky**

Syntaktická analýza programovacích × přirozených jazyků

- ▶ počítačové programy a přirozené jazyky sdílí **teorii formálních jazyků** a praktický zájem o **efektivní algoritmy** analýzy
- ▶ **ALGOL 60** – první programovací jazyk popsán pomocí **Backus-Naurovy formy** (BNF)

```

<if_statement> ::= if <boolean_expression> then
                      <statement_sequence>
                  [ else
                      <statement_sequence> ]
                  end if ;
  
```
- ▶ dokázalo se, že BNF je **ekvivalentní** CFG (1962) → podnítilo výzkum formálních jazyků z hlediska jazyků přirozených

Gramatiky přirozeného jazyka

- konkrétní popis **gramatiky přirozeného jazyka** je velmi složitým úkolem
- kontrast s faktem, že rodilí mluvčí nemívají potíže s pochopením významu vět
- asi **nejstarší formální popis jazyka** – gramatika sanskrtu od indického učence Paniniho



संस्कृत भारती

- vznikla cca 400 př.n.l.
- dochovaná v rituálních védických textech
- gramatika podobná BNF (Backus-Naurově formě)
- používala bezkontextových i kontextových pravidel, obsahovala asi 1700 termů
- zabývala se z větší části morfologií, nikoliv syntaxí, neboť pořádek slov je v sanskrtu dosti volný
- toto dílo bylo evropské škole obecné lingvistiky, která má kořeny v řecké a římské tradici, neznámé až do 19. století

Základní termíny – pokrač.

► frázová kategorie (*phrasal category*)

neterminální symbol gramatiky, který nevyjadřuje lexikální kategorii

| | | | |
|------|---|------|-----|
| ADJP | → | ADJP | ADJ |
| NP | → | ADJP | N |
| VP | → | V | NP |
| S | → | NP | VP |

► větný člen (*constituent*) lexikální nebo frázová kategorie

Základní termíny

- fráze (*phrase*)** – jednotka jazyka větší než slovo, ale menší než věta např. *jmenná fráze*, *slovesná fráze*, *adjektivní fráze* nebo *příslovečná fráze*
- lexikální symbol, lexikální kategorie (*lexical category*)** tzv. **pre-terminál** speciální neterminál gramatiky, který se přímo přepisuje na terminálový řetězec znaků, tj. pravidla tvaru $X \rightarrow w$

| | | | | | | | |
|------|---|------|--|--------|--|------|-----|
| N | → | pes | | člověk | | dům | ... |
| V | → | nese | | chodit | | psal | ... |
| ADJ | → | ... | | | | | |
| PREP | → | ... | | | | | |
| ADV | → | ... | | | | | |

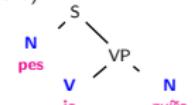
označuje všechny slova, která odpovídají určitému lexikálnímu symbolu (všechna podstatná jména, přídavná jména, ...)

Základní termíny – pokrač.

► větná struktura (*sentence structure*) – strukturovaný popis větných členů

► povrchová struktura (*surface structure*)

derivační/složkový strom jako výsledek bezkontextové (CF) analýzy



► závislostní struktura (*dependency structure*)

zobrazuje závislosti mezi větnými členy



► hloubková struktura (*deep structure*) – sémantická interpretace fráze.

Popisuje **role větných členů** (agens, patiens, donor, cause, ...)

Složkový a závislostní přístup

dva základní způsoby zadávání gramatik

složkový přístup:

- ▶ skupiny slov tvoří větné jednotky, které jsou označovány jako **fráze**, a jako **větné členy** (*constituents*) formují **větu**
- ▶ např.
podstatné jméno – součást jmenné fráze (noun phrase – NP)
jmenná fráze spolu s předložkou – tvoří předložkovou frázi (prepositional phrase – PP)
- ▶ syntaktická struktura věty je zachycována jako **složkový strom**

Složkový a závislostní přístup – pokrač.

závislostní přístup:

- ▶ jeden člen vazby je označován jako **řídící**, druhý jako **závislý**
- ▶ např.
přidavné jméno závisí na řídícím podstatném jméně
- ▶ syntaktická struktura věty je zachycována pomocí **závislostního stromu**:
 - uzly odpovídají elementárním jednotkám vstupu (často slovům)
 - hrany označují vztahy závislosti mezi elementárními jednotkami
- ▶ závislost není relací mezi jednotlivými slovy, ale obecně relací mezi jedním **slovem a frází** řízenou druhým slovem. např.
vazba mezi konkrétním slovesem a podmětem
nebo vazba mezi slovesem a předmětem věty
- ▶ technicky vzato, závislostní relace je vztahem mezi uzly a podstromy (uzlem a všemi uzly, které na tomto uzlu závisí)

Složkový a závislostní přístup – pokrač.

- ▶ jen zřídka se používá **čistě** složkový či striktně závislostní přístup
- ▶ ve složkovém jsou závislosti zpravidla vyjádřeny přidáním označení, která složka je řídící pro danou frázi
- ▶ závislostní strom bývá doplněn o informaci určující lineární precedenci
- ▶ je možné pak mezi těmito přístupy výsledek převádět

Uzly syntaktického stromu

označení uzlu (název neterminálu):

- ▶ **gramatická role** (gramatická funkce)
 - charakterizují vztahy mezi větnými složkami na povrchové úrovni
 - určujeme, zda daný větný člen je NP v roli **podmětu**, NP v roli **předmětu**, ADVP určující **lokaci** atd.
 - v češtině (a jazycích se systémem gramatických pádů) pomáhá k určení gramatické role právě **informace o pádu**
 - ovšem přiřazení gramatických rolí ke gramatickým pádům a naopak není zdaleka jednoznačné.
- ▶ **tematická role** (též **hloubkový/sémantický pád**)
 - na rozdíl od gramatické role se jedná o **sémantickou kategorii**
 - určujeme např.:
 - **Agens** – kdo je životním **původcem** nějaké cílevědomé činnosti
 - **Patiens** – co hráje roli entity, na kterou se **působí**
 - **Donor** – osoba, která **dává**
 - **Cause** – entita, která **způsobuje**, že je něco děláno
 - opět neexistuje jednoznačná vazba mezi gramatickými a tematickými rolemi (viz např. aktivní a pasivní konstrukce, kdy je stejná tematická role realizována podmětem i předmětem)

Příznaky a příznakové struktury

informace v uzlu syntaktického stromu:

- příznaky/rysy (features) – zaznamenávají **syntaktické nebo sémantické informace** o slovu nebo frázi.

např. **test na shodu**:

Malý Petr přišel domů.

podmět (Petr) je ve shodě s přísluhkem (přišel) v **čísle a rodě** případně jméno (malý) a podstatné jméno (Petr) se shodují v **pádě, čísle a rodě**

$$\begin{array}{lcl} S(n, g) & \rightarrow & NP(., n, g) \quad VP(n, g) \\ NP(c, n, g) & \rightarrow & ADJ(c, n, g) \quad N(c, n, g) \end{array}$$

Příznaky a příznakové struktury – pokrač.

- gramatické znaky (slovní druh, gramatický pád, rod, číslo, osoba, ...) je výhodné začlenit do gramatiky ve formě dvojic **atribut–hodnota**
- potom je možné **zobecňovat**, např. vyjádřit shodu v pádě, čísle a rodě výhradně pomocí atributů
- aplikace – v mnoha gramatických formalismech jazykové objekty jsou zde modelovány jako **příznakové struktury (feature structures)**, tedy právě **matice** dvojic atribut–hodnota.
- u složitějších struktur – nestačí pak běžné porovnání instanciace jde oběma směry → použije se **unifikace**

Pořádek slov ve větě

syntaktická pozice – standardní pozice větných členů ve větě

angličtina: **S V O M P T**

Subject, Verb, Object, Modus, Place, Temp

- avšak např. předmět se může přesunout na první pozici – **topikalizace**

The book I read.

- v češtině – téměř libovolné přesuny syntaktických elementů souvisí s tzv. **aktuálním větným členěním**

Možnosti zadávání gramatik

- nejčastější formát specifikace gramatik – **produkční pravidla** gramatika se skládá z pravidel generujících **správně utvořené řetězce**
- cíl analyzátoru – najít odvození vstupního řetězce ze zadанého neterminálu (označovaného obyčejně velkým písmenem *S* z anglického *sentence* – věta) na základě daných pravidel
- pokud je tohoto cíle dosaženo, vstup je akceptován a je mu přiřazena odpovídající struktura
- v minulosti rovněž populární – **přechodové sítě** (*transition networks*) přechody sítě = lingvistické jednotky, uzly sítě = stavы analyzátoru v procesu analýzy vstupu. Přechody jsou označeny symboly definujícími, za jakých podmínek se analyzátor může přesunout z jednoho stavu do stavu druhého.
- rozšířené přechodové sítě** (*ATN – Augmented TN*) jsou doplněny o podmínky a procedury – ekvivalentní deklarativní gramatikám

Standardní teorie syntaxe

- ▶ 50. léta 20. stol. – Noam Chomsky vytvořil **formální teorii syntaxe**
- ▶ jedna ze základních tezí – **autonomie syntaxe**
 ↳ k ověření **syntaktické správnosti** věty nepotřebujeme znát její význam
 Bezbarvé zelené myšlenky zuřivě spí.
- ▶ syntaktické principy mají **univerzální platnost** pro různé přirozené jazyky

Chomského standardní teorie syntaxe

znalost jazyka = gramatika

Chomského předpoklady o **rozumu**:

- ▶ rozum má *vrozenou strukturu*
- ▶ rozum je *modulární*
- ▶ rozum obsahuje speciální modul pro *jazyk* porozumění jazyku je oddělitelné od jiných aktivit
- ▶ syntaxe je *formální* nezávislá na významu a komunikačních funkcích
- ▶ znalost jazyka je *modulární* obsahuje moduly pro jednotlivé fáze analýzy jazyka

Standardní teorie syntaxe – pokrač.

- ▶ Noam Chomsky, **Aspects of the Theory of Syntax**, 1965 – standardní teorie syntaxe – **transformační generativní gramatika** (TGG)
- ▶ snaží se řešit i zachycení sémantických vztahů v **hloubkové struktuře**
- ▶ postupně se vyvinula:
 - v **rozšířenou standardní teorii** (1968)
 - později tzv. **Government & Binding Theory** (teorie nadřazení a vázání, 1981), která zakládá na pojmu *univerzální gramatiky*
 - 90. léta – teorie **minimalismu** (snaha po úspornosti popisného aparátu)

Standardní teorie syntaxe – pokrač.

základní části standardní teorie:

- ▶ **bázová komponenta**
 - ▶ bezkontextová **pravidla** a schémata pravidel generují základní strukturu větných členů
 - ▶ **lexikon** popisuje lexikální kategorie a syntaktické rysy lexikálních položek
- ▶ **transformační pravidla** – vložení, smazání, přesun, změna-rysu, kopie-rysu transformace převádí hloubkové struktury na struktury povrchové

Příklad bázové komponenty

pravidla:

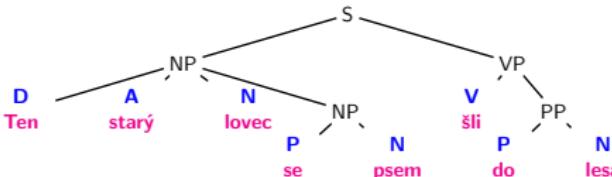
$$\begin{aligned} S &\rightarrow NP\ VP \\ NP &\rightarrow (D\ A^*\ N\ PP^*) \\ VP &\rightarrow V\ (NP)\ (PP) \\ PP &\rightarrow P\ NP \end{aligned}$$

lexikon:

$$\begin{aligned} D: & ten, ta \\ A: & velký, hnědý, starý \\ N: & pták, psem, lovec, já, lesa \\ V: & loví, jí, šli \\ P: & se, do \end{aligned}$$

věta: **Ten starý lovec se psem šli do lesa.**

syntaktický strom:



Návrh podkladů a datových struktur

- ▶ **syntaktický** (odvozovací, derivační) frázový **strom** – kompletní hierarchický popis struktury věty
- ▶ úkol syntaktické analýzy = pro danou gramatiku a daný vstup (větu) dát všechny odvozovací stromy
- ▶ existují techniky pro kompaktní uložení **lesa** takových stromů (chart parsing)
- ▶ jelikož se zabýváme výhradně syntaktickou strukturou a nevylučujeme a priori derivační stromy s absurdní interpretací, má většina vět mnoho různých syntaktických stromů

Obehnat Šalounův pomník mistra Jana Husa na pražském Staroměstském náměstí živým plotem z hustých keřů s trny navrhují občanské sdružení Společnost Jana Jesenia.

Pocet uspěšných stromů = 57 102 672

Příklad transformačních pravidel

např. **pasivizace** (v angličtině):

John chose a book.

NP1 – Aux – V – NP2

1 – 2 – 3 – 4 → 4 – 2+be+en – 3 – by+1
přesuny + vložení + změny-rysu

▶ transformace:

- **obligatorní** – např. přesun slovesné koncovky za sloveso
- **fakultativní** – např. pasivizace, tvorba otázek, negace (změna významu)
- ▶ pravidla bázové komponenty – popisují strom hloubkové struktury v obvyklém pořadí
- ▶ transformace umožňují jeho změny na různé povrchové varianty (trpný rod, otázka, ...)
- ▶ **stopa (trace)** – ukazuje, kde byl prvek před přemístěním

Návrh podkladů a datových struktur – pokrač.

Automatická analýza syntaxe musí vždy projít třemi fázemi:

1. musí být zvolena notace pro zápis gramatiky – **gramatický formalismus**
2. musí být ve zvoleném formalismu napsána **gramatika** pro každý jazyk, který bude zpracováván
3. musí být vybrán nebo navržen **algoritmus**, který určí, zda daný vstup odpovídá gramatice, a pokud ano, jaký popis mu odpovídá

Gramatické formalismy

Gramatické formalismy pro ZPJ

Aleš Horák

E-mail: hales@fi.muni.cz
http://nlp.fi.muni.cz/poc_lingv/

Obsah:

- ▶ Gramatické formalismy
- ▶ Kategoriální gramatiky
- ▶ Závislostní gramatiky
- ▶ Stromové gramatiky TAG a LTAG
- ▶ Lexikální funkční gramatiky LFG

Kategoriální gramatiky

- ▶ **kategoriální gramatika** (categorial grammar, CG) – skupina teorií syntaxe a sémantiky PJ s velkým důrazem na **lexikon**
- ▶ neobsahuje **pravidla** pro kombinování slov → **lexikální kategorie** slov tvoří **funkce**, které určují, jak se dané kategorie kombinují s jinými výraz je výsledkem **aplikace podvýrazů na sebe**

pěkný := $NP/N \dots$ funkce, která má argument N a vrací NP

- ▶ všechny verze CG se opírají o **princip kompozicionality**:
Význam složeného výrazu je jednoznačně určen významy částí tohoto výrazu a způsobem, jakým jsou tyto části složeny dohromady.
- ▶ **zakladatelé** generativních gramatik – Leśniewski (publ. 1929) a Ajdukiewiczem (publ. 1935) ve vazbě na Husserlovu a Russellovou teorii kategorií a teorii typů
- ▶ první použití kategoriálních gramatik pro **popis přirozeného jazyka** – Bar-Hillel, Yehoshua 1953

- ▶ existuje velké množství různých přístupů k formální specifikaci gramatik, různé **gramatické formalismy**
- ▶ popíšeme několik nejrozšířenějších formalismů:
 - kategoriální gramatiky – categorial grammars, CG
 - závislostní gramatiky – dependency grammars
 - stromové gramatiky – (Lexicalized) Tree Adjoining Grammar, (L)TAG
 - lexikální funkční gramatiky – Lexical Functional Grammar, LFG
 - gramatiky příznakových struktur – Head Phrase Structure Grammar, HPSG
- ▶ soustředíme se jen na **zápis gramatiky** (notaci)

