

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

Úvod do počítačové lingvistiky 1/11 1 / 18
Organizace předmětu IB030

Organizace předmětu IB030

Hodnocení předmětu:

- ▶ závěrečná písemka (max 80 bodů)
 - jeden řádný a dva opravné termíny
- ▶ 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	K	45 – 100
B	73 – 79	Z	40 – 100
C	65 – 72		
D	58 – 64		
E	50 – 57		
F	0 – 49		

Základní informace

- ▶ 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 www.nltk.org
 - FreeLing nlp.lsi.upc.edu/freeling/
 - Stanford University Natural Language Software nlp.stanford.edu/software/
 - Grammatical Framework www.grammaticalframework.org
 - AIML www.aiml.foundation,
 - ChatScript github.com/ChatScript/ChatScript,
 - ParlAI github.com/facebookresearch/ParlAI
 - Pepper nlp.fi.muni.cz/projects/pepper
 - Facebook research – fastText github.com/facebookresearch/fastText
- ▶ k odevzdání je zapotřebí:
 - naprogramovaný odsouhlasený vybraný algoritmus na češtině (návrh tématu je součástí úkolu)
 - dokumentace programu s ukázkami a návodem na instalaci/spuštění na serveru aurora.fi.muni.cz a vyhodnocením úspěšnosti algoritmu na ne zcela triválních českých datech
 - vše uložit v komprimovaném archivu do odevzdávárny do **21. května 2019**
- ▶ hodnocení bude od 0 do 20 bodů podle:
 - složitosti vybraného algoritmus
 - kvality zpracování algoritmu i dokumentace

Samostatný hodnocený úkol – lingvistický

- **lingvistický úkol** – tvorba **specializovaných jazykových dat** pro evaluaci automatických nástrojů

SQAD – Simple Question Answering Database:

- čeština, 300 otázek a odpovědí podle textů z Wikipedie

Jak se nazývá strom, jehož zrna jsou využívána k výrobě čokolády?

Theobroma cacao

Čokoláda se vyrábí z kvašených, pražených a mletých zrnek tropického kakaového stromu *Theobroma cacao*.

<http://cs.wikipedia.org/wiki/%C4%8Cokol%C3%A1da>

- k **odevzdání** je zapotřebí:

- oznamit včas výběr úkolu
- odeslat výsledek v obou částech dle instrukcí na webu

- **hodnocení** bude od 0 do 20 bodů podle:

- výsledků kombinovaného hodnocení navržených sad

Literatura



Jurafsky & Martin: **Speech and Language Processing**, 3rd edition, 2017. 499 s.



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



Pala, Karel: **Počítačové zpracování přirozeného jazyka**, Brno FI MU, 2000. 190 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 analýzy 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 paranoíí
- ▶ oba využívají spíš “**manipulace s řetězci**” než analýzu
- ▶ praktický význam – tzv. **expertní systémy, chatboti**

Chatbot – dialogový robot

- ▶ mnoho proprietárních řešení pro návrh dialogových robotů
- ▶ praktické dialogy i pouze udržení zájmu
- ▶ přístupy:
 - pravidla založená na vzorech
 - Artificial Intelligence Markup Language, AIML
 - robot ALICE, Mitsuku – vítězí v Loebnerově ceně
 - praktičtější použití, hodně závisí na podkladových pravidlech
 - učení z předchozích dialogů
 - potřebuje velké množství dialogů na učení
 - lépe se přizpůsobí novým tématům (což je plus i minus, viz Microsoft Tay)
 - robot Cleverbot, Xiaoice

Turingův test – jiné varianty

Winograd Schema Challenge:

- ▶ vyhlášený organizacemi Commonsense Reasoning a Nuance od 2015
- ▶ “strukturovanější” test – založený na rozpoznávání anafor
- ▶ podrobněji v přednášce o sémantice

Turing tests in Creative Arts:

- ▶ DigiLit, DigiKidLit – generování povídek
- ▶ PoetiX, LimeriX, LyriX – generování sonetů, limeriků nebo básní
- ▶ Human-Computer Music Interaction – AccompaniX, AlgoRhythm – generování doprovodné hudby pro duet s člověkem

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**
 - vysoko **paralelní hledání** odpovědi s určením **míry jistoty**
 - vyladěný algoritmus pro **kombinaci** stovek výsledků do výsledného rozhodovacího skóre
 - viz Jak a proč Watson vyhrál Jeopardy!
- ▶ 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, Text Mining*)
- ▶ výtah z textu (*Text summarization*)
- ▶ určení typu dokumentu (*Text Classification/Clustering*)
- ▶ určení stylu dokumentu/autora (*Stylometry, Authorship Attribution*)

Přednášky se vztahem k NLP na FI MU

- ▶ obor **Umělá inteligence a zpracování přirozeného jazyka**
- ▶ vybrané Bc přednášky:

IB030	Úvod do počítačové lingvistiky	Horák
IB047	Úvod do korpusové lingvistiky a počítačové lexikografie	Rychlý, Pala
IV029	Logická analýza přirozeného jazyka	Materna, Duží
PB016	Úvod do umělé inteligence	Horák
PB095	Úvod do počítačového zpracování řeči	Bártek
PV056	Strojové učení a dobývání znalostí	Popelínský
PV173	Seminář zpracování přirozeného jazyka	Horák, Rychlý

NLP Centre – Centrum 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, místnosti **laboratoře zpracování přirozeného jazyka**
- ▶ 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 zaměstnanec 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) analyzátor
- ▶ **X/plain** – hra na hádání slov, člověk × počítač
- ▶ **Watsonson** – hra na hledání parafrází
- ▶ **DEB** – platforma pro XML databáze/slovníky
- ▶ **(DEB)VisDic** – editor wordnetů
- ▶ **VerbaLex** – slovník slovesných valencí
- ▶ **bonito**, **manatee**, **Word Sketches** – korpusový manažer
- ▶ **Visual Browser** – grafické znázornění (sémantických) sítí
- ▶ **GDW** (Grammar Development Workbench) – GUI pro vývoj gramatiky
- ▶ **demosthenes**, **text2phone** (**mbrola**) – syntetizátory řeči
- ▶ korpusy, slovníky, encyklopedie, . . .