Natural Language Toolkit

NLTK

Stručná charakteristika

- NLTK je sada knihoven pro Python a programů pro symbolické a statistické zpracování přirozeného jazyka
- k dispozici jsou
  - zdrojové kódy
  - dokumentace
  - tutoriály
  - data (korpusy, seznamy slov, ...)

NLTK je určeno

- pro studenty zpracování přirozeného jazyka
- pro podporu výzkumu souvisejících oblastí, například:
  - empirická ligvistika (korpusy)
  - kongitivní vědy
  - umělá inteligence, strojové učení
  - vyhledávání znalostí

Motivační příklad 1
nltk.app.rdparser_app

- Ukázka rekurzivní sestupné analýzy shora dolů

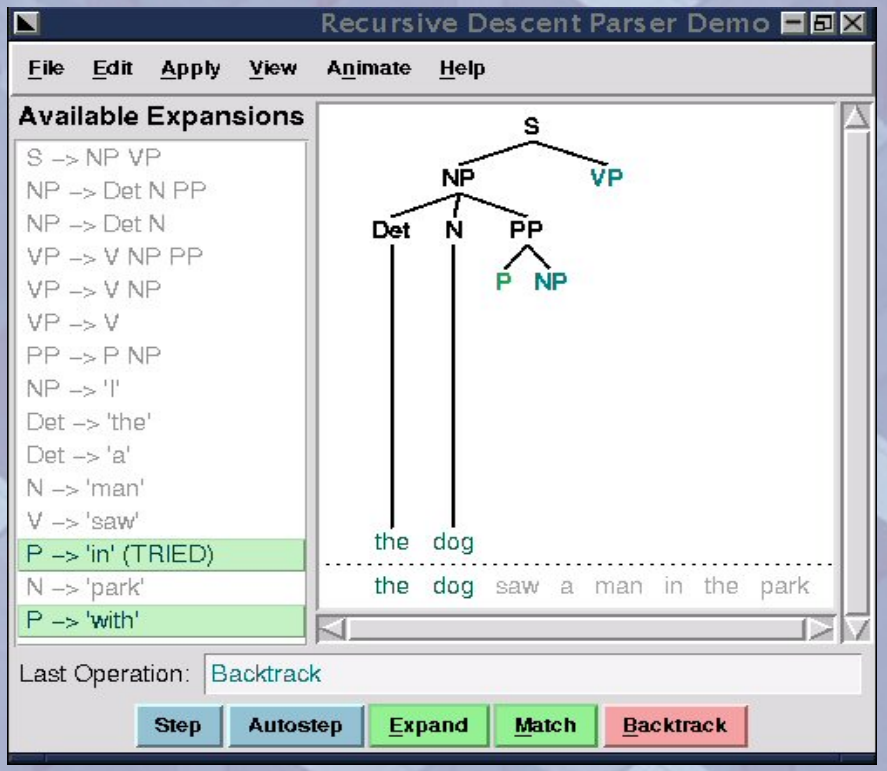

Motivační příklad 2 nltk.app.srparser_app

- Ukázka posuvně-redukční analýzy zdola nahoru

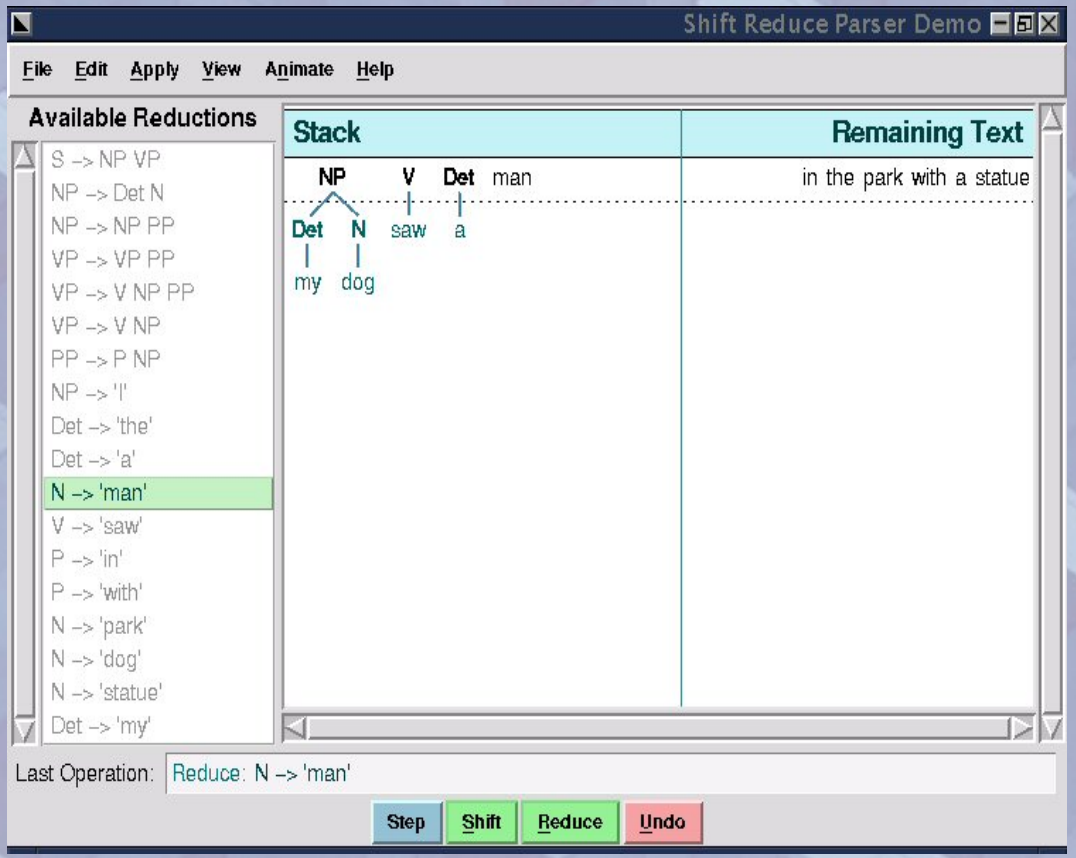

Motivační příklad 3
nltk.app.chartparser_app

- Analýza zdola nahoru může najít jen jedno vyhodnocení, někdy nenalezne existující řešení
- Analýza shora dolů může být značně neefektivní (pro LR gramatiky může cyklit)
- Řešíme znovuužitím výpočtů (dynamické programování) -> chart parsing