Notace kategoriálních gramatik

- ▶ existuje několik různých variant notace

| <u>šikovní</u> | <u>psi</u> | <u>mají rádi</u> | <u>kočky</u> |
|----------------|------------|-----------------------|------------------|
| NP/N | N | $(S\backslash NP)/NP$ | NP |
| | | | $S\backslash NP$ |
| | | | S |

- ▶ jiný rozšířený zápis – **výsledek na vrcholku** (result on top) Lambek 1958

| <u>šikovní</u> | <u>psi</u> | <u>mají rádi</u> | <u>kočky</u> |
|----------------|------------|-----------------------|------------------|
| NP/N | N | $(NP\backslash S)/NP$ | NP |
| | | | $NP\backslash S$ |
| | | | S |

Notace kategorialních gramatik – pokrač.

kategorialní gramatika je šestice $(\Sigma, C_{base}, C, Lex, RS, C_{complete})$, kde

1. Σ je konečná množina **slov**
2. C_{base} je konečná množina **základních kategorií** (funkčních typů)
3. C je množina **kategorií** definovaná induktivně takto:

$$C_{base} \subseteq C$$

pokud $X, Y \in C$, potom i $(X/Y) \in C$ a $(X\backslash Y) \in C$

- c) C obsahuje pouze prvky dané výše uvedenými body a) a b)
- 4. $Lex \subseteq \Sigma \times C$ je konečná množina – **lexikon** (zapisujeme v indexovém tvaru **slово_{kategorie}**)
- 5. RS je množina následujících **schémat pravidel**:
 - a) $\alpha(X/Y) \circ \beta(Y) \rightarrow \alpha\beta(X)$
 - b) $\beta(Y) \circ \alpha(X\backslash Y) \rightarrow \beta\alpha(X)$,
 kde $\alpha, \beta \in \Sigma$ a $X, Y \in C$
- 6. $C_{complete} \subseteq C$ je množina **dokončených (kompletních) kategorií**

Rozšíření kategorialních gramatik

- klíčový problém – nespojité větné části, tzv. **neprojektivity**
- řešení pomocí rozšíření CG – přídavné **kombinatorické operátory** založené na **typecheck**
- dva možné přístupy:
 - **pravidlový orientovaný** přidává pravidla odpovídající jednoduchým operacím nad kategoriemi, jako jsou:
 - **wrap** – komutace argumentů
 - **type-raising** – aplikace typů podobná aplikaci tradičních pádů na jmenné fráze
 - **comp** – kompozice funkcí
- k nejpracovanějším systémům tohoto typu patří **kombinatorické kategorialní gramatiky (CCG)**.
- **deduktivní přístup** vychází z Lambekova syntaktického kalkulu
 - pohled na kategorialní lomitko (slash) jako formu **logické implikace**
 - axiomu a inferenční pravidla potom definují **teorii důkazu**
např. *aplikace funkce* \approx pravidlo *modus ponens* $P \wedge (P \Rightarrow Q) \Rightarrow Q$

Notace kategorialních gramatik – pokrač.

- daná schémata umožňují 2 způsoby kombinace:

- argument **vpravo** (/) – $\alpha(x/y) \circ \beta(y) \rightarrow \alpha\beta(x)$
- argument **vlevo** (\) – $\beta(y) \circ \alpha(x\backslash y) \rightarrow \beta\alpha(x)$

- tento typ kategorialní gramatiky označoval Bar-Hillel jako **oboustranný** (bidirectional CG)

Karel miluje Marii:

- bázové kategorie = $\{NP, S\}$
- kategorie z lexikonom: $Karel(NP)$, $Marii(NP)$, $miluje((S\backslash NP)/NP)$
- $C_{complete} = \{S\}$

- v tomto tvaru je odvození **ekvivalentní derivací stromů** CFG

- existují ale **rozšíření kategorialních gramatik**, která vedou k systémům s vyšší vyjadřovací silou, než mají standardní CFG

Závislostní gramatiky

- blízko ke kategorialním gramatikám – vztah **závislosti** mezi **řídícími** a **závislými** větnými členy
- vhodné pro popis jazyků s volným slovosledem
- používají výhradně **lexikalizovaných uzlů** (v závislostním stromu) – neexistují žádné neterminální
 - závislostní analýza se jeví **jednodušší**
- využívá **valence** či subkategorizace – vztah mezi jedním slovem a jeho argumenty
 - typicky vztah mezi slovesem a jeho možnými doplněními:
nosit
= koho | co
= komu & koho | co

Závislostní gramatiky – pokrač.

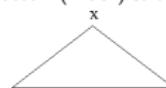
hlavní přístupy:

- ▶ navazuje na evropskou lingvistickou tradici – až k antice
- ▶ nejstarší užití – Tesnière 1959
- ▶ **funkční generativní popis** (*Functional Generative Description*, FGD) – jeden z nejpracovanějších závislostních systémů, pražská lingvistická škola (Sgall, Hajičová, Panevová)
- ▶ UDG, *Unification Dependency Grammar* – Maxwell
- ▶ MTT, *Meaning-Text Theory* – Mel'čuk
- ▶ WG, *Word Grammar* – Hudson
- ▶ Lexicase – Starosta
- ▶ FG, *Functional Grammar* – Dik
- ▶ LG, *Link Grammar* – Temperley, Carnegie Mellon University
<http://www.link.cs.cmu.edu/link/>
- ▶ DUG, *Dependency Unification Grammar* – Halliday

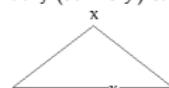
Stromové gramatiky TAG a LTAG

- ▶ Tree Adjoining Grammar – Joshi, Levy a Takahashi: *TAG Formalism*, 1975
- ▶ Lexicalized TAG – Joshi a Schabes: *Parsing with Lexicalized TAG*, 1991
- ▶ pracují přímo se **stromy** a ne s řetězci slov
- ▶ množina **počátečních stromů** – základní stavební prvky
- ▶ složitější věty odvozovány s použitím **pomocných stromů**

počáteční (*initial*) strom:



pomocný (*auxiliary*) strom:



TAG – počáteční a pomocné stromy

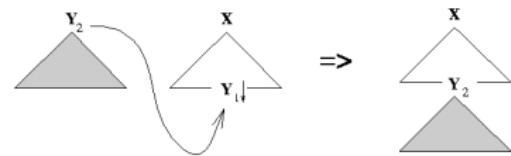
- ▶ **počáteční stromy** – neobsahují rekurzi → popisují složkovou strukturu jednoduchých vět, jmenných skupin, předložkových skupin, ...
 1. všechny **nelistové uzly** odpovídají **neterminálům**
 2. všechny **listové uzly** odpovídají **terminálům** nebo **neterminálním uzlům** určeným k **substituci**

počáteční strom typu X = jeho kořen je označen termem X

- ▶ **pomocné stromy** – reprezentují **rekurzivní struktury**
 popisují větné členy, které se **připojují** k základním strukturám (např. příslovečné určení)
- ▶ charakterizace:
 1. všechny **nelistové uzly** odpovídají **neterminálům**
 2. všechny **listové uzly** odpovídají **terminálům** nebo **neterminálním uzlům** určeným k **substituci** kromě právě jednoho neterminálního uzlu (**patový uzel**, *foot node*)
 3. **patový uzel** má stejné označení jako kořenový uzel
- ▶ **patový uzel** slouží k připojení stromu k jinému uzlu

TAG – operace

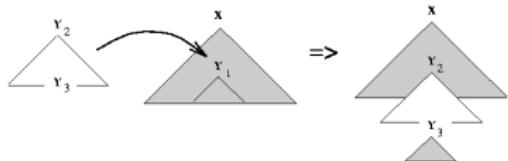
- dvě operace – **substituce** a **připojení** (*adjunction*)
- operace **substituce** – nahrazuje označený neterminál v listech nějakého stromu stromem, jehož kořen nese stejně označení



$Y_1 \downarrow$ – označený pro substituci

TAG – operace připojení

operace **připojení** – vložení pomocného stromu, popisujícího rekurzi neterminálu X , se stromem, který obsahuje uzel označený rovněž X



Definice TAG

► **TAG $G = (I, A, S)$** je:

- množina I konečných počátečních stromů
- množina A pomocných stromů
- typ stromu S – neterminál označující větu

► **množina stromů $T(G)$** TA gramatiky G = množina všech stromů odvoditelných počátečními stromy typu S z I , jejichž spodní okraj sestává čistě z terminálních uzlů (všechny substituční uzly byly doplněny)

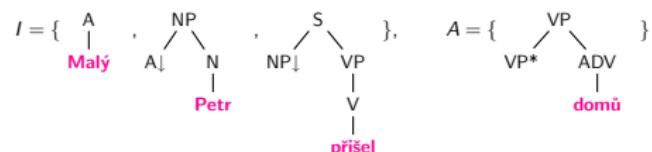
► **jazyk řetězců $\mathcal{L}(G)$** generovaných TA gramatikou G = množina všech terminálních řetězců na spodním okraji stromů v $T(G)$.

LTAG – lexikalizace

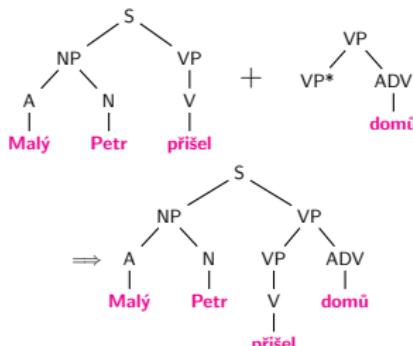
LTAG je **lexikalizovanou variantou formalismu TAG**

→ počáteční i pomocné stromy obsahují v listech jednu nebo více tzv. **lexikálních kotev** – uzly, které jsou přiřazeny (ukotveny) k určitému slovům lexikonu

lexikalizované stromy (*substituční uzly* – ↓, *patové uzly* – *):



LTAG – lexikalizované připojení



TAG a LTAG – generované jazyky

- ▶ díky použití operace připojení mají TAG a LTAG **větší generativní sílu** než bezkontextové gramatiky ($CFG \subset MCSL$) → generují **mírně kontextové jazyky** (*mildly context-sensitive languages*) $MCSL$:
 - vlastnost **konstantního růstu** – pokud uspořádáme řetězce jazyka vzestupně podle délky, potom rozdíl dvou po sobě jdoucích délek nemůže být libovolný (každá délka je lineární kombinací konečného počtu prevních délek).
 - analyzovatelnost v **polynomiálním čase** $O(n^6)$ vzhledem k délce vstupu
- ▶ i jiné formalismy umí $MCSL$ (jsou ekvivalentní s (L)TAG):
 - LIG, *Linear Indexed Grammars* – Gazdar, 1985
 - HG, *Head Grammars* – Pollard, 1984
 - CCG, kombinatorické kategoriální gramatiky

The XTAG Project – <http://www.cis.upenn.edu/~xtag/>

Lexikální funkční gramatiky LFG – pokrač.

- ▶ L = vztahy mezi jazykovými formami, např. mezi aktivními a pasivními formami slovesa, jsou zobecněním struktury **lexikonu**, ne transformačními operacemi, derivujícími jednu formu z druhé
- ▶ F = **funkcionální teorie** – gramatické vztahy, jako je podmět, předmět atd., jsou základními konstrukty, a nejsou definovány pomocí konfigurace frázové struktury, nebo sémantických pojmu typu Agent a Patient
- ▶ v LFG – pro reprezentaci funkcionální syntaktické informace je vhodné definovat hierarchickou strukturu jazykových jednotek, avšak vynucená linearizace pořadku těchto struktur není vhodná

Lexikální funkční gramatiky LFG

- ▶ **LFG, Lexical Functional Grammar** – Kaplan a Bresnan, 1982
- ▶ dva typy syntaktických struktur
 - **vnější, c-struktura** – viditelná hierarchická organizace slov do frází
 - **vnitřní, f-struktura** – abstraktnější struktura gramatických funkcí, které tvorí hierarchii komplexních funkčních struktur
- ▶ **důvod:**
 - různé přirozené jazyky se významným způsobem odlišují v **organizaci fráze**, v pořadí a způsobech realizace gramatických funkcí
 - abstraktnější, **funkcionální** organizace jazyků se odlišuje mnohem méně v mnoha jazyčích se např. objevují gramatické funkce *podmětu, předmětu* atd.

Syntaktické úrovně LFG

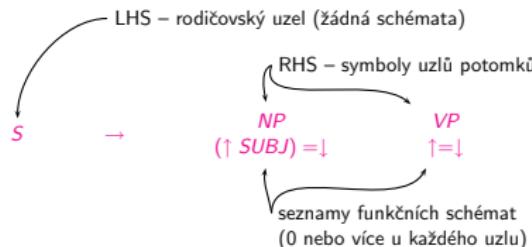
- ▶ dvě syntaktické úrovně:
 - **složková struktura** (*c-structure, constituent structure*) – zachycuje frázovou dominanci a prioritu a je reprezentována jako **strom** frázové struktury (CFG strom)
 - **funkcionální struktura** (*f-structure*) – zachycuje syntaktickou strukturu typu predikát-argumenty a je reprezentována **maticí** dvojicí *atribut-hodnota* nabízí jednotnou reprezentaci syntaktické informace abstrahující od detailů struktury fráze a lineárního pořádku
- ▶ f-struktura obsahuje soubor atributů:
 - **příznaky** – čas, rod, číslo, ...
 - **funkce** – PRED, SUBJ, OBJ, jejichž hodnoty mohou být jiné f-struktury
- ▶ vztah mezi c-strukturami (stromy) a odpovídajícími f-strukturami:

projekce $\phi : \{\text{uzly stromu c-struktury}\} \rightarrow \{\text{f-struktury}\}$

LFG – c-struktura

LFG pravidla:

- klasická CF pravidla
- plus **funkční schéma** – výrazy pracující se symboly na pravé straně pravidel (za →, RHS)



LFG – pravidla

příklady:

$$\begin{array}{lll} S \rightarrow & NP & VP \\ & (\uparrow SUBJ) = \downarrow & \uparrow = \downarrow \\ VP \rightarrow & V & (NP) \\ & \uparrow = \downarrow & (\uparrow OBJ) = \downarrow \\ NP \rightarrow & (DET) & N \\ & \uparrow = \downarrow & \uparrow = \downarrow \end{array}$$

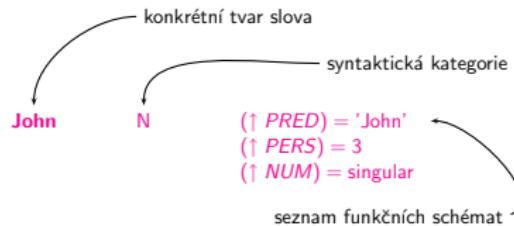
výrazy $(\uparrow SUBJ) = \downarrow$, $\uparrow = \downarrow$ a $(\uparrow OBJ) = \downarrow$ jsou funkční schéma

LFG – lexikon

lexikon také obsahuje funkční schémata

položka lexikonu:

1. konkrétní tvar slova
2. syntaktickou kategorii
3. seznam funkčních schémat



LFG – lexikon – pokrač.

příklady:

| | | | | |
|------|---|------------------------|---|--------------------------------------|
| John | N | $(\uparrow PRED)$ | = | 'JOHN' |
| | | $(\uparrow NUM)$ | = | SING |
| | | $(\uparrow PERS)$ | = | 3 |
| sees | N | $(\uparrow PRED)$ | = | 'SEE<(\uparrow SUBJ)(\uparrow OBJ)>' |
| | | $(\uparrow SUBJ NUM)$ | = | SING |
| | | $(\uparrow SUBJ PERS)$ | = | 3 |
| Mary | N | $(\uparrow PRED)$ | = | 'MARY' |
| | | $(\uparrow NUM)$ | = | SING |
| | | $(\uparrow PERS)$ | = | 3 |

