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

Organizace předmětu IB030

Hodnocení předmětu:

- závěrečná písemka (max **80 bodů**)
  - dva řádné a jeden opravný termín
- průběžný úkol (max **20 bodů**)
- navíc možnost **1 bodu** za netriviální vylepšení slajdů
- 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 slajdy)
- 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 – programátorský

- dva **typy** – *programátorský* × *lingvistický*
- **programátorský úkol** – **upravit** některou z dostupných jazykových knihoven pro **češtinu**:
  - **NLTK – Natural Language Toolkit** `http://www.nltk.org`
  - **C&C Tools** `http://svn.ask.it.usyd.edu.au/trac/candc/wiki`
  - **Field Linguist's Toolbox** `http://www.sil.org/computing/toolbox/`
  - **FreeLing** `http://nlp.lsi.upc.edu/freeling/`
  - **Stanford University Natural Language Software** `http://nlp.stanford.edu/software/`
  - **IBM LanguageWare Resource Workbench** `http://alphaworks.ibm.com/tech/lrw`
- 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 **18. května 2010**
- **hodnocení** bude od 0 do 20 bodů podle:
  - složitosti vybraného algoritmus
  - kvality zpracování algoritmu i dokumentace

Samostatný hodnocený úkol – lingvistický

- **lingvistický úkol** – **značkování** argumentů **slovesných valencí** v korpusu
  - čeština, 800 vět
  - nástroj pro značkování vyvinutý Markem Grácem

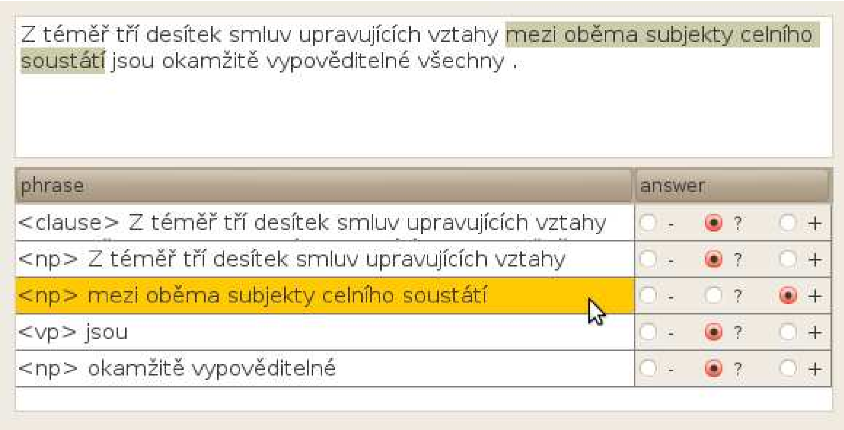

- k **odevzdání** je zapotřebí:
  - oznámit včas výběr úkolu a získat svoji sadu vět
  - odeslat výsledek v ZPIu e-mailem přednášejícímu (**Subject: IB030 – odevzdani ukolu**) do **4. května 2010**
- **hodnocení** bude od 0 do 20 bodů podle:
  - kvality zpracování značkování všech vět

Literatura

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

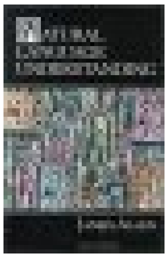

Allen, James: **Natural language understanding**, Redwood : Benjamin/Cummings Publishing, 1995, 654 s.

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

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 jazycích, 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**, . . .

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)

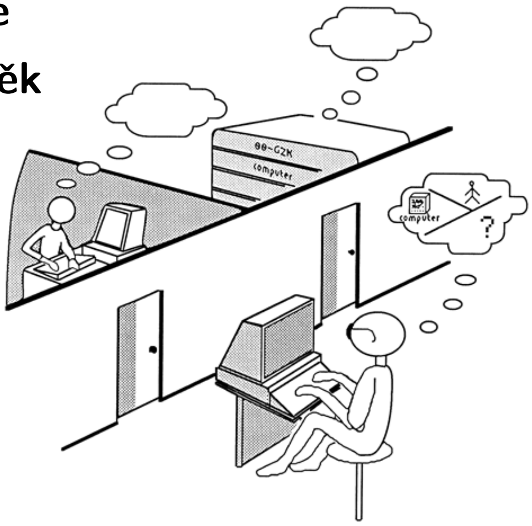

- od 1991 – **Loebnerova cena** (*Loebner Prize*) → každý rok \$4.000 za "nejlidštější" program, nabízí \$100.000 a zlatá medaile za složení celého Turingova testu

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**

IBM Watson – DeepQA

- stroj označovaný jako **Watson** – **DeepQA** vyvinutý za účelem porazit lidské šampiony ve hře **Jeopardy** (**Riskuj**)
  navazuje tím na stroj **DeepBlue**, který v roce 1997 porazil Kasparova v šachu
- po 5 letech vývoje se to Watsonovi podařilo 16.února 2011
- princip:
  - vytvoření **databáze tvrzení** z internetových dat
  - analýza částí otázky, členění otázek podle **typu**
  - vysoce **paralelní hledání** odpovědi s určením **míry jistoty**
  - vyladěný algoritmus pro **kombinaci** stovek výsledků do výsledného rozhodovacího skóre
- **nejedná se o umělou inteligenci** podle Turingova testu
- praktický význam – **inteligentní** zpracování obrovského množství textů pro **hledání odpovědi**

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:

IB030	Úvod do počítačové lingvistiky	Horák
IB047	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	Strojové učení a dobývání znalostí	Popelínský
PV173	Seminář zpracování přirozeného jazyka	Horák, Rychlý

NLPlab – 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**, **majka**, **desamb** – morfologický analyzátor, tagger
- **synt**, **set**, **zuzana** – syntaktické (a logický) analyzátory
- **GDW** (Grammar Development Workbench) – GUI pro vývoj gramatiky
- **(DEB)VisDic** – editor wordnetů
- **DEB** – platforma pro XML databáze/slovníky
- **VerbaLex** – slovník slovesných valencí
- **bonito**, **manatee**, **Word Sketches** – korpusový manažer
- **demosthenes**, **text2phone (mbrola)** – syntetizátory řeči
- **Visual Browser** – grafické znázornění (sémantických) sítí
- **X.plain** – hra na hádání slov, člověk $\times$ počítač
- korpusy, slovníky, encyklopedie, ...