Motivační příklad 3
nltk.app.chartparser_app

- Ukázka

  tabulková analýza

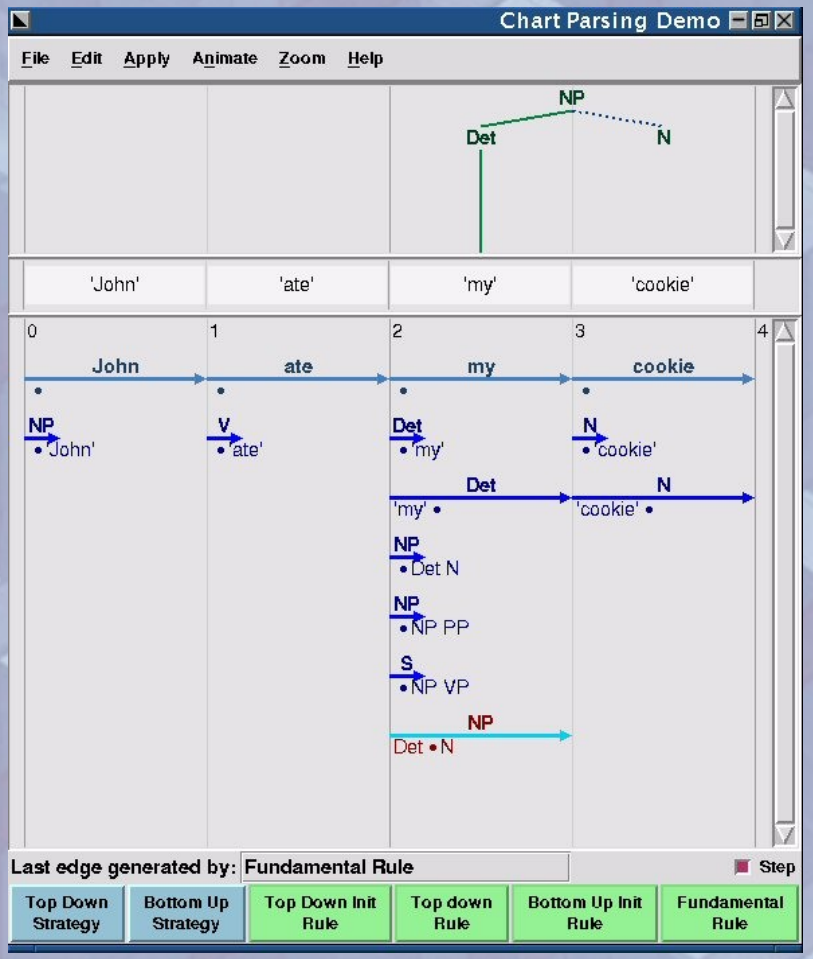

Motivační příklad 3
nltk.app.chartparser_app

- Můžeme uložit jakoukoli hypotézu kompatibilní s gramatikou (ale nemusíme ji potom využít)
- Každá hypotéza reprezentována hranou

NLTK

- vývoj: 2005 jako NLTK -Lite
- od prosince 2005 je to jediná podporovaná verze
- stejná funkčnost jako starší NLTK, avšak s nižšími nároky na programátora (používá standardní objekty Pythonu, atd.)
- nyní ve verzi 2

Autoři a licence

- autoři: Steven Bird, Edward Loper
- mnoho přispěvatelů
- licence:
  - projekt je open source bez záruky
    - GNU General Public License
  - dokumentace
    - Creative Commons Attribution-ShareAlike 2.5 License

NLTK - zdroje

- http://nltk.org/
- kniha *Natural Language Processing with Python* (http://nltk.org/book)

Instalace (1)

- Instalace vyžaduje Python 2.6 a vyšší
- Platformy
  - Linux
  - Mac
  - Windows

Instalace (2)

1) Python

http://www.python.org/download/

2) Numerical Python (Numarray)

http://sourceforge.net/project/showfiles.php?group_id=1369&package_id=32367

3) NLTK

https://pypi.python.org/pypi/nltk

Linux: packages:

sudo apt-get install python-nltk

Data:

```
>>> import nltk
>>> nltk.download()
```

Python a NLP

- Python je vhodný nástroj pro NLP
  - jednoduchý
  - snadno “debugovatelný”
    - výjimky
    - interpretovaný jazyk
  - strukturovatelný
    - moduly, OOP
  - výkonná práce nad (znakovými) řetězci

Moduly a balíky

- moduly *modules* umožňují znovu použít kód
- balíky *packages jsou hierarchické moduly*
- *příkazy pro práci*
  - *import*
  - *from ... import*
  - *reload*

Moduly a balíky import

- Příkaz *import načítá modul:*

```
# Load the regular expression module
>>> import re
```

- *Použití přístupu k metodám (pomocí tečkové notace)*

```
# Use the search method from the re module
>>> re.search('\w+', str)
```

- *Zobrazení obsahu modulu pomocí dir:*

```
>>> dir(re)
['DOTALL', 'I', 'IGNORECASE', ...]
```

Moduly a balíky
from .. import

- Příkaz `from...import` *načítá jednotlivé funkce:*

```
# Load the search function from the re module
>>> from re import search
>>> nltk.app.rdparser_app import *
```

- *Poté již může být příkaz použit přímo:*

```
# Use the search method from the re module
>>> search('\w+', str)
>>> demo()
```

Moduly NLTK

- nltk
- nltk.chat
- nltk.contrib
- nltk.corpus
- nltk.draw
- nltk.misc
- nltk.model
- nltk.parse
- nltk.tag
- nltk.tokenize