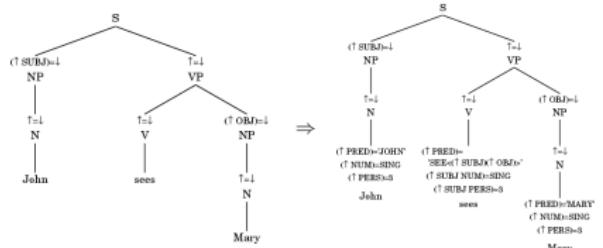
XLE web interface –

<http://decentius.aksis.uib.no/logon/xle.xml>

LFG – konstrukce c-struktury

informace v c-strukturě:

- hierarchická struktura větných členů
- **funkční anotace** (funkční schéma převedené do stromu) – po jejich *interpretaci* získáme výslednou f-strukturu



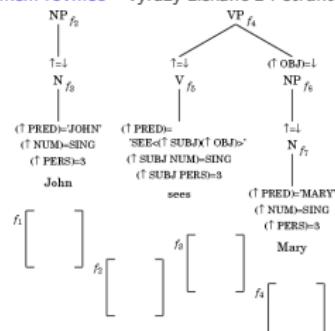
LFG – instanciace hodnot

Instanciace hodnot

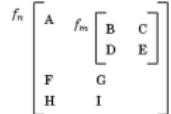
- doplňuje hodnoty metaproměnných \uparrow a \downarrow
- transformuje schémata na **funkční rovnice** – výrazy získané z f-struktur

grafický zápis – f-struktura
v hranatých závorkách []

každý uzel c-struktury má
k sobě připojenou *matici*
f-struktury, které se označují
indexy f_i



LFG – f-struktura



grafický zápis:

matice atribut-hodnota (attribute-value matrix, AVM) – levé sloupce jsou atributy, pravé sloupce hodnoty (symboly, podřazené f-struktury nebo sémantické formy)

funkční rovnice a f-struktury:

$$(f_p \text{ ATT}) = \text{VAL}$$

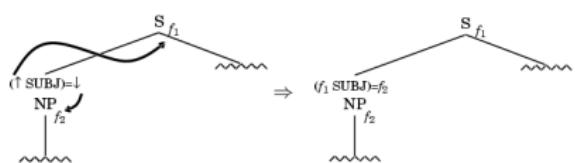
v f-struktuře f_p je řádek, kde
atribut je ATT
a jeho hodnota je VAL

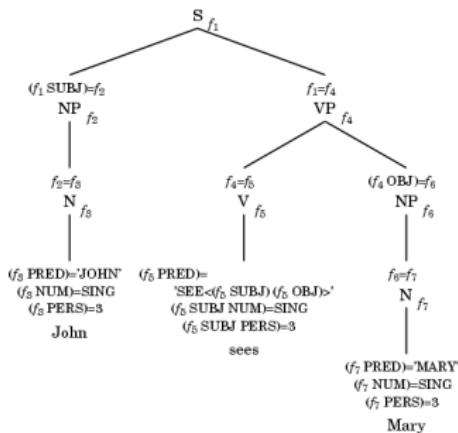
funkční rovnice mohou být splněny nebo nesplněny (true/false)

LFG – doplnění hodnot metaproměnných

\uparrow a \downarrow (metaproměnné) se odkazují na f-struktury
je potřeba najít správné proměnné f_i na místě šipek

- \uparrow – metaproměnná EGO nebo SELF – odkazuje na f-strukturu uzlu nad schématem
- \downarrow – metaproměnná MOTHER – odkazuje na f-strukturu rodičovského uzlu vzhledem k uzlu nad schématem





LFG – funkční popis

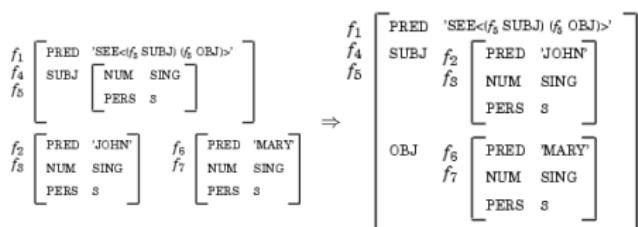
funkční popis = množina všech instanciovaných funkčních rovnic stromu vlastní konstrukce f-struktury pracuje pouze s tímto funkčním popisem funkční popis předchozí věty:

- | | |
|--|---|
| a. $(f_1 \text{ SUBJ}) = f_2$ | i. $(f_5 \text{ SUBJ NUM}) = \text{SING}$ |
| b. $f_3 = f_2$ | j. $(f_5 \text{ SUBJ PERS}) = f_3$ |
| c. $(f_3 \text{ PRED}) = \text{'JOHN'}$ | k. $(f_4 \text{ OBJ}) = f_6$ |
| d. $(f_3 \text{ NUM}) = \text{SING}$ | l. $f_6 = f_7$ |
| e. $(f_3 \text{ PERS}) = f_5$ | m. $(f_7 \text{ PRED}) = \text{'MARY'}$ |
| f. $f_1 = f_4$ | n. $(f_7 \text{ NUM}) = \text{SING}$ |
| g. $f_4 = f_5$ | o. $(f_7 \text{ PERS}) = f_3$ |
| h. $(f_5 \text{ PRED}) = \text{'SEE}<(f_5 \text{ SUBJ})(f_5 \text{ OBJ})>\text{'}$ | |

LFG – konstrukce f-struktury

f-struktura se tvoří z funkčního popisu tak, aby všechny funkční rovnice byly splněny

výsledná f-struktura musí být **minimální** taková f-struktura



HPSG – Head-driven Phrase Structure Grammar

Gramatické formalismy pro ZPJ II

Aleš Horák

E-mail: hales@fi.muni.cz
http://nlp.fi.muni.cz/poc_lingv/

Obsah:

- ▶ HPSG – Head-driven Phrase Structure Grammar
- ▶ Metagramatika systému synt

- ▶ HPSG, Head-driven Phrase Structure Grammar – Pollard & Sag, 1994
- ▶ navazuje na Gazdar, Generalized Phrase Structure Grammar, 1985
- ▶ lexikalizovaná teorie generativní gramatiky přirozeného jazyka
- ▶ neterminální CFG jsou nahrazeny **příznakovými strukturami**
- ▶ založená na **omezeních** (constraints)
- ▶ modeluje jazyk pomocí **deklarativních** omezení typovaných struktur
- ▶ **příznaky** jsou propojeny pomocí **strukturního sdílení**, tedy předávání proměnných mezi podstrukturami dané struktury
- ▶ HPSG je **nederivační**, na rozdíl od jiných formalismů, kde jsou různé úrovně syntaktické struktury sekvenčně odvozovány pomocí transformačních operací

HPSG – Head-driven Phrase Structure Grammar – pokrač.

- ▶ gramatika je v HPSG modelována pomocí **uspořádaných příznakových struktur**, které korespondují s typy výrazů přirozeného jazyka a jejich částmi
- ▶ cílem teorie je detailní specifikace, které příznakové struktury jsou **přípustné**
- ▶ příznakové struktury definují **omezení**
 hodnoty příznaků mohou být jednoho ze čtyř typů
 - atomy
 - příznakové struktury
 - množiny příznakových struktur (**{...}**)
 - nebo seznamy příznakových struktur (**<...>**)

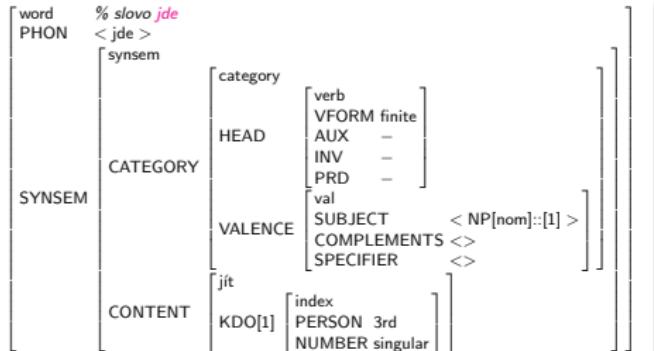
HPSG – lexikální hlava

- ▶ **slova** (lexikální položky) obsahují **hodně informací** – podle psycholingvistiky se podobá zpracování v **lidském mozku**
- ▶ **lexikální hlava** – základní prvek frázové struktury HPSG
 lexikální hlava = jedno slovo, jehož položka specifikuje informace, které určují základní gramatické **vlastnosti fráze**, kterou hlava zastupuje
 gramatické vlastnosti zahrnují:
 - morfologické informace (part-of-speech, POS)
 - N zastupuje NP, VP zastupuje S, V zastupuje VP
 - relace závislosti (např. valenční rámec slovesa)
- ▶ lexikální hlava obsahuje také klíčové **sémantické informace**, které sdílí se zastupovanou frází

HPSG – struktury

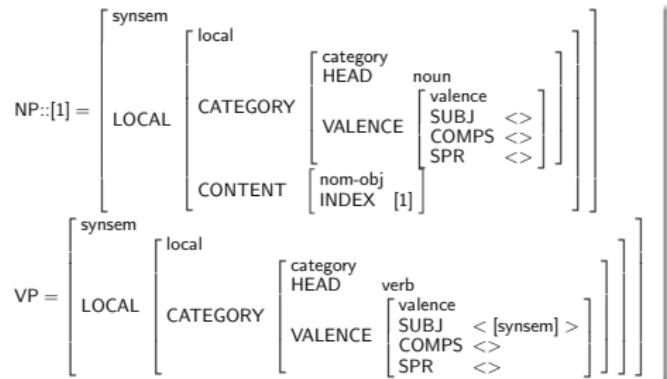
HPSG struktury jsou typované příznakové struktury

zapisují se pomocí AVM – příznaky velkými písmeny, typy malými



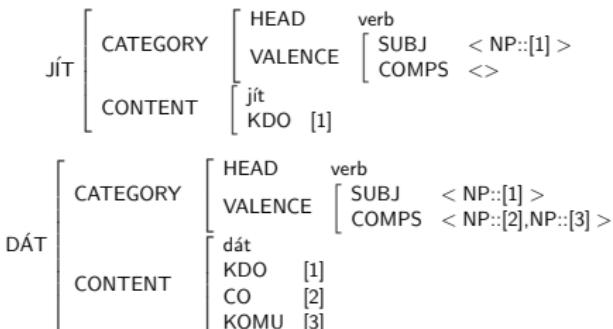
HPSG – syntaktické kategorie

symboly syntaktických kategorií – zkratky určitých příznakových popisů:



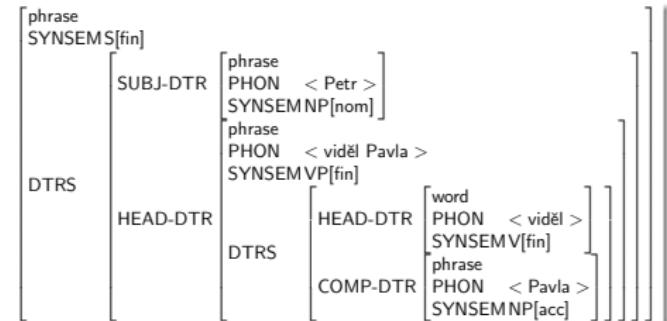
HPSG – lexikální položky

velké množství akcí je v lexiku:



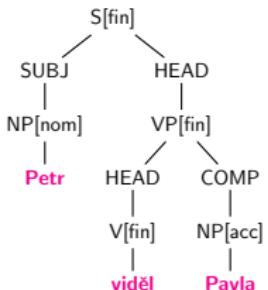
HPSG – fráze

reprezentace frází – v HPSG obdoba reprezentace slov
navíc příznak DAUGHTERS – struktura členů fráze



HPSG – fráze – pokrač.

pro snazší čtení popisů **frází** používáme **stromový zápis**:



ve skutečnosti se ovšem jedná o **příznakovou strukturu**, ne strom!

HPSG – deklarace typu

pro popis omezení geometrie příznaku se používají **typové deklarace**:

category: [HEAD: head, VALENCE: valence]

head # příznaková struktura složená z příznakových struktur
 noun: [CASE: case]
 verb: [VFORM: vform, AUX: boolean, INV: boolean]
 prep: [PFORM: pform]
 ...

vform # jednoduchý příznak, forma slovesa – možné hodnoty:
 fin # určitý tvar slovesa
 inf # neurčitý tvar slovesa – infinitive
 ...

case # jednoduchý příznak, gramatický pád
 nom # 1. pád, nominativ
 acc # 4. pád, akuzativ
 ...

HPSG – dobré utvořené příznakové struktury

dobrě utvořené příznakové struktury musí splňovat **omezení daná gramatikou**

příznaková struktura je **dobrě utvořená** ⇔:

- ▶ každý uzel splňuje **omezení geometrie příznaku**
- ▶ každá uzel vstupního slova splňuje **omezení některé lexikální položky**
- ▶ každý frázový uzel splňuje **frázová omezení** – **omezení přímé dominance** (immediate dominance, viz dále), **omezení hlavových příznaků** (head feature), **valenční omezení**, ...

omezení geometrie příznaku specifikují:

- ▶ s jakými **typy** se pracuje
- ▶ jaká je použitá **typová hierarchie** – který typ je podtypem jiného typu
- ▶ pro každý typ – jaké příznaky přísluší tomuto typu
- ▶ pro každý typ a každý příznak – jakých typů mohou být hodnoty tohoto příznaku

HPSG – dobré utvořená slova a fráze

- ▶ každé vstupní **slovo** musí splňovat některou **lexikální položku**
- ▶ **fráze** musí splňovat **frázová omezení** (constraints):

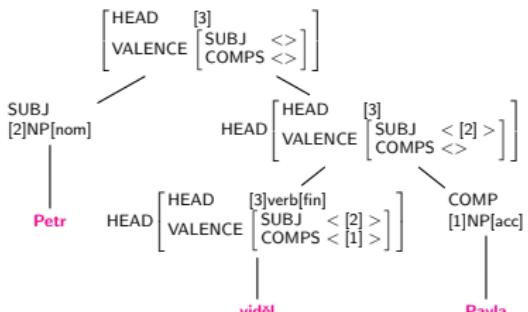
• **omezení přímé dominance** – každá fráze musí odpovídat jednomu ze schémat – schéma *head-subjekt*, schéma *head-specifier*, schéma *head-complement*, ...



- **omezení hlavových příznaků** – pro každou frázi, která má hlavu, musí být hlavové příznaky fráze shodné s hlavovými příznaky potomka, který je hlavou
- **valenční omezení** – pro každý z valenčních příznaků (SUBJECT, COMPLEMENTS, ...) – hodnota příznaku na hlavové frázi musí odpovídat hodnotě na potomku, který je hlavou, méně ty příznaky, které jsou splněny některým z nehlavových potomků

HPSG – dobře utvořené příznakové struktury

omezení ve větě 'Petr viděl Pavla.'



DEMO: GG – HPSG pro němčinu, DFKI Language Technology Lab, Saarbrücken
<http://www.cl.uni-bremen.de/~stefan/Babel/Interaktiv/>

Metagramatika – kombinatorické konstrukty

kombinatorické konstrukty se používají pro generování variant pořadí daným terminálů a neterminálů

hlavní kombinatorické konstrukty:

- ▶ **order()** generuje všechny možné permutace zadaných komponent
- ▶ **first()** argument musí být na prvním místě
- ▶ **rhs()** doplní všechny pravé strany svého argumentu

```
/* budu se ptát */
clause ===> order(VBU,R,VRI)
```

```
/* který ... */
relclause ===> first(relprongr) rhs(clause)
```

Metagramatika systému synt

3 formy (meta)gramatiky:

▶ metagramatika (G1)

- ▶ pravidla s kombinatorickými konstrukty + globální omezení pořadí
- ▶ akce (= gramatické testy + kontextové akce)
- ▶ česká lingvistická tradice – závislostní struktury, kontrola shody, pravidla pro pořadí slov, ...

