PLIN015 Proseminář z počítačové lingvistiky II

Miloš Jakubíček

Centrum zpracování přirozeného jazyka
Fakulty informatiky, Masarykova univerzita
xjakub@fi.muni.cz

3. června 2013

Obsah

Cíl kursu

- navázat na PLIN013, obdobná skladba a cíle

Požadavky k zápočtu

- přiměřená účast (max. 3 neomluvené absence)
- vyhotovení 3 průběžných úkolů a složení závěrečného testu
- tentokrát zkusíme celkem 60 bodů ;)

Osnova

- ne nutně pevná, máte-li náměty, ozvěte se
- algoritmická složitost a její vazba na korpusové databáze pro ZPJ
- vyhledávání v korpusech, jazyk CQL
- syntaktická analýza, elementární algoritmy, ukázka gramatik

- cíl: změřit „výkon“, příp. „náročnost“ programu/algoritmu
- výsledky by měly být reprezentativní, odrážet skutečné vlastnosti algoritmu, ne jeho konkrétní chování na určitém typu HW
- klíčové otázky: **Co** měřit? **Jak** měřit?

Co měřit?

- čas – časová složitost: kolik času potřebuje program na své vykonání?
- paměť – prostorová/paměťová složitost: kolik paměti (úložného prostoru) program ke svému běhu potřebuje?
- obě vlastnosti jsou do určité míry komplementární – proč?
- budeme se zabývat především časovou složitostí

Jak měřit?

- Uvažujme následující posloupnosti, ve kterých chceme vyhledat zadaný prvek, např. 3
- 3 18 1
- 1 18 3
- 1 18 2 5 3
- 1 18 2 5 27 11 3
- 1 18 1 3 1 1
- 1 18 2 5 87 12 2 32 45 12 1 3
- Kdy nám to potrvá nejdéle? Na čem to závisí?

Asymptotická složitost

- cíl: vyjádřit složitost jako funkci vstupu (resp. jeho velikosti, délky), tedy říct, jak roste složitost algoritmu vzhledem k rostoucímu vstupu
- Můžeme uvažovat složitost v *nejlepším* případě, *průměrném* případě, *nejhorším* případě nebo *amortizovanou* složitost.
- 3 18 2 5 1
- 1 18 3 5 1
- 1 18 2 5 3
- V mnoha případech (ale ne vždy!) nás zajímá hlavně složitost v nejhorším případě.

Základní složitosti

seřazené od „nejmenší“, s užitím tzv. O-notace

název	**složitost**	$n = 10^2, c = 10$	$n = 10^6, c = 10$
konstantní	$O(1) = c$	10	10
logaritmická	$O(\log n)$	6,64	19,9
lineární	$O(n)$	100	1 000 000
lineárnělogaritmická	$O(n \cdot \log n)$	664	19 900 000
kvadratická	$O(n^2)$	10 000	10^{12}
kubická	$O(n^3)$	1 000 000	10^{18}
obecná polynomiální	$O(n^c)$	10^{20}	10^{600}
exponenciální	$O(c^n)$	10^{100}	$10^{1000000}$
faktoriálová	$O(n!)$	moc	strašně moc:)

Složitost problému vs. složitost algoritmu

Složitost algoritmu

Složitostí algoritmu rozumíme složitost konkrétní instance zadaného algoritmu (implementovatelného v nějakém programovacím jazyce). Algoritmy pracující s lepší než exponenciální/faktoriálovou složitostí označujeme jako *efektivní*.

Složitost problému

Složitostí problému rozumíme složitost *optimálního* algoritmu korektně řešícího zadaný problém.

Vyhledávání v neseřazené posloupnosti

- jaká je složitost demonstrovaného algoritmu? $O(n)$.
- jaká je složitost problému (tj. jde to lépe) a proč?