Tokenizace
úvod

- Co je slovo?
  - Shluk znaků oddělený mezerou? NE
    - Konce řádků
    - Interpunkce
    - …
- Rozdíl *Type* vs. *Token*
  - Type – to co je mnoha tokenům společné
  - Token - konkrétní realizace znaku

"slovo" se vyskytuje dvakrát (dva tokeny),
ale jde jen o jedno slovo (jeden type)

Tokenizace
text = sekvence tokenů

```
>>> from nltk_lite import tokenize
>>> text = 'Hello world.  This is a test string.'
>>> list(tokenize.whitespace(text))
['Hello', 'world.', 'This', 'is', 'a', 'test', 'string.']
```

```
>>> text = 'That poster costs $22.40.'
>>> pattern = r'\w+|\$\d+\.\d+|[^\w\s]+'
>>> list(tokenize.regexp(text, pattern))
['That', 'poster', 'costs', '$22.40', '.']
>>> list(tokenize.regexp(text, pattern=r'\s+', gaps=True))
['That', 'poster', 'costs', '$22.40.']
```

```
>>> from nltk_lite.corpora import brown, extract
>>> print extract(0, brown.raw('a'))
['The', 'Fulton', 'County', 'Grand', 'Jury', 'said', 'Friday', 'an', 'investigation', '
of', "Atlanta's", 'recent', 'primary', 'election', 'produced', '``', 'no', 'evidence',
"''", 'that', 'any', 'irregularities', 'took', 'place', '.']
```

Tokenizace
stemming (hledání kořene)

```
>>> porter = tokenize.PorterStemmer()
>>> tokens = extract(0, brown.raw('a'))
>>> for token in tokens:
        print porter.stem(token)
```

```
The Fulton Counti Grand Juri said Friday an investig of
Atlanta' recent primari elect produc `` no evid '' that
ani irregular took place .
```

Tokenizace statistiky

Počet slov

```
>>> from nltk_lite.corpora import genesis
```

```
>>> len(list(genesis.raw('english-kjv')))
38240
>>> len(list(genesis.raw('finnish')))
26597
>>>
```

Frekvenční distribuce

```
>>> from nltk_lite.probability import FreqDist
>>> fd = FreqDist()
>>> for token in genesis.raw():
        fd.inc(token)


>>> fd.max()
'the'
```

Tokenizace statistiky

nltk_lite.probability.FreqDist

Jméno	Příklad	Popis
Count	`fd.count('the')`	Kolikrát se daný vzorek vyskytl
Frequency	`fd.freq('the')`	Frekvence daného vzorku
N	`fd.N()`	Počet vzorků
Samples	`fd.samples()`	Seznam různých zaznamenaných vzorků
Max	`fd.max()`	Vzorek s nejvyšším počtem výskytů

Tokenizace
statistika pomocí tokenů

```
>>> def length_dist(text):
        fd = FreqDist()
        for token in genesis.raw(text):
                fd.inc(len(token))
        for i in range(15):
                print "%2d" % int(100*fd.freq(i)),
        print

>>> length_dist('english-kjv')
 0  2 14 28 21 13  7  5  2  2  0  0  0  0  0
>>> length_dist('finnish')
 0  0  9  6 10 16 16 12  9  6  3  2  2  1  0
```

Tokenizace
podmíněná pravděpodobnost

```
>>> from nltk_lite.probability import ConditionalFreqDist
>>> cfdist = ConditionalFreqDist()
>>> for text in genesis.items:
        for word in genesis.raw(text):
                cfdist[text].inc(len(word))
>>> for cond in cfdist.conditions():
        wordlens = cfdist[cond].samples()
        wordlens.sort()
        points = [(i, cfdist[cond].freq(i)) for i in wordlens]
```

```
>>> from nltk_lite.draw.plot import Plot
>>> Plot(points).mainloop()
```