▶ generovaná gramatika (G2)

- ▶ bezkontextová pravidla
- ▶ akce

▶ expandovaná gramatika (G3)

- ▶ jen bezkontextová pravidla

Metagramatika – typy pravidel

- ▶ -> normální CF pravidlo
- ▶ --> vložit **intersegment** mezi každé dva prvky
- ▶ ==> + kontrola správného pořadí příklonek
- ▶ ===> intersegmenty na začátku a konci RHS, spojky, ...

```
ss -> conj clause
/* budu muset číst */
futmod --> VBU VOI VI
/* byl bych býval */
cpredcondgr ==> VBL VBK VBLL
/* musím se ptát */
clause ===> VO R VRI
```

clause pravidla se zadávají pomocí **pravidlových vzorů**

Metagramatika – globální omezení pořadí

globální omezení pořadí zakazuje některé kombinace pořadí preterminálů

%enclitic – které preterminály jsou brány jako příklonky

%order – zajišťuje dodržení precedence zadaných preterminálů

```
/* jsem, bych, se */
%enclitic = (VB12, VBK, R)

/* byl — četl, ptal, musel */
%order VBL = {VL, VRL, VOL}
```

Metagramatika – pravidlové vzory

pravidla pro slovesné skupiny – cca 40% všech pravidel metagramatiky
pravidlové vzory %group – definují časté skupiny konstrukcí v pravidlech

```
%group verbP={

V:    verb_rule_schema($@,"(#1)")
      groupflag($1,"head"),
  VR R: verb_rule_schema($@,"(#1 #2)")
      groupflag($1,"head"),
}

%template clause =====> order(RHS)

/* ctu/ptam se - I am reading/I am asking */
clause %> group(verbP) vi_list
      verb_rule_schema($@,"#2")
      depends(getgroupflag($1,"head"), $2)
```

Metagramatika – generativní konstrukty

skupina výrazů %list_* – produkuje nová pravidla pro seznamy (s oddělovači/bez oddělovačů, s různými testy na shody, ...)

```
/* (nesmím) zapomenout udelat - to forget to do */
%list_nocoord vi_list
vi_list -> VI
```

```
%list_coord_case np
%list_coord_case_number_gender left_modif
/* krasny velky pes a mala kocka - beautiful dog and small cat */
np -> left_modif np
```

koncovky *_case, *_number_gender and *_case_number_gender určují typ shody

Metagramatika – pravidlové vzory – pokrač.

- ▶ předchozí příklad – skupina verbP = dvě skupiny preterminálů (V a VR R) s příslušnými akcemi
- ▶ při použití v clause vytvoří postupně dvě různé pravé strany
- ▶ (get)groupflag – odkaz na prvek uvnitř %group
- ▶ vzor celého pravidla – speciální pravidlová šipka %>
%template definuje vzor každého pravidla s %>

Metagramatika – úrovně pravidel

- ▶ používá se pro **ohodnocení** výstupních stromů pro jejich **třídění**
- ▶ doplněk trénování na velkých **stromových korpusech** (zatím jen 5.000 vět)
- ▶ zadáné **lingvistou** – specialistou na vývoj gramatiky
- ▶ **základní úroveň – 0, vyšší úrovně** – méně frekventované fenomény
- ▶ pravidla vyšších úrovní mohou být v průběhu analýzy **zapnuté/vypnuté**

```
3:np -> adj_group
      propagate_case_number_gender($1)
```

Expandovaná gramatika G3

- ▶ překlad testů na shody do CF pravidel
- ▶ v češtině – 7 gramatických pádů, dvě čísla a 4 rody → 56 možných variant pro plnou shodu mezi dvěma prvky

počty pravidel

| | |
|--------------------------|-------|
| metagramatika G1 | 253 |
| gramatika G2 | 3091 |
| expandovaná gramatika G3 | 11530 |

DEMO: **wwwsynt** – webové rozhraní k syntu
<http://nlp.fi.muni.cz/projekty/wwwsynt/>
 manuál ke **GDW** – Grammar Development Workbench
http://nlp.fi.muni.cz/projekty/grammar_workbench/manual/

Gramatika G2 – kontextové akce

- ▶ gramatické **testy na shody** – pád, rod, číslo
 - ▶ **testy na zanoření vedlejších vět** – **test_comma**
 - ▶ akce pro specifikaci **závislostních hran**
 - ▶ akce **typové kontroly** logických konstrukcí
- ```
np -> adj_group np
 rule_schema($@, "lwtx(awtx(#1) and awtx(#2))")
 rule_schema($@, "lwtx([[awt(#1),#2],x]])")
```

**rule\_schema** – schéma pro tvorbu logické konstrukce ze subkonstrukcí  
 projdou jenom kombinace, které **typově vyhovují** danému schématu

## Systém synt – příklad logické analýzy

vyhodnocení **rule\_schema** pro **np 'pečené kuře'**

```
4, 6, -npnl -> . left_modif np .: k1gNnSc145
agree_case_number_gender_and_propagate OK
rule_schema: 2 nterms, 'lwtx(awtx(#1) and awtx(#2))',
And constrs, Abstr and Exi vars are just gathered
1 (1x1) constructions:
 $\lambda w_2 \lambda t_3 \lambda x_4 ([\text{pečený}_{w_2 t_3}, x_4] \wedge [\text{kuře}_{w_2 t_3}, x_4]) \dots (\text{oi})_{\tau_w}$
And constrs: none added
Exi vars: none added
```

# Systém synt – příklad logické analýzy – pokrač.

vyhodnocení `verb_rule_schema` pro celou `clause`

`verb_rule_schema: 3 groups`

no acceptable subject found: supplying an inexplicit one

inexplicit subject: k3xPgMnSci,k3xPgInSci: *On...*

Clause valency list: jist <v>#1:(1)hA-#2:(2)hPTc1, ...

Verb valency list: jist <v>#2:hH-#1:hPTc4ti

Matched valency list: jist <v>#2:(1)hH-#1:(2)hPTc4ti

time span:  $\lambda t_{12} dnes_{t_{12}} \dots (\sigma\tau)$

frequency: **Onc**...((o(στ))π)<sub>ω</sub>

verbal object: x<sub>15</sub>...((o(στ))(oπ))

present tense clause:

$\lambda w_{17} \lambda t_{18} (\exists i_{10}) (\exists i_{15}) (\exists i_{16}) ([\text{Does}_{w_{17} t_{18}}, On, [\text{Imp}_{w_{17}}, x_{15}]] \wedge [\text{večeře}_{w_{17} t_{18}}, i_{10}] \wedge$

[pečený]<sub>w<sub>17</sub> t<sub>18</sub></sub>, i<sub>16</sub>]  $\wedge [\text{kuře}_{w_{17} t_{18}}, i_{16}] \wedge x_{15} =$

[jist., i<sub>16</sub>]<sub>w<sub>17</sub></sub>  $\wedge [[\mathbf{k}_{w_{17} t_{18}}, i_{10}]_{w_{17}}, x_{15}]) \dots \pi$

clause:

$\lambda w_{19} \lambda t_{20} [\mathbf{P}_{t_{20}}, [\mathbf{Onc}_{w_{19}}, \lambda w_{17} \lambda t_{18} (\exists i_{10}) (\exists i_{15}) (\exists i_{16}) ([\text{Does}_{w_{17} t_{18}}, On, [\text{Imp}_{w_{17}}, x_{15}]] \wedge$

[večeře]<sub>w<sub>17</sub> t<sub>18</sub></sub>, i<sub>10</sub>]  $\wedge [\text{pečený}<sub>w<sub>17</sub> t<sub>18</sub></sub>, i<sub>16</sub>]  $\wedge [\text{kuře}_{w_{17} t_{18}}, i_{16}] \wedge x_{15} =$$

[jist., i<sub>16</sub>]<sub>w<sub>17</sub></sub>  $\wedge [[\mathbf{k}_{w_{17} t_{18}}, i_{10}]_{w_{17}}, x_{15}])], \lambda t_{12} dnes_{t_{12}}] \dots \pi$

# Algoritmy syntaktické analýzy (pomocí CFG)

Vladimír Kadlec, Aleš Horák

E-mail: hales@fi.muni.cz  
[http://nlp.fi.muni.cz/poc\\_lingv/](http://nlp.fi.muni.cz/poc_lingv/)

## Obsah:

- ▶ Základní postupy pro syntaktickou analýzu obecných CFG
- ▶ Algoritmus CKY
- ▶ Tabulkové analyzátoru
- ▶ Tomitův zobecněný analyzátor LR
- ▶ Porovnání jednotlivých algoritmů

# Základní postupy pro syntaktickou analýzu obecných bezkontextových gramatik

- ▶ **obecná CFG** – rozsáhlá, (silně) víceznačná, s  $\epsilon$ -pravidly
- ▶ všechny uvedené algoritmy pracují s *polynomiální časovou a prostorovou složitostí*
- ▶ **algoritmus CKY – Cocke, Kasami, Younger;**
- ▶ **tabulková (chart) analýza** (neplést s LR tabulkou):
  - shora dolů (*top-down*);
  - zdola nahoru (*bottom-up*);
  - analýza řízená hlavou pravidla (*head-driven*);
- ▶ **Tomitův zobecněný algoritmus LR**

## Algoritmus CKY

- ▶ **Vstupy:**
  - řetězec lexikálních kategorií (preterminálních symbolů)  $a_1 \ a_2 \ \dots \ a_n$   
 např.: ADJ CONJ ADJ N V PREP N !
  - bezkontextová **gramatika**  $G = \langle N, \Sigma, P, S \rangle$ .
- ▶ **Výstup:**
  - efektivní reprezentace derivačních **stromů**.

- ▶ Gramatika musí být v Chomského normální formě.
- ▶ CNF (každá CFG jde do ní převést):  $A \rightarrow BC$   
 $D \rightarrow 'd'$
- ▶ Pro daný vstup délky  $n$  derivujeme podřetězce symbolů délky  $q$  na pozici  $p$ , značíme  $w_{p,q}$ ,  $1 \leq p, q \leq n$ .
- ▶ Derivace řetězců délky 1,  $A \Rightarrow w_{p,1}$ , je prováděno prohledáváním terminálních pravidel.
- ▶ Derivace delších řetězců  $A \Rightarrow^* w_{p,q}$ ,  $q \geq 2$  vyžaduje aby platilo  $A \Rightarrow BC \Rightarrow^* w_{p,q}$ . Tedy z  $B$  derivujeme řetězec délky  $k$ ,  $1 \leq k \leq q$ , a z  $C$  derivujeme zbytek, řetězec délky  $q - k$ . Tzn.  $B \Rightarrow^* w_{p,k}$  a  $C \Rightarrow^* w_{p+k,q-k}$ . Kratší řetězce máme tedy vždy "předpočítané".

## Algoritmus CKY pokrač.

```

program CKY Parser;
begin
 for p := 1 to n do V[p, 1] := {A|A → ap ∈ P };
 for q := 2 to n do
 for p := 1 to n - q + 1 do
 V[p, q] = ∅;
 for k := 1 to q - 1 do
 V[p, q] =
 V[p, q] ∪
 U {A|A → BC ∈ P, B ∈ V[p, k], C ∈ V[p + k, q - k]};
 od
 od
end

```

složitost CKY je  $O(n^3)$

## Algoritmus CKY, příklad – zadání

► vstupní gramatika je:

$$\begin{aligned} S &\rightarrow AA|BB|AX|BY|a|b \\ X &\rightarrow SA \\ Y &\rightarrow SB \\ A &\rightarrow a \\ B &\rightarrow b \end{aligned}$$

► vstupní řetězec je  $w = abaaba$ .

## Algoritmus CKY, příklad – řešení (matice V)

a b a a a b a

$$\begin{aligned} S &\rightarrow AA|BB|AX|BY|a|b \\ X &\rightarrow SA \\ Y &\rightarrow SB \\ A &\rightarrow a \\ B &\rightarrow b \end{aligned}$$

$p$  – pozice,  $q$  – délka

| $q \backslash p$ | 1           | 2           | 3           | 4      | 5      | 6      |
|------------------|-------------|-------------|-------------|--------|--------|--------|
| 1                | $S, A$      | $S, B$      | $S, A$      | $S, A$ | $S, B$ | $S, A$ |
| 2                | $Y$         | $X$         | $S, X$      | $Y$    | $X$    |        |
| 3                | $S$         | $\emptyset$ | $Y$         | $S$    |        |        |
| 4                | $X$         | $S$         | $\emptyset$ |        |        |        |
| 5                | $\emptyset$ | $X$         |             |        |        |        |
| 6                | $S$         |             |             |        |        |        |

## Tabulkové (chart) analyzátory

► Rozlišujeme tři základní typy tabulkových analyzátorů:

- shora dolů;
- zdola nahoru;
- analýza řízená hlavou pravidla.

► Mnoho dalších variant je popsáno v:

Sikkel Klaas: [Parsing Schemata: A Framework for Specification and Analysis of Parsing Algorithm](#), 1997.

- Neklade se žádné omezení na gramatiku.
- Analyzátoři typu "chart" v sobě většinou obsahují dvě datové struktury chart a agenda. Chart a agenda obsahují tzv. hrany.
- Hrana je trojice  $[A \rightarrow \alpha, \beta, i, j]$ , kde:
  - $i, j$  jsou celá čísla,  $0 \leq i \leq j \leq n$  pro  $n$  slov ve vstupní větě
  - $\alpha, \beta$  je řetězec slov v rozsahu  $i \dots j$  podle vstupní gramatiky.



## Obecný analyzátor typu "chart"

```

program Chart Parser;
begin
 inicializuj (CHART);
 inicializuj (AGENDA);
 while (AGENDA není prázdná) do
 E := vezmi hranu z AGENDA;
 for each (hrana F, která může být vytvořena pomocí
 hrany E a nějaké jiné hrany z CHART) do
 if ((F není v AGENDA) and (F není v CHART) and
 (F je různá od E))
 then přidej F do AGENDA;
 fi;
 od;
 přidej E do CHART;
 od;
end;

```

## Varianta shora dolů

### Inicializace:

- $\forall p \in P \mid p = S \rightarrow \alpha$  přidej hranu  $[S \rightarrow \bullet\alpha, 0, 0]$  do agendy.
- počáteční chart je prázdný.

### Iterace – vezmi hranu E z agendy a pak:

- (fundamentální pravidlo) pokud je E ve tvaru  $[A \rightarrow \alpha_0, j, k]$ , potom pro každou hranu  $[B \rightarrow \gamma_0 A \beta, i, l]$  v chartu vytvoř hranu  $[B \rightarrow \gamma A \bullet\beta, i, k]$ .
- (uzavřené hrany) pokud je E ve tvaru  $[B \rightarrow \gamma_0 A \beta, i, l]$ , potom pro každou hranu  $[A \rightarrow \alpha_0, j, k]$  v chartu vytvoř hranu  $[B \rightarrow \gamma A \bullet\beta, i, k]$ .
- (terminál na vstupu) pokud je E ve tvaru  $[A \rightarrow \alpha_0 a_{j+1} \beta, i, l]$ , vytvoř hranu  $[A \rightarrow \alpha a_{j+1} \beta, i, j+1]$ .
- (predikce) pokud je E ve tvaru  $[A \rightarrow \alpha_0 B \beta, i, l]$  potom pro každé pravidlo  $B \rightarrow \gamma \in P$ , vytvoř hranu  $[B \rightarrow \bullet\gamma, i, l]$ .

## Příklad – tabulkové analýzy (typu chart)

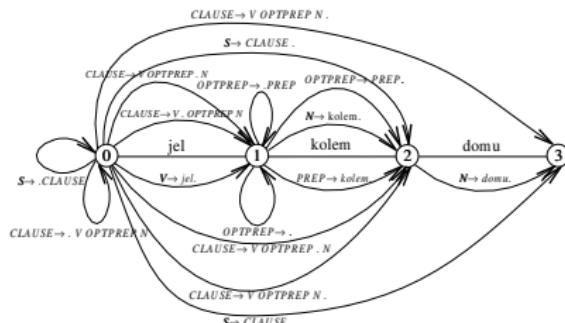
### Gramatika:

$$\begin{array}{l}
 S \rightarrow CLAUSE \\
 CLAUSE \rightarrow V OPTPREP N \\
 OPTPREP \rightarrow \epsilon \\
 OPTPREP \rightarrow PREP \\
 V \rightarrow jel \\
 PREP \rightarrow kolem \\
 N \rightarrow domu \\
 N \rightarrow kolem
 \end{array}$$

### Věta:

"jel kolem domu" ( $a_1=jel$ ,  $a_2=kolem$ ,  $a_3=domu$ ).

## Příklad – chart po analýze shora dolů



## Varianta zdola nahoru

### Inicializace:

- ▶  $\forall p \in P \mid p = A \rightarrow \epsilon$  přidej hrany  $[A \rightarrow \bullet, 0, 0], [A \rightarrow \bullet, 1, 1], \dots, [A \rightarrow \bullet, n, n]$  do agendy.
- ▶  $\forall p \in P \mid p = A \rightarrow a_i \alpha$  přidej hranu  $[A \rightarrow \bullet a_i \alpha, i-1, i-1]$  do agendy.
- ▶ počáteční chart je prázdný.

**Iterace** – vezmi hranu  $E$  z agendy a pak:

- (fundamentální pravidlo) pokud je  $E$  ve tvaru  $[A \rightarrow \alpha_\bullet, j, k]$ , potom pro každou hranu  $[B \rightarrow \gamma_\bullet A \beta, i, l]$  v chartu vytvoř hranu  $[B \rightarrow \gamma A \bullet \beta, i, k]$ .
- (uzavřené hrany) pokud je  $E$  ve tvaru  $[B \rightarrow \gamma_\bullet A \beta, i, l]$ , potom pro každou hranu  $[A \rightarrow \alpha_\bullet, j, k]$  v chartu vytvoř hranu  $[B \rightarrow \gamma A \bullet \beta, i, k]$ .
- (terminál na vstupu) pokud je  $E$  ve tvaru  $[A \rightarrow \alpha_\bullet a_{j+1} \beta, i, l]$ , potom vytvoř hranu  $[A \rightarrow \alpha a_{j+1} \bullet \beta, i, j+1]$ .
- (predikce) pokud je  $E$  ve tvaru  $[A \rightarrow \alpha_\bullet, i, l]$ , potom pro každé pravidlo  $B \rightarrow A \gamma$  vstupní gramatiky vytvoř hranu  $[B \rightarrow \bullet A \gamma, i, l]$ .

## Analýza řízená hlavou pravidla

### head-driven chart parsing

- ▶ **Hlava pravidla** – libovolný (určený) symbol z pravé strany pravidla. Například pravidlo  $CLAUSE \rightarrow V \text{ OPTPREP } N$  může mít hlavy  $V, OPTPREP, N$ .

▶ Epsilon pravidlo má hlavu  $\epsilon$ .

- ▶ Hrana v analyzátoru řízeném hlavou pravidla – trojice  $[A \rightarrow \alpha_\bullet \beta_\bullet \gamma, i, l]$ , kde  $i, j$  jsou celá čísla,  $0 \leq i \leq j \leq n$  pro  $n$  slov ve vstupní větě a  $A \rightarrow \alpha \beta \gamma$  je pravidlo vstupní gramatiky a hlava je v  $\beta$ .
- ▶ Algoritmus vlastní analýzy (varianta zdola nahoru) je podobný jednoduchému přístupu. Analýza neprobíhá zleva doprava, ale začíná na hlavě daného pravidla.

## Analyzátor řízený hlavou pravidla

### Inicializace:

- ▶  $\forall p \in P \mid p = A \rightarrow \epsilon$  přidej hrany  $[A \rightarrow \bullet\bullet, 0, 0], [A \rightarrow \bullet\bullet, 1, 1], \dots, [A \rightarrow \bullet\bullet, n, n]$  do agendy.
- ▶  $\forall p \in P \mid p = A \rightarrow \alpha a_i \beta$  ( $a_i$  je hlavou pravidla) přidej hranu  $[A \rightarrow \alpha \bullet a_i \beta, i-1, i]$  do agendy.
- ▶ počáteční chart je prázdný.

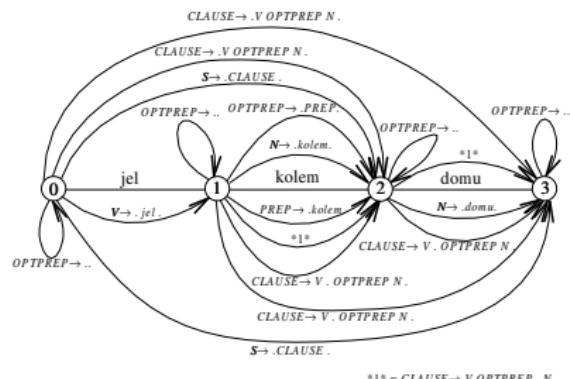
Je tato inicializace v pořádku?

## Analyzátor řízený hlavou pravidla pokrač.

**Iterace** – vezmi hranu  $E$  z agendy a pak:

- pokud je  $E$  ve tvaru  $[A \rightarrow \bullet \alpha_\bullet, j, k]$ , potom pro každou hranu  $[B \rightarrow \beta_\bullet \gamma_\bullet A \delta, i, l]$  v chartu vytvoř hranu  $[B \rightarrow \beta_\bullet \gamma_\bullet A \delta, i, k]$ .
- $[B \rightarrow \beta A_\bullet \gamma_\bullet \delta, k, l]$  v chartu vytvoř hranu  $[B \rightarrow \beta_\bullet A \gamma_\bullet \delta, j, l]$ .
- pokud je  $E$  ve tvaru  $[B \rightarrow \beta_\bullet \gamma_\bullet A \delta, i, l]$ , potom pro každou hranu  $[A \rightarrow \bullet \alpha_\bullet, j, k]$  v chartu vytvoř hranu  $[B \rightarrow \beta_\bullet \gamma_\bullet A \delta, i, k]$ .
- pokud je  $E$  ve tvaru  $[B \rightarrow \beta A_\bullet \gamma_\bullet \delta, k, l]$ , potom pro každou hranu  $[A \rightarrow \bullet \alpha_\bullet, j, k]$  v chartu vytvoř hranu  $[B \rightarrow \beta_\bullet A \gamma_\bullet \delta, j, l]$ .
- pokud je  $E$  ve tvaru  $[A \rightarrow \beta a_i \bullet \gamma_\bullet \delta, i, l]$ , potom vytvoř hranu  $[A \rightarrow \beta_\bullet a_i \gamma_\bullet \delta, i-1, l]$ .
- pokud je  $E$  ve tvaru  $[A \rightarrow \beta_\bullet \gamma_\bullet a_{j+1} \delta, i, l]$ , potom vytvoř hranu  $[A \rightarrow \beta_\bullet \gamma a_{j+1} \bullet \delta, i, j+1]$ .
- pokud je  $E$  ve tvaru  $[A \rightarrow \bullet \alpha_\bullet, i, l]$ , potom pro každé pravidlo  $B \rightarrow \beta A \gamma$  ve vstupní gramatice vytvoř hranu  $[B \rightarrow \beta_\bullet A \bullet \gamma, i, l]$  (symbol  $A$  je hlavou pravidla).

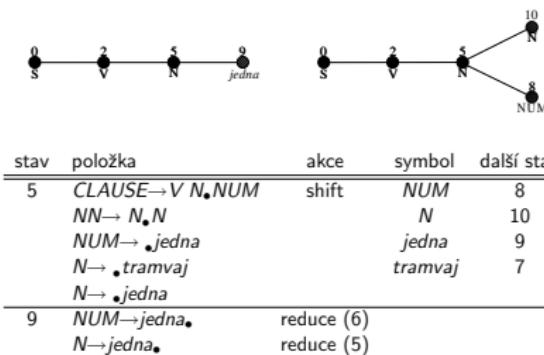
## Příklad – chart po analýze řízené hlavou pravidla



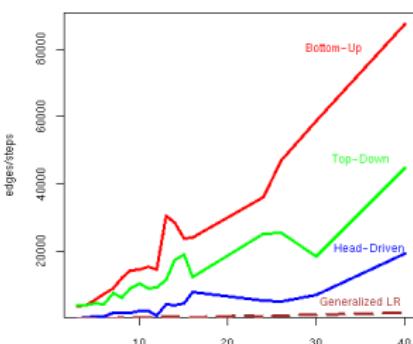
## Tomitův zobecněný analyzátor LR

- ▶ generalized LR parser (GLR)
- ▶ Masaru Tomita: Efficient parsing for natural language, 1986
- ▶ standardní LR tabulka, která může obsahovat konflikty;
- ▶ zásobník je reprezentován acyklickým orientovaným grafem (DAG);
- ▶ derivační stromy jsou uloženy ve sbaleném "lese" stromů.
- ▶ v podstatě stejný, jako algoritmus LR;
- ▶ udržujeme si seznam aktivních uzlů zásobníku (grau);
- ▶ akce redukce provádime vždy před akcemi čtení;
- ▶ akci čtení provádime pro všechny aktivní uzly najednou;
- ▶ kde je to možné, tam uzly slučujeme.

## Příklad konfliktu redukce/redukce



## Porovnání jednotlivých algoritmů



# Co to je korpus?

## Korpusy textů a jejich využití

Pavel Rychlý, Aleš Horák

E-mail: [hales@fi.muni.cz](mailto:hales@fi.muni.cz)  
[http://nlp.fi.muni.cz/poc\\_lingv/](http://nlp.fi.muni.cz/poc_lingv/)

### Obsah:

- ▶ Co to je korpus?
- ▶ Anglické a národní korpusy
- ▶ Formáty korpusů
- ▶ Korpusové manažery

- ▶ Co to je text, dokument?
  - lecos
- ▶ Různé typy korpusů
  - textové
  - mluvené
- ▶ Pro potřeby NLP
  - textový korpus

## Textový korpus

## Typy korpusů

- ▶ soubor textů
- ▶ charakteristiky
  - rozsáhlý (stovky mil. až mld. pozic/slov)
  - v jednotném formátu
  - strukturovaný
  - v elektronické podobě

- ▶ vždy záleží na účelu a způsobu použití
- ▶ možnosti
  - jazyk
  - typy textů
  - zdroj dat
  - značkování
  - ...

## První korpus

Brown

- ▶ americká angličtina (1961)
- ▶ Brown University, 1964
- ▶ gramatické značkování, 1979
- ▶ 500 textů, 1 mil. slov
- ▶ W. N. Francis & H. Kučera
  - první statistické charakteristiky angličtiny
  - relativní četnosti slov a slovních druhů

## SUSANNE

SUSANNE

- ▶ autor Geoffrey Sampson, Sussex University
- ▶ kniha *English for the Computer*
- ▶ část korpusu Brown ( $\frac{1}{4}$ )
- ▶ nové gramatické značkování
- ▶ syntaktické značkování

## BNC

British National Corpus

- ▶ britská angličtina, 10% mluva
- ▶ první velký korpus pro lexikografy
- ▶ vydavatelé slovníků (OUP) + univerzity
- ▶ 1991–1994, World Edition 2000
- ▶ ≈3000 textů, 100 mil. slov
- ▶ gramatické značkování automatickým nástrojem

## BoE

Bank of English

- ▶ britská angličtina
- ▶ COBUILD (HarperCollins), University of Birmingham
- ▶ 1991, stále rozšiřován
- ▶ 2002, ≈450 mil. slov

## Další národní korpusy

## Korpusy na FI

- ▶ Český národní korpus
  - ÚČNK, FF UK
  - SYN2000: 100 mil. slov
  - Litera, Synek, BMK, ...
- ▶ Slovenský, Maďarský, Chorvatský, ...
- ▶ Americký

vytvořené na FI, příklady:

- ▶ Desam
  - 1996, ručně značkovaný (desambiguovaný)
  - ≈1 mil. slov
- ▶ WWW
  - periodika z webu, z let 1996–1998
  - ≈100 mil.
- ▶ Chyby
  - práce studentů předmětu Základy odb. stylu s vyznačenými chybami
  - ≈400 tis.

## Korpusy na FI

## Formáty korpusů

### spolupráce

- ▶ Dopisy
- ▶ Mluv
- ▶ Kačenka
- ▶ ČNPK
- ▶ 1984
- ▶ Otto
- ▶ Italian
- ▶ Giga Chinese
- ▶ Francouzský, Slovinský, Britská angličtina, ...

- ▶ archiv/kolekce
  - různé formáty, podle zdroje/typu
- ▶ textové banky
  - jednotný formát a základní struktura
  - dokumenty/texty, základní metainformace
- ▶ vertikální text
- ▶ binární data v aplikaci
  - pomocné data pro rychlejší zpracování
    - indexy
    - statistiky

## Kódování znaků

- ▶ 8 bitů ≈ 256 znaků
  - ASCII – základ 7 bitů
  - kódování pro češtinu
    - ISO-Latin-2, Windows-1250, 852
- ▶ Unicode
  - 32bitů na znak
  - UTF-8
    - 1 až 4 byty na znak
  - UTF-16
    - 2 až 4 byty na znak

## Kódování metainformací

- ▶ escape-sekvence
  - speciální znak mění význam následujících znaků
  - \n, \t, & , <tag>
- ▶ SGML
  - Standard Generalised Markup Language
  - ISO 8879:1986(E)
- ▶ XML
  - Extensible Markup Language
  - W3C, 1998

## XML

- ▶ struktura popsána v DTD
- ▶ elementy
  - počáteční, koncová značka
  - <doc>, <head>, </head>, <g/>
- ▶ atributy elementů/značek
  - <doc title="Jak pejsek ..." author="Čapek">
  - <head type="main">
- ▶ entity
  - &gt;, &lt;, & , &acute;

## Standardy pro ukládání

- ▶ SGML/XML
- ▶ TEI
  - Text Encoding Initiative
  - TEI Guidelines for Electronic Text Encoding and Interchange
- ▶ CES, XCES
  - Corpus Encoding Standard

## Obsah korpusu

Co je v korpusu uloženo?