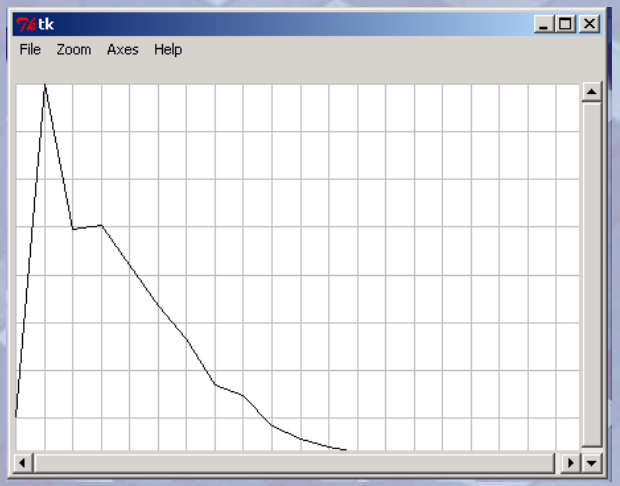

Tokenizace
předpovídání slov (kolokace)

- Trénovací korpus
- `ConditionalFreqDist` a `max()`

```
>>> from nltk_lite.probability import ConditionalFreqDist
>>> cfdist = ConditionalFreqDist()
>>> prev = None
>>> for word in genesis.raw():
        cfdist[prev].inc(word)
        prev = word

>>> word = 'living'
>>> cfdist['living'].samples()
['creature,', 'substance', 'soul.', 'thing', 'thing,', 'creature']
```

- Generování

```
>>> word = 'better'
>>> for i in range(20):
        print word,
        word = cfdist[word].max()

better that he said, I will not be a wife of the land of the land
```

Tagování nástroje NLTK tag

```
>>> sent = """
John/nn saw/vb the/at book/nn on/in the/at table/nn ./end  He/nn s
ighed/vb ./end
"""
>>> from nltk_lite.tag import tag2tuple
>>> for t in tokenize.whitespace(sent):
        print tag2tuple(t),

('John', 'nn') ('saw', 'vb') ('the', 'at') ('book', 'nn') ('on', '
in') ('the', 'at') ('table', 'nn') ('.', 'end') ('He', 'nn') ('sig
hed', 'vb') ('.', 'end')
```

Word Class Label	Brown Tag	Word Class
Det	at	Article
N	nn	Noun
V	vb	Verb
Adj	jj	Adjective
P	in	Preposition
Card	cd	Number
	end	Sentence-ending punctuation

Tagování nástroje NLTK tag

- Jednoduchý tagger

```
>>> text = "John saw 3 polar bears ."
>>> tokens = list(tokenize.whitespace(text))
>>> ['John', 'saw', '3', 'polar', 'bears', '.']
['John', 'saw', '3', 'polar', 'bears', '.']
>>> my_tagger = tag.Default('nn')
```

```
>>> from nltk_lite import tag
>>> my_tagger = tag.Default('nn')
>>> list(my_tagger.tag(tokens))
[('John', 'nn'), ('saw', 'nn'), ('3', 'nn'), ('polar', 'nn'), ('b
ars', 'nn'), ('.', 'nn')]
```

  - Přesnost cca. *20-30%*
  - Používá se jako *fallback solution*

Tagování nástroje NLTK tag

- Tagger s regulárními výrazy

```
>>> text = "John saw 3 polar bears ."
>>> tokens = list(tokenize.whitespace(text))
>>> ['John', 'saw', '3', 'polar', 'bears', '.']
['John', 'saw', '3', 'polar', 'bears', '.']
>>> patterns = [(r'^-?[0-9]+(.[0-9]+)?$', 'cd'), (r'.*', 'nn')]
>>> nn_cd_tagger = tag.Regexp(patterns)
>>> list(nn_cd_tagger.tag(tokens))
[('John', 'nn'), ('saw', 'nn'), ('3', 'cd'), ('polar', 'nn'), ('be
ars', 'nn'), ('.', 'nn')]
```

  - Vhodný pro slovní tvary s charakteristickou příponou/předponou
  - Vhodný pro čísla, mailové adresy, www stránky apod.
  - Používá se jako *fallback solution*

Tagování
nástroje NLTK tokenize

- Unigramový tagger
  - Trénování:

```
>>> from nltk_lite.corpora import brown
>>> from itertools import islice
>>> train_sents = list(islice(brown.tagged(), 500))
>>> unigram_tagger = tag.Unigram()
>>> unigram_tagger.train(train_sents)
```