- ▶ text
- ▶ metainformace
- ▶ struktura dokumentu
  - odstavce, nadpisy, verše, věty
- ▶ značkování
  - informace o slovech
  - morfologie, základní tvary

## Tokenizace

Rozdělení textu do pozic

- ▶ token (pozice) = základní prvek korpusu
- ▶ větinou slovo, číslo, interpunkce
  - bude-li, don't
- ▶ může silně ovlivnit výsledky

## Vertikální text

- ▶ jednoduchý formát i jeho zpracování
  - každý token na samostatném řádku
  - struktury formou XML elementů
  - značkování odděleno tabulátorem
- ▶ podrobnosti
  - <http://www.fi.muni.cz/nlp/>
  - Informace pro současné a potenciální spolupracovníky
  - Textové korpusy
  - Popis vertikálů

## Zpracování textů na UNIXu

- ▶ coreutils
  - cat, head, tail, wc, sort, uniq, comm
  - cut, paste join, tr
- ▶ grep
- ▶ awk
- ▶ sed / perl

## Příklady použití coreutils

- ▶ slovník z vertikálního textu

```
cut -f 1 -s desam.vert |sort |uniq -c \
|sort -rn >desam.dict
```

- ▶ jednoduchá tokenizace

```
tr -cs 'a-zA-Z0-9' '\n' <GPL>GPL.vert
cat GPL.vert |sort |uniq -c |sort -rn >GPL.dict
```

## Korpusové manažery

nástroje na zpracování korpusů

- ▶ uložení textu
- ▶ editace/příprava textu
- ▶ značkování
- ▶ rozdělení do pozic (tokenizace)
- ▶ vyhledávání (konkordance)
- ▶ statistiky

## Systém Manatee

- ▶ korpusový manažer
- ▶ přímo podporuje
  - uložení textu
  - vyhledávání (konkordance)
  - statistiky
- ▶ externí nástroje
  - značkování
  - rozdělení do pozic

## Systém Manatee

hlavní zaměření

- ▶ velké korpusy
- ▶ rozsáhlé značkování
  - morfologické, syntaktické, metainformace
- ▶ návaznost na další aplikace/nástroje
  - korpusový editor, tvorba slovníků
- ▶ univerzalnost
  - různé jazyky, kódování, systémy značek

## Klíčové vlastnosti

- ▶ modulární systém
- ▶ přístup z různých rozhraní
  - grafické uživatelské rozhraní (Bonito)
  - aplikativní programové rozhraní (API)
  - příkazový řádek
- ▶ rozsáhlá data
  - až 2 mld. pozic
  - neomezeně atributů a metainformací
- ▶ rychlosť
  - vyhledávání, statistiky
- ▶ multihodnoty
  - zpracování víceznačných značkování
- ▶ dynamické atributy
  - vyhledávání a statistiky na počítaných datech
- ▶ subkorpusy
- ▶ silný dotazovací jazyk
  - dotazy na všechny atributy, metainformace
  - pozitivní/negativní filtry

## Klíčové vlastnosti

- ▶ frekvenční distribuce
  - víceúrovňová
  - všechny atributy a metainformace
- ▶ kolokace
  - různé statistické funkce

# Sémantika

## Sémantika a základní sémantické reprezentace

Aleš Horák

E-mail: [hales@fi.muni.cz](mailto:hales@fi.muni.cz)  
<http://nlp.fi.muni.cz/poc Lingv/>

Obsah:

- ▶ Sémantika
- ▶ Slovníky a encyklopedie
- ▶ Sémantické sítě
- ▶ Reprezentace slovesných valencí

**studium významu** – rozdílné, i když překrývající se přístupy různých vědeckých disciplín:

- ▶ **filosofie** – Jak je možné, že něco vůbec něco znamená?  
 Jaký typ relace musí být mezi X a Y, aby X znamenalo Y? (filosofie jazyka)
- ▶ **psychologie** – psycholingvistika – experimentální studie, jak jsou významy reprezentovány v mysli a jaké mechanismy ovlivňují při kódování a dekódování zpráv (délka odpovědi u konkrétního abstraktu se liší)
- ▶ **neurologie** – jak jsou psychologické stavy a procesy *implementovány* na úrovni neuronů

## Význam v jazyce

Rozdělení studia významu v jazyce:

- ▶ **lexikální sémantika**
- ▶ **gramatická sémantika** – větné fráze, slovotvorba
- ▶ **logická sémantika** – výroková, predikátová a vyšší logiky
- ▶ **lingvistická pragmatika**

*entail* = znamenat, vyplývat; nutnost a očekávanost

1. X přestal zpívat ?→? X nepokračoval ve zpěvu
2. X je kočka ?→? je zvíře
3. X je v jiném stavu ?→? X je žena
4. X je fyzikální objekt ?→? X má hmotnost
5. X je čtyřnožec ?→? X má čtyři nohy
6. X je žena Y ?→? X není dcera Y

## Princip kompozicionality

*Význam složeného tvrzení je funkcí významu jednotlivých komponent.*

(je určován, je odhadnutelný, každá složka hraje význam?)  
 omezení PK: idiomu, ustrnulé metafore, kolokace, klišé

*listém* je jazykový výraz, jehož význam není určen významy jeho částí (pokud existují), a který si tedy uživatel jazyka musí zapamatovat jako kombinaci formy a významu.

# Problémy při analýze přirozeného jazyka

## Víceznačnost

- ▶ víceznačnost
- ▶ anaforické výrazy
- ▶ indexické výrazy
- ▶ nejasnost
- ▶ nekompozicionalita
- ▶ struktura promluvy
- ▶ metonymie
- ▶ metafory

- ▶ *ambiguity*
- ▶ **víceznačnost** může být **lexikální, syntaktická, sémantická a referenční**
- ▶ lexikální – "stát,"      "žena,"      "hnát"
- ▶ syntaktická – "Jím špagety s masem."
  - "Jím špagety se salátem."
  - "Jím špagety s použitím vidličky."
  - "Jím špagety se sebezapřením."
  - "Jím špagety s přítelem."
- ▶ sémantická – "**Jeřáb** je vysoký."      "Viděli jsme veliké **oko**."
- ▶ referenční – "**Oni** přišli pozdě."      "Můžete mi půjčit **knihu**?"  
"Ředitel vyhodil dělníka, protože (**on**) byl agresivní."

## Anaforické a indexické výrazy

### anaforické výrazy:

- ▶ *anaphora*
- ▶ používají **zájmena** pro odkazování na objekty zmíněné **dříve**
- ▶ "Poté co se Honza s Marií rozhodli se vzít, (**oni**) vyhledali kněze, aby **je** oddal."  

- ▶ "Marie uviděla ve výloze prstýnek a požádala Honzu, aby **jí ho** kupil."  


### indexické výrazy:

- ▶ *indexicals*
- ▶ **odkazují** se na údaje v **jiných částech** promluvy
- ▶ "Já jsem **tady**."
- ▶ "Proč **jsi** to udělal?"

## Metafora a metonymie

### metafora:

- ▶ *metaphor*
- ▶ použití slov v **přeneseném významu** (na základě podobnosti), často systematicky
- ▶ "Zkoušel jsem ten proces **zabít**, ale nešlo to."
- ▶ "Bouře se **vtreká**."

### metonymie:

- ▶ *metonymy*
- ▶ používání **jména jedné věci** pro (často zkrácené) označení **věci jiné**
- ▶ "Čtu **Shakespearea**."
- ▶ "Chrysler oznamil rekordní zisk."
- ▶ "Ten **pstruh na másle** u stolu 3 chce další pivo."

## Nekompozicionalita

- ▶ *noncompositionality*
- ▶ příklady **porušení pravidla kompozicionality** u ustálených termínů nebo přednost jiného možného významu při určitých spojeních
- ▶ "aligátoří boty," "basketbalové boty," "dětské boty"
- ▶ "pata sloupu"
- ▶ "červená kniha," "červené pero"
- ▶ "bílý trpaslík"
- ▶ "dřevěný pes," "umělá tráva"
- ▶ "velká molekula"

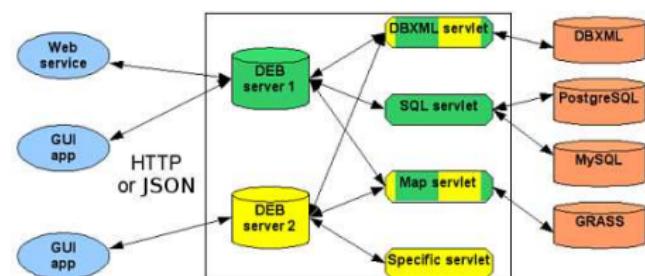
## Slovníky a encyklopédie

**Slovníky typicky obsahují:**

- ▶ specifikace **formy**:
    - grafická podoba – alternativy, dělení, velká počáteční písmena
    - zvuková podoba – výslovnost a její alternativy, slabiky, přízvuk, výška
  - ▶ **gramatické** (morpho-syntaktické) **informace** – slovní druh a příslušné gramatické kategorie, morfológický vzor?
  - ▶ specifikace **významu** – hierarchie
- slovník** uvádí významy listémů, **encyklopédie** informace o jejich denotátech  
specializované lexikony a encyklopédie (znalost odborníků a rozdílné  
předpoklady a pohledy)

## DEB – platforma pro vývoj slovníků

- ▶ platforma pro vývoj systémů na psaní slovníků
  - <http://deb.fi.muni.cz/>
  - pracuje s hesly ve formě XML struktury
- ▶ strikní klient-server architektura
- ▶ server
  - specializované moduly – *servlety*
  - databázové úložiště
- ▶ klient
  - jen jednoduchá funkcionality
  - GUI i web rozhraní – postavený na *Mozilla Engine*

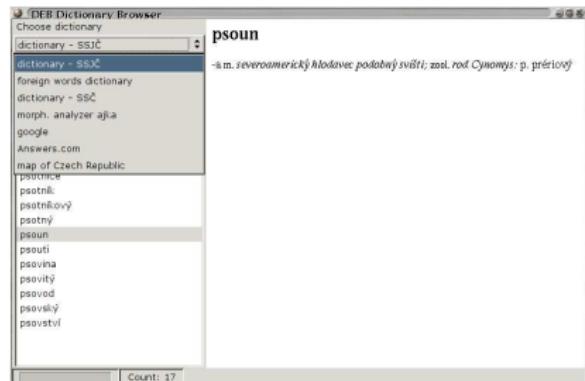


DEB používá komunikaci typu AJAX

# DEBDict – příklad DEB klienta

jednoduchý klient původně určený pro demo základních funkcí

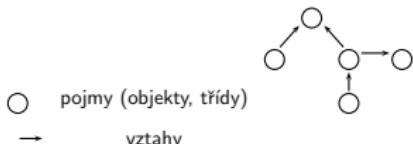
- ▶ dostupný jako instalovatelné rozšíření Firefoxu i jako vzdálená webová služba
- ▶ vícejazyčné uživatelské rozhraní (angličtina, čeština, další lze snadno doplnit)
- ▶ dotazy do několika XML slovníků s různou strukturou, výsledky jsou zpracovány XSLT transformací
- ▶ napojení na český morfologický analyzátor
- ▶ napojení na externí webové stránky (Google, Answers.com, Wikipedia)
- ▶ napojení na geografický informační systém – zobrazení geografických odkazů přímo na mapě



## Sémantické sítě

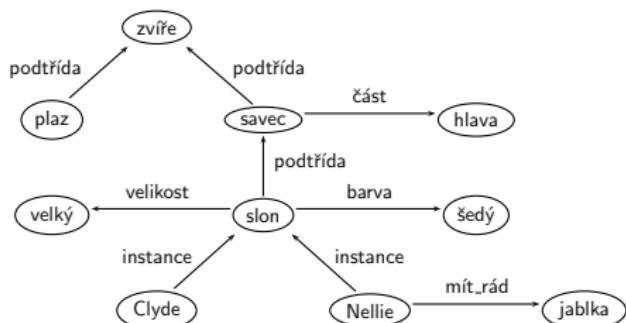
**sémantické sítě** – reprezentace faktových znalostí (pojmy + vztahy)

- ▶ vznikly kolem roku 1960 pro reprezentaci významu anglických slov
- ▶ znalosti jsou uloženy ve formě grafu



- ▶ nejdůležitější vztahy:
    - **podtřída** (subclass) – vztah mezi třídami
    - **instance** – vztah mezi konkrétním objektem a jeho rodičovskou třídou
- jiné vztahy – část (has-part), barva, ...

## Sémantické sítě – příklad



## Dědičnost v sémantických sítích

- ▶ pojem sémantické sítě *předchází* OOP
- ▶ **dědičnost:**
  - jestliže určitá vlastnost platí pro třídu → platí i pro všechny její podtřídy
  - jestliže určitá vlastnost platí pro třídu → platí i pro všechny prvky této třídy
- ▶ určení hodnoty vlastnosti – rekuzivní algoritmus
- ▶ potřeba specifikovat i výjimky – mechanizmus **vzorů** a **výjimek** (*defaults and exceptions*)
  - vzor – hodnota vlastnosti u třídy nebo podtřídy, platí ta, co je blíž objektu
  - výjimka – u konkrétního objektu, odlišná od vzoru

## Dědičnost vztahů část/celek

- ▶ "krávy mají 4 nohy."
  - každá noha je částí krávy
- ▶ "Na poli je (konkrétní) kráva."
  - všechny části krávy jsou taky na poli
- ▶ "Ta kráva (na poli) je hnědá (celá)."
  - všechny části té krávy jsou hnědé
- ▶ "Ta kráva je šťastná."
  - všechny části té krávy jsou šťastné – neplatí
- ▶ lekce: některé vlastnosti jsou děděny částmi, některé nejsou explicitně se to vyjadřuje pomocí pravidel jako  

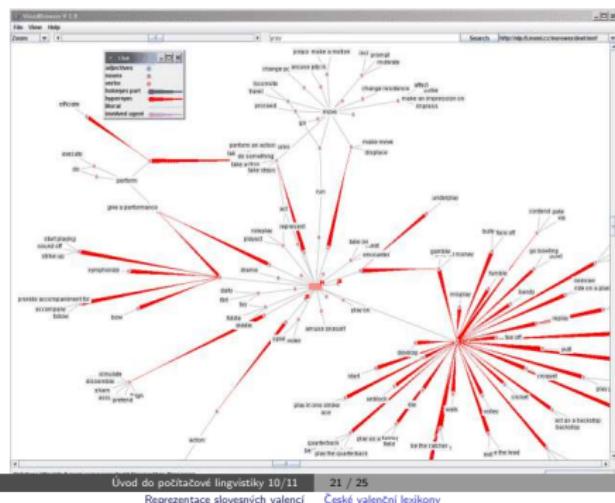
$$\text{part-of}(x, y) \wedge \text{location}(y, z) \Rightarrow \text{location}(x, z)$$

## Vzory a výjimky – příklad

- ▶ "všichni ptáci mají křídla."
- ▶ "všichni ptáci umí létat."
- ▶ "ptáci se zlomenými křídly jsou ptáci, ale neumí létat."
- ▶ "tučnáci jsou ptáci, ale neumí létat."
- ▶ "kouzelní tučňáci jsou tučňáci, kteří umí létat."
- ▶ kdo umí létat:
  - "Tweety je pták."
  - "Petřík je tučnák."
  - "Penelope je kouzelný tučnák."
- ▶ všimněte si, že víra v hodnotu vlastnosti objektu se může měnit s příchodem nových informací o klasifikaci objektu

## Aplikace sémantických sítí

- (Princeton) [WordNet](http://wordnet.princeton.edu/) – <http://wordnet.princeton.edu/>
- ▶ sématická síť 100.000 (anglických) pojmu, zachycuje:
    - synonyma, antonyma (významově stejná/opačná)
    - hyperonyma, hyponyma (podtřídy)
    - odvozenost a další jazykové vztahy
  - ▶ tvoří se **národní wordnety** (navázané na anglický WN) český wordnet – cca 30.000 pojmu
  - ▶ nástroj na editaci národních wordnetů – DEBVisDic, vyvinutý na FI MU
  - ▶ VisualBrowser – <http://nlp.fi.muni.cz/projekty/visualbrowser/> nástroj na vizualizaci (sémantických) sítí, vznikl jako DP na FI MU



## České valenční lexikony

zdroje (lexikony) slovesných valencí:

- ▶ syntaktické valenční rámce **Brief** (FI MU, od 1997) cca 15,000 sloves:  
lámat <v>hPTc4,hPTc4-hTc7,hPc3-hTc4
- ▶ valenční rámce v **českém wordnetu** (FI MU 2000), cca 3,000 slovesných literálů (sloveso+význam):  
synset: lámat:3, dobývat:1, těžit:2  
valence: kdo1\*AG(person:1)=co4\*SUBS(substance:1)  
valence: co1\*AG(institution:1)=co4\*SUBS(substance:1)
- ▶ pražský lexikon **Vallex 1.0**, na začátku roku 2005 cca 1,000 sloves (ted' snad až 4,000):  
- impf: lámat  
+ ACT(1;obl) PAT(4;obl)

Úvod do počítačové lingvistiky 10/11  
22 / 25  
Reprezentace slovesných valencí Valeční lexikon VerbaLex

## Valeční lexikon VerbaLex

- ▶ vznikl na začátku roku 2005, využívá všech dostupných zdrojů aktuálně se do něj doplňují slovesa z Briefu
- ▶ edituje se v jednoduchém textovém formátu, který se pro další zpracování převádí do XML
- ▶ vlastnosti:
  - dvouúrovňové sémantické role
  - odkazy na hypero/hyponymickou hierarchii v českém wordnetu
  - odlišení životnosti a neživotnosti větných členů
  - implicitní pozice slovesa
  - valenční rámců se odkazují na číslované významy sloves
- ▶ exporty z XML do HTML pro prohlížení a PDF pro tisk

## VerbaLex v HTML

alphabet | wlink | verb class | functors | forms | aspect | complexity | miscel. | search | home | help (?)

- \* A (18)
- \* B (101)
- \* C (11)
- \* C (18)
- \* D (457)
- \* E (6)
- \* F (13)
- \* G (80)
- \* H (14)
- I (8)
- J (14)
- K (70)
- L (24)
- M (64)
- N (249)
- O (315)
- P (572)
- R (64)
- R (42)
- S (217)
- S (25)
- T (25)
- U (360)
- V (469)
- Z (304)
- Z (29)

**dobývat<sup>1</sup><sub>impl</sub> / těžit<sup>2</sup><sub>impl</sub> / lámat<sup>3</sup><sub>impl</sub>**

[1] **dobývat<sub>1</sub>** / těžit<sub>2</sub> / lámat<sub>3</sub> \*

-frame: AG<person:<sub>1</sub><sub>obj</sub> VERB<sup>obj</sup> SUBS<substance:<sub>1</sub><sub>obj</sub>

-example: ned: lámal v dlech kámen

-synonym:

-use: prn

[2] **dobývat<sub>1</sub>** / těžit<sub>2</sub> / lámat<sub>3</sub> \*

-frame: AG<institution:<sub>1</sub><sub>obj</sub> VERB<sup>obj</sup> SUBS<substance:<sub>1</sub><sub>obj</sub>

-example: ned: tato společnost má mramor

-synonym:

-use: prn

# Logická analýza přirozeného jazyka

## Intenzionální sémantika, reprezentace znalostí

Aleš Horák

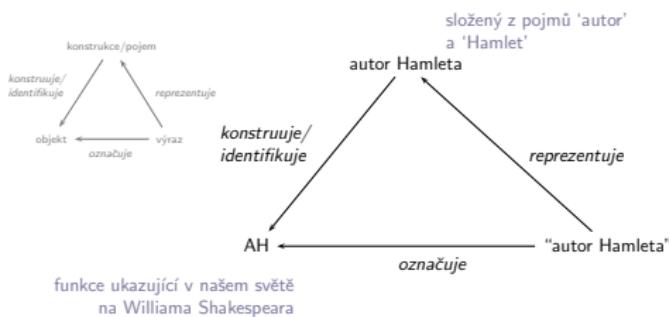
E-mail: hales@fi.muni.cz  
[http://nlp.fi.muni.cz/poc\\_lingv/](http://nlp.fi.muni.cz/poc_lingv/)

### Obsah:

- ▶ Intenzionální sémantika
- ▶ Reprezentace znalostí

## Vztah pojmu a výrazu

ve zjednodušené podobě: pojem odpovídá **logické konstrukci**



funkce ukazující v našem světě  
 na Williama Shakespeara

## Omezenost predikátové logiky 1. řádu

dva omezující rysy:

- ▶ nedostatečná expresivita
- ▶ extenzionalismus

**Expressivita:** vyjadřovací síla jazyka

"Je-li barva stropu pokoj č. 3 uklidňující, je pokoj č. 3 vhodný pro pacienta X a není vhodný pro pacienta Y."

analýza ve **výrokové logice**:

$$P \Rightarrow (Q \wedge \neg R) \quad P \quad \text{"Barva stropu pokoj č. 3 je uklidňující."} \\ Q \quad \text{"Pokoj č. 3 je vhodný pro pacienta X."} \\ R \quad \text{"Pokoj č. 3 není vhodný pro pacienta Y."}$$

analýza v **PL1**:

$$U(B) \Rightarrow (V(P, X) \wedge \neg V(P, Y)) \quad U \quad \text{třída uklidňujících objektů} \\ B \quad \text{individuum "barva stropu pokoj č. 3"} \\ V \quad \text{relace mezi individuji "být vhodný pro"} \\ P \quad \text{individuum "pokoj č. 3"} \\ X, Y \quad \text{individua "pacient X" a "pacient Y"}$$

## Nedostatečná expresivita PL1 – pokrač.

Červená barva je krásnější než hnědá barva. Kostka je červená.

analýza v PL1:

$Kr(\check{c}_1, H)$

$\check{c}_2(Ko)$

$\check{c}_1$  individuum 'červená barva'

$\check{c}_2$  vlastnost individu 'být červený' (třída červených objektů)

nelze vyjádřit       $\check{c}_1 \equiv \check{c}_2$

## Extenzionalismus PL1

Varšava

hlavní město Polska

Varšava

– jméno individua, jasně identifikovatelné a odlišitelné

hlavní město Polska

– individuová role, momentálně identifikuje Varšavu, ale dříve to byl i Krakov

'hlavní město Polska':

- ▶ závisí na světě a čase
- ▶ pochopení významu, ale není vázané na znalost obsahu – tj. význam na světě a čase nezávisí

číslo X je větší než číslo Y

budova X je větší než budova Y

matematické větší než – relace dvojic čísel, pevně daná

empirické větší než – vztah dvou individuí, který se může měnit v čase (otec a syn)

## Extenzionalismus PL1 – pokrač.

ano

V Brně prší

ano – pravdivostní hodnota true

V Brně prší – propozice – označuje pravdivostní hodnotu, která se mění (alespoň) v čase

i když hodnota někdy závisí na světě a čase, samotný význam na nich nezávisí

## Extenze a intenze

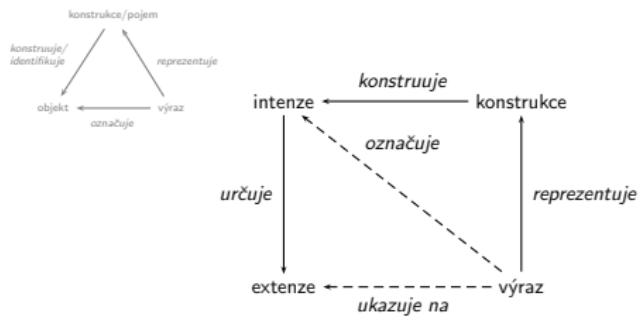
Definujeme:

- ▶ intenze – objekty typu funkcí, jejichž hodnoty závisí na světě a čase
- ▶ extenze – ostatní objekty (na světě a čase nezávislé)

časté extenze a intenze:

| extenze              | intenze          |
|----------------------|------------------|
| individua            | individuové role |
| třídy                | vlastnosti       |
| relace               | vztahy           |
| pravdivostní hodnoty | propozice        |
| funkce               | empirické funkce |
| čísla                | veličiny         |

## Rozšířený vztah výrazu a významu u intenzi



## Rozšířený vztah výrazu a významu u intenzi



## Transparentní intenzionální logika

- ▶ *Transparent Intensional Logic, TIL*
- ▶ logický systém speciálně navržený pro zachycení **významu výrazů PJ**
- ▶ autor Pavel Tichý: *The Foundations of Frege's Logic*, de Gruyter, Berlin, New York, 1988.
- ▶ obdobná teorie – *Montagueho intenzionální logika* – Tichý ukazuje její nedostatky
- ▶ Tichý vychází z myšlenek – Gottlob Frege (1848 – 1925, logik) a Alonzo Church (1903 – 1995, teorie typů)
- ▶ vlastnosti:
  - rozvětvená **typová hierarchie** (s typy **vyšších řad**)
  - **temporální**
  - **intenzionální** (intenzie × extenze)
- ▶ **transparentost**:
  1. nositel významu (**konstrukce**) není prvek formálního aparátu, tento aparát pouze **studuje** konstrukce
  2. zachycení intenzionality je přesně popsáno z matematického hlediska

otázka:

Jak zapíšeme znalosti o problému/doméně?

Když je zapíšeme, můžeme z nich mechanicky odvodit nová fakta?

- ▶ **reprezentace znalostí** (*knowledge representation*) – hledá způsob vyjádření znalostí počítačově zpracovatelnou formou (za účelem odvozování)
- ▶ **vyzovování znalostí** (*reasoning*) – zpracovává znalosti uložené v **bázi znalostí** (*knowledge base, KB*) a provádí **odvození** (*inference*) nových závěrů:
  - odpovědi na dotazy
  - zjištění faktů, které vyplývají z faktů a pravidel v KB
  - odvodit akci, která vyplývá z dodaných znalostí, ...

## Reprezentace znalostí

proč je potřeba speciální **reprezentace znalostí**?

**vnímání lidí × vnímání počítačů**

► člověk

- ▶ když dostane novou věc (třeba pomeranč) – **prozkoumá a zapamatuje** si ho (a třeba sní)
- ▶ během tohoto procesu člověk zjistí a uloží všechny základní vlastnosti
- ▶ později, když se **zmíní** daná věc, vyhledají se a připomenou uložené informace

► počítač

- ▶ musí se spolehnout na informace od lidí
- ▶ jednodušší informace – přímé **programování**
- ▶ složité informace – zadáné v **symbolickém jazyce**

## Volba reprezentace znalostí

která **reprezentace znalostí** je **nejlepší**?

*Pro řešení skutečně obtížných problémů musíme použít několik různých reprezentací. Důvodem pro to je to, že každý typ datových struktur má své přínosy i nedostatky a žádná z nich není adekvátní pro všechny různé funkce používané v tom, čemu říkáme "zdravý rozum" (common sense).*

– Marvin Minsky

## Reprezentace znalostí pomocí logiky nebo sém. sítí

### Logika:

- ▶ znalosti uloženy ve formě **logických formulí**
- ▶ vyvozování nových znalostí = hledání **důkazu**

### Sémantické sítě:

- ▶ reprezentace faktových znalostí (pojmy + vztahy)
- ▶ znalosti jsou uloženy ve formě grafu
- ▶ nejdůležitější vztahy:
  - **podtřída** (*subclass*) – vztah mezi třídami
  - **instance** – vztah mezi konkrétním objektem a jeho rodičovskou třídou
- jiné vztahy – část (has-part), barva, ...

## Rámce

### Rámce (frames):

- ▶ varianta sémantických sítí
- ▶ velice populární pro reprezentaci znalostí v expertních systémech
- ▶ všechny informace relevantní pro daný pojem se ukládají do univerzálních struktur – **rámci**
- ▶ stejně jako sémantické sítě, rámce podporují dědičnost
- ▶ OO programovací jazyky vycházejí z teorie rámčů

## Rámce – příklad

rámec obsahuje **objekty**, **sloty** a **hodnoty slotů**

příklady rámci:

**savec:**

|                    |       |
|--------------------|-------|
| <i>podtížda:</i>   | zvíře |
| <i>část:</i>       | hlava |
| <i>*má_kožich:</i> | ano   |

**slon:**

|                   |       |
|-------------------|-------|
| <i>podtížda:</i>  | savec |
| <i>*barva:</i>    | šedá  |
| <i>*velikost:</i> | velký |

**Nellie:**

|                  |        |
|------------------|--------|
| <i>instance:</i> | slon   |
| <i>mít_rád:</i>  | jablka |

## Sémantické síť × rámce

| sémantické síť             | rámce         |
|----------------------------|---------------|
| uzly                       | objekty       |
| spoje                      | sloty         |
| uzel na druhém konci spoje | hodnota slotu |

**deskripcní logika** – logický systém, který manipuluje přímo s rámcí

'\*' označuje **vzorové hodnoty**, které mohou měnit hodnoty u podtíží a instancí

## Pravidlové systémy

- snaha zachytit **produkčními pravidly** znalosti, které má expert
- obecná forma pravidel

*IF*      *podmínka*  
*THEN*    *akce*

- podmínky – booleovské výrazy, dotazy na hodnoty **proměnných**
- akce – nastavení hodnot proměnných, příznaků, ...

- důležité vlastnosti:

- znalosti mohou být strukturovány do modulů
- systém může být snadno rozšířen přidáním nových pravidel bezem změny zbytku systému

## Pravidlová báze znalostí – příklad

pravidla pro **oblékání**:

pravidlo 1 IF X je seriózní  
 AND X bydlí ve městě  
 THEN X by měl nosit sako

pravidlo 2 IF X je akademik  
 AND X je společensky aktivní  
 AND X je seriózní  
 THEN X by měl nosit sako a  
 kravatu

pravidlo 3 IF X bydlí ve městě  
 AND X je akademik  
 THEN X by měl nosit sako  
 kravatu

pravidlo 4 IF X je podnikatel  
 AND X je společensky aktivní  
 AND X je seriózní  
 THEN X by měl nosit sako,  
 ale ne kravatu

**společenská** pravidla:  
 pravidlo 5 IF X je podnikatel  
 AND X je ženatý  
 THEN X je společensky  
 aktivní

pravidlo 6 IF X je akademik  
 AND X je ženatý  
 THEN X je seriózní

**profesní** pravidla:  
 pravidlo 7 IF X učí na univerzitě  
 OR X učí na vysoké škole  
 THEN X je akademik

pravidlo 8 IF X vlastní firmu  
 OR X je OSVČ  
 THEN X je podnikatel

## Expertní systémy

- ▶ aplikace pravidlových systémů
- ▶ zaměřeny na specifické oblasti – medicínská diagnóza, návrh konfigurace počítače, expertiza pro těžbu nafty, ...
- ▶ snaha zachytit **znalosti experta** pomocí pravidel ale znalosti experta zahrnují – postupy, strategie, odhady, ...
- ▶ expertní systém musí pracovat s procedurami, nejistými znalostmi, různými formami vstupu
- ▶ vhodné oblasti pro nasazení expertního systému:
  - **diagnóza** – hledání řešení podle symptomů
  - **návrh konfigurace** – složení prvků splňujících podmínky
  - **plánování** – posloupnost akcí splňujících podmínky
  - **monitorování** – porovnání chování s očekávaným chováním, reakce na změny
  - **řízení** – ovládání složitého komplexu
  - **předpověď** – projekce pravděpodobných závěrů z daných skutečností
  - **instruktáz** – inteligenční vyučování a zkoušení studentů

## Nejistota a pravděpodobnost

definujme akci  $A_t$  jako „**Vyrazit na letiště t hodin před odletem letadla.**“ jak najít odpověď na otázku „**Dostanu se akcí  $A_t$  na letiště včas?**“

problémy:

1. částečná pozorovatelnost (stav vozovky, záměry ostatních řidičů, ...)
2. šum v senzorech (hlášení o dopravní situaci)
3. nejistota výsledků akcí (píchnutí kola, ...)
4. obrovská složitost modelování a předpovědi dopravní situace

čistě logický přístup tedy:

- ▶ riskuje chybu – „ $A_5$  mě tam dostane včas.“
- ▶ vede k závěrům, které jsou příliš slabé pro rozhodování: „ $A_5$  mě tam dostane včas, pokud nebude na dálnici nehoda a pokud nebude přesná jestli nepíchnu kolo ...“

## Metody pro práci s nejistotou

- ▶ defaultní/nemonotonné logika  
Předpokládajme, že nepíchnu cestou kolo.  
Předpokládajme, že  $A_5$  bude OK, pokud se nenajde protipříklad.
- ▶ pravidla s faktory nejistoty  
 $A_5 \rightarrow_{0,3}$  dostat se na letiště včas.  
zalévání  $\rightarrow_{0,99}$  mokrý trávník  
mokrý trávník  $\rightarrow_{0,7}$  dešť
- ▶ pravděpodobnost  
Vzhledem k dostupným informacím,  $A_3$  mě tam dostane včas s pravděpodobností 0.05.