  - Použití:

```
>>> text = "John saw the book on the table"
>>> tokens = list(tokenize.whitespace(text))
>>> list(unigram_tagger.tag(tokens))
[('John', 'np'), ('saw', 'vbd'), ('the', 'at'), ('book', None), ('
on', 'in'), ('the', 'at'), ('table', None)]
```

```
>>> unigram_tagger = tag.Unigram(backoff=nn_cd_tagger)
>>> unigram_tagger.train(train_sents)
>>> list(unigram_tagger.tag(tokens))
[('John', 'np'), ('saw', 'vbd'), ('the', 'at'), ('book', 'nn'), ('
on', 'in'), ('the', 'at'), ('table', 'nn')]
```

Tagování nástroje NLTK tag

- Kombinace

```
>>> t0 = tag.Default('nn')
>>> t1 = tag.Unigram(backoff=t0)
>>> t2 = tag.Bigram(backoff=t1)
>>> t0 = tag.Default('nn')
>>> t1 = tag.Unigram(backoff=t0)
>>> t2 = tag.Bigram(cutoff=2, backoff=t1)
>>> t1.train(brown.tagged('a'))
>>> t2.train(brown.tagged('a'))
>>> accuracy2 = tag.accuracy(t2, brown.tagged('b'))
```

```
>>> print 'Bigram Accuracy = %4.1f%%' % (100 * accuracy2
Bigram Accuracy = 79.3%
```

- Brillův tagger

```
>>> from nltk_lite.tag import brill
>>> brill.demo()
```

Chunk parsing nástroje NLTK parse

- Příklad

```
>>> from nltk_lite.parse import tree
>>> tree.chunk("[ the/DT little/JJ cat/NN ] sat/VBD on/IN [ the/DT mat/NN ]")
(S: (NP: ('the', 'DT') ('little', 'JJ') ('cat', 'NN')) ('sat', 'VBD') ('on',
'IN') (NP: ('the', 'DT') ('mat', 'NN')))
```

  - Shlukování tokenů do *chunks*
    - Tvořeny vedoucím slovem (např. podst. jm) a souvisejícími slovy (např. příd. jm.)
  - *Chunks* a uplynulé tokeny vytváří tzv. *chunk structure*
    - Dvojúrovňový strom obsahující celý text a obsahující jak *chunks* tak neparsované tokeny

Chunk parsing nástroje NLTK parse

- Chunk tree

```
>>> from nltk_lite.corpora import treebank, extract
>>> chunk_tree = extract(603, treebank.chunked())
>>> print chunk_tree
(S:
  ('In', 'IN')
  (NP: ('happier', 'JJR') ('news', 'NN'))
  (',', ',')
  (NP: ('South', 'NNP') ('Korea', 'NNP'))
  (',', ',')
  ('in', 'IN')
  ('establishing', 'VBG')
  (NP: ('diplomatic', 'JJ') ('ties', 'NNS'))
  ('with', 'IN')
  (NP: ('Poland', 'NNP') ('yesterday', 'NN'))
  (',', ',')
  ('announced', 'VBD')
  (NP: ('$', '$') ('450', 'CD') ('million', 'CD'))
  ('in', 'IN')
  (NP: ('loans', 'NNS'))
  ('to', 'TO')
  (NP: ('the', 'DT'))
  ('financially', 'RB')
  ('strapped', 'VBN')
  (NP: ('Warsaw', 'NNP') ('government', 'NN'))
  ('.', '.'))
```

Shrnutí

- NLTK je vhodný nástroj pro NLP:
  - Umožňuje rychlou a pohodlnou práci s textem
  - Mnoho obsažených výrazů

Literatura

- NLTK Book
  Steven Bird, Ewan Klein, Edward Loper, 2001-2009
  - http://nltk.org/book
- NLTK Guides

http://nltk.googlecode.com/svn/trunk/doc/howto/index.html

- nltk modules

http://nltk.org/py-modindex.html