# Guessер

## Vybrané aktuální projekty Laboratoře NLP

Pavel Šmerk, Miloš Husák

E-mail: xsmerk@fi.muni.cz, xhusak@fi.muni.cz  
[http://nlp.fi.muni.cz/poc\\_lingv/](http://nlp.fi.muni.cz/poc_lingv/)

### Značkování českých neznámých slov

Pavel Šmerk  
[xsmerk@fi.muni.cz](mailto:xsmerk@fi.muni.cz)

#### Obsah:

- ▶ Guesser – značkování českých neznámých slov
- ▶ GDEX – Good Dictionary Examples

## Problém

Není možné mít všechna slova, která lze při zpracování přirozeného jazyka "potkat", předem ve slovníku. Je tedy potřeba umět řešit situaci, kdy slovo ve slovníku není.

Potřebné informace o neznámém slovu mohu odhadnout buďto z jeho větného kontextu, nebo z jeho podoby, konkrétně z jeho konce. Optimální řešení bude pochopitelně kombinovat oba přístupy.

Dále bude řeč o druhé variantě. Tedy dostanu slovo *napipetovaná*, řeknu si, aha, to je jako *malovaná*, tedy lemma *napipetovaný* podle *malovaný*, značky stejné.

## Produktivita

Čeština má relativně velké množství vzorů pro ohýbání i odvozování slov. Velká část z nich ale není v součastnosti "produktivních", jsou to jen pozůstatky z minulosti (*den, husa, myš, kost; dřevěný vs. umakartový, ...*), případně jsou produktivní jen nějak omezeně (*pařba x \*krvácbə*).

Nově se objevující česká slova budou tedy patřit k nějaké podmnožině produktivních vzorů. Při odhadování konkrétního vzoru budou neproduktivní vzory nadbytečné, naopak dokonce budou tvořit šum a "překážet". My ale (zatím) nemáme informaci, které vzory jsou produktivní.

## Předpoklad

Můžeme předpokládat, že slovníky zahrnují všechna nepravidelně se chovající slova, která lze reálně "potkat" (pokud bychom se dostali k nějakému historickému textu, nemuselo by to tak být). Zároveň byly jistě tvořeny se snahou o co největší pokrytí reálného jazyka. To znamená, že se přidávala "nová", pravidelně se chovající slova, např. z různých oborů.

Jde si to představit i jinak: máme-li 390 000 lemmat, není možné, aby naprostá většina z nich nebyla pravidelná, to by člověk nezvládl udržet v hlavě.

Pak si lze myslet, že to, co je produktivní, poznáme podle četnosti ve stávajících datech. Cílem je tedy z dat extrahat jen jejich produktivní (častou) část a pouze na jejím základě pak odhadovat morfologické vlastnosti neznámých slov.

## Konstrukce dat pro guesser

- ▶ ze slovníku ajky (.dic) vyhodíme lemmata od vzorů, u kterých je méně než 20 lemmat (tedy cca 6000 lemmat z 390 000, 55 000 slovních tvarů)
- ▶ pro všechny tvary každého lemmatu vygeneruju trojice word-lemma-tag ve formátu  
`abaraks:a:k1gMnSc2,k1gMnSc4,`  
 kde nejprve je obrácený slovní tvar, dále, co musím utrhnut, a za další dvojtečkou, co musím přidat, abych dostal lemma, nakonec značky
- ▶ beru jen slova délky alespoň 7, vyhazuju eN, d3 a věci mimo k[1256], neberu wH a pod.
- ▶ setřídím podle abecedy (nikoli česky)

## Konstrukce dat pro guesser

- ▶ procházím a zaznamenávám do pole, min. kořen 3 znaky, max. konec 10 znaků
- ▶ pokud v daném místě pole bylo něco jiného, zkusím vypsat. Pro výpis to musí mít aspoň 20 výskytů, jednotlivé značky aspoň 10x, pokud je něčeho více než 20x méně než zbytku, ignoruju.
- ▶ vypsané odečítám od levých podřetězců
- ▶ setřídím podle abecedy
- ▶ slučuju stejně věci (s ohledem na počty), ignoruju vid
- ▶ setřídím retrográdně kvůli snadnému nacpní do \$re (...|ab|a), viz dále

## Použití

- ▶ hádáná slova otáčím a zkouším `=~ /($re).{$minroot}/ # $minroot == 3`
- ▶ díky "uspořádání" `/^(ab|a)/` se pro abxyz namatchuje ab, a nikoli a, tedy obecně nejdélší možný konec
- ▶ k nalezenému konci slova mám v hashi info o změně konce na lemma a příslušných značkách

`/nlp/projekty/rule.ind/stat/guesser.pl`, očekává vertikál, případně označovaný něčím jako ajka `-c` – (existující značkování ponechává beze změny)

Problém: zdaleka ne všechna neznámá slova jsou česká, tedy začleněná do systému jazyka. Zejména asi nesklonné názvy, jména, případně i cizojazyčná slova či celé citáty. Hodně z nich by asi bylo možné odhadovat pomocí velkého písmena na začátku a absence diakritiky. Zatím nijak netestováno/neřešeno.

## Good Dictionary EXamples

### Dobré slovníkové příklady

Miloš Husák  
xhusak@mail.muni.cz

## Slovníkový příklad

crawl

161

~~PREVIEW~~ **crawl<sup>1</sup>** /krɔ:l/ **v. [intransitive]** **be crawling with** 1 to be too full of something: *The town was crawling with police.* 2 to be full of unpleasant insects or animals



crawl

**crawl<sup>2</sup>** /krɔ:l/ **noun [singular]** 1 a very slow speed 2 a style of swimming in which you move one arm over your head and then the other while you are kicking your legs

**crayon** /kreɪən/ **noun [C]** a stick of coloured wax that is used for drawing

**craze** /kreɪz/ **noun [C]** something that suddenly becomes very popular for a short time

**crazed** /kreɪzd/ **adj** completely crazy and

credit

**crease<sup>2</sup>** /kri:s/ **v[intransitive]** to make lines on cloth or paper by folding or crushing it, or to become covered in these lines

**crazy** /'kreɪzɪ/ **adj** informal **\*\*** not at all sensible or practical: *It's crazy.* Who would do a thing like that? **▲ be crazy to do sth** She knew she would be completely crazy to refuse.

**crazy about** **sb** very much in love with someone: *I'm crazy about my boyfriend.* **crazy about sth** very enthusiastic about something: *I'm crazy about swimming.* **drive sb crazy** to make someone very annoyed go **crazy** **2** to become very angry about something **2** to become very bored and uninterested: **to become very excited** like crazy to a very great degree = **MAD:** *The games are selling like crazy.* **crazily** **adv**

C

### Words that may cause offence: crazy

Avoid using words like crazy, mad, and insane about people who have mental illnesses or mental health problems. Instead, use an expression such as mentally ill.

Jak jsem ke slovníkům přišel/přešel

Cíl práce

- ▶ brigáda "na léto"
- ▶ řecký korpus
- ▶ ohodnocování slovníkových příkladů
- ▶ Python, Manatee, SkE, WebBootCat ....
- ▶ bakalářská práce

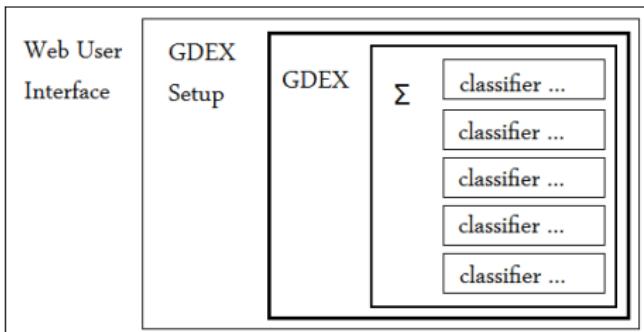
Zautomatizovat (alespoň částečně) vyhledávání slovníkových příkladů v korpusu.

- ▶ zjistit, jak se dobré příklady dají rozpoznat
- ▶ zkombinovat různé přístupy
- ▶ vytvořit snadno použitelné rozhraní

## Dobrý příklad je ...

- ▶ informativní, samopopisný
  - pozice slova ve větě
  - synonyma
  - redundancy
- ▶ snadno čitelný
  - jednoduchá větná struktura
  - krátká slova
  - běžná jména (politické problémy)
  - častá slovní spojení

## GDEX



## GDEX

GDEX je srdcem a tělem ohodnocování vět.

- ▶ hostí hlavní klasifikátor
- ▶ poskytuje jednotné rozhraní všem klasifikátorům
- ▶ spravuje dostupné prostředky

## Klasifikátory

Klasifikátory jsou mozkem ohodnocování vět.

- ▶ každou větu ohodnotí číslem z < 0,1 >
- ▶ silné a slabé klasifikátory
- ▶ délka vět, délka slov, četnost slov, počty významů, ...
- ▶ vážený průměr, progresivní skóre, přibližné progresivní skóre

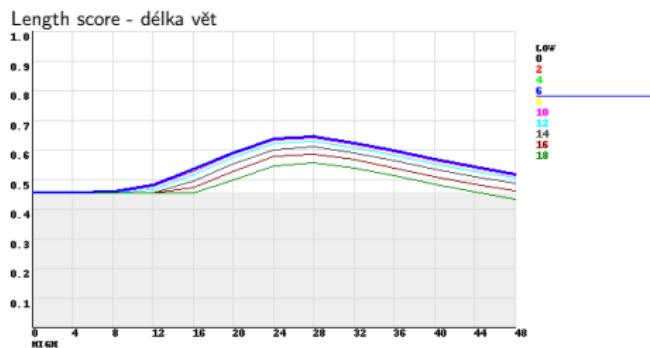
# Měření efektivity

$$\text{benchmark} = 1 - \frac{\sum_{i \in \text{concordances}} \sum_{j \in \text{goodexamples}_i} n_{i,j}}{\sum_{i \in \text{concordances}} |\text{goodexamples}_i| + 1}$$

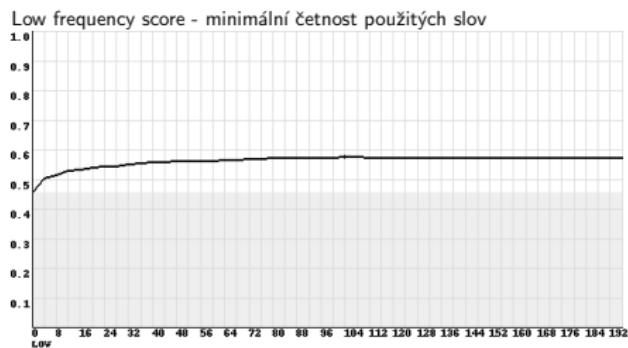
# Měření efektivity

- ▶ průměrná pozice dobrých slovníkových příkladů
- ▶ ručně značkované konkordance
- ▶ optimalizace parametrů klasifikátorů
- ▶ vyvažování důležitostí klasifikátorů

## Dobrý klasifikátor I.

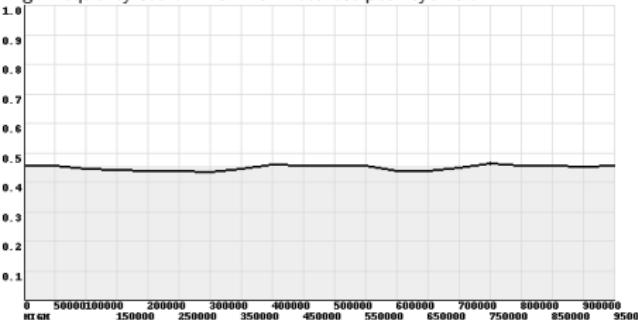


## Dobrý klasifikátor II.



# Špatný klasifikátor

High frequency score - maximální četnost použitých slov



# Ukázky

- ▶ GDEX Setup
- ▶ Sketch Engine
- ▶ GDEX Demo Dictionary

## GDEX Setup

Config file Constants Classifiers Preview Learn Archive

| Name                | Weight              | Parameters                              |
|---------------------|---------------------|-----------------------------------------|
| weighted score      | 0 (selected)        | 0                                       |
| length score        | 1 (selected)        | LOW: 10 HIGH: 25                        |
| low frequency score | 1 (selected)        | LOW: 44                                 |
| verbs score         | 2 (selected)        | VERBNUM: 3                              |
| position score      | 1 (selected)        | IDEAL: 0.2 TOLERANCE: 0.6               |
| whole sentence      | 3 (selected)        | MAX: 7 PENALTY: 0.2                     |
| long words score    | 1 (selected)        | WORDLIST: ['the', 'be', 'to'] MIN: 0.25 |
| wordlist min        | 3 (selected)        | FUNC: DICE                              |
| all colloc. avg     | 2 (all colloc. avg) |                                         |

Strong classifier

## SketchEngine

<http://beta.sketchengine.co.uk/>

Home Concordance Word List Word Sketch Thesaurus Sketch-Dict View Corpus: British National Corpus conc decription

### View options

Attributes Structures References

|                                          |           |               |
|------------------------------------------|-----------|---------------|
| <input checked="" type="checkbox"/> word | <bn:doc>  | Token number  |
| <input type="checkbox"/> amntag          | <text>    | bn:doc.id     |
| <input type="checkbox"/> lempos          | <s>       | bn:doc.date   |
| <input type="checkbox"/> tag             | <p>       | bn:doc.author |
| <input type="checkbox"/> lemma           | <align>   | bn:doc.title  |
| <input type="checkbox"/> lc              | <caption> | bn:doc.info   |

Display attributes

For each token

KWIC tokens only

Page size (number of lines): 20

KWIC Context size (number of characters): 40

Icon for one-click sentence copying

Sort concordance lines best-first. Number of lines to be sorted: 100

# GDEX Demo Dictionary

<http://forbetterenglish.sketchengine.co.uk/>

The GDEX Demo Dictionary  
 This is an experimental automatic collections dictionary, based on the Sketch Engine technology. Models are described in López et al. (2008). GDEX is automatically building and storing examples in a corpus. Proc. EURALEC, Barcelone, Spain.  
 See on [English](#) website to see its collection, such file as example entries.

| <a href="#">[edit]</a> |                                                                                                             |
|------------------------|-------------------------------------------------------------------------------------------------------------|
| <b>example_30</b>      |                                                                                                             |
| <b>BEAT</b>            | There are some examples of good practice being carried out by firms on a daily basis.                       |
| <b>architecture</b>    | Was that, then, the case of the original building, originally 1793, now a striking example of               |
| <b>type</b>            | The following is one of the numerous types of good practice which have been identified                      |
| <b>lead</b>            | That was the case of the first edition of the book in 1912, when a considerable number of                   |
| <b>process</b>         | Good practice is also a process, consisting of a series of steps.                                           |
| <b>theory</b>          | (An example of the latter is the specific knowledge underlying scientific findings, although there          |
| <b>object_of</b>       | We can also measure examples through looking in connection with this topic.                                 |
| <b>give</b>            | Here we give two examples of companies that are leading a way to the adoption of                            |
| <b>follow</b>          | Following the example of the first edition, the second edition can also follow another source of the        |
| <b>others</b>          | Following example, the first edition of the book was followed by the second.                                |
| <b>etc</b>             | More Than That have a slightly different formula when it comes a good example to be seen.                   |
| <b>see</b>             | See our own example on the other page about <a href="#">Santos</a> .                                        |
| <b>examples</b>        | The following is one of the numerous types of good practice which have been identified                      |
| <b>period</b>          | As actions the third period of time is the period of time in which the firm would be given complete freedom |
| <b>period</b>          | To assess the third period of time in which the firm would be given complete freedom                        |
| <b>for</b>             | The following is one of the numerous types of good practice which have been identified                      |
| <b>choose</b>          | Physics is a classic example of cognitive as studies                                                        |
| <b>already</b>         | Adolescent children seem to make more than one reference to lead to the same effect, or in the              |
| <b>everdifferent</b>   | An ever-different example is that the Chinese are known as Chinese scholars.                                |
| <b>examples</b>        | The following is one of the numerous types of good practice which have been identified                      |
| <b>examples</b>        | As an example we provide both the business side and the academic side.                                      |

# Budoucí práce

- ▶ implementovat další klasifikátory
- ▶ naučit GDEX i na jiných datech/jazyčích
- ▶ reimplementovat GDEX v C/C++