Vyhledávání v seřazené posloupnosti

- tzv. binárním vyhledáváním nebo-li půlením intervalů
- jaká je složitost demonstrovaného algoritmu? $O(\log_2 n)$.
- jaká je složitost problému (tj. jde to lépe) a proč?

Vztah asymptotické složitosti a výkonu HW

- uvažujme jeden krok výpočtu jako 1 s, 10 min odpovídá 600 krokům
- lineární algoritmus složitosti $3 \cdot n$: 10 min stačí na vykonání pro vstup velikosti 200
- exponenciální algoritmus 2^n: 10 min stačí na vykonání pro vstup velikosti 9 ($2^9 = 512, 2^{10} = 1024$)
- uvažujme dvakrát vykonnější HW: jeden krok výpočtu = 0,5 s, 10 min odpovídá 1 200 krokům
- lineární algoritmus složitosti $3 \cdot n$: 10 min stačí na vykonání pro vstup velikosti 400
- exponenciální algoritmus 2^n: 10 min stačí na vykonání pro vstup velikosti 10 ($2^{11} = 2048$)

Indexování

- klíč – jednoznačný identifikátor záznamu (např. v relační databázi – „tabulce“)
- index – seřazená posloupnost hodnot pro jeden klíč, s ukazateli na záznam
- vybudování indexu $\Rightarrow$ rychlé vyhledávání

Datové struktury

- zajímá nás způsob uložení dat
- pole, lineární spojový seznam
- operace: přístup k *n*-tému prvku, vložení prvku, odstranění *n*-tého prvku

Pole (array)

- uložení n hodnot v souvislé paměťové oblasti
- indexování číslem ($\rightarrow$ adresou v paměti)
- prostorová složitost: $O(c \cdot n)$, kde n je počet záznamů, c velikost jednoho záznamu (konstanta)
- přístup k n-tému prvku: $O(1)$ (adresování v paměti)
- vložení prvku: $O(n)$ (realokace)
- odstranění prvku: $O(n)$ (realokace)

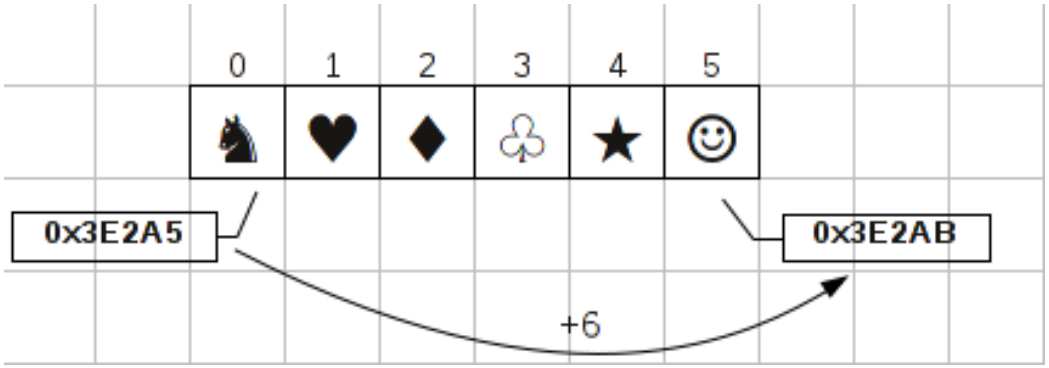

Seznam (list) I

- uložení n hodnot v nesouvislé paměťové oblasti
- s každou hodnotou je asociovaný ukazatel na následníka
- prostorová složitost: $O(c \cdot n)$, kde n je počet záznamů, c velikost jednoho záznamu (konstanta) – ale: záznam zde musí obsahovat i ukazatel na následníka $\Rightarrow$ vyšší paměťové nároky než pole
- přístup k n-tému prvku: $O(n)$ (lineární průchod seznamem)
- vložení prvku: $O(1)$ (přepojení ukazatelů)
- odstranění prvku: $O(1)$ (přepojení ukazatelů)

Seznam (list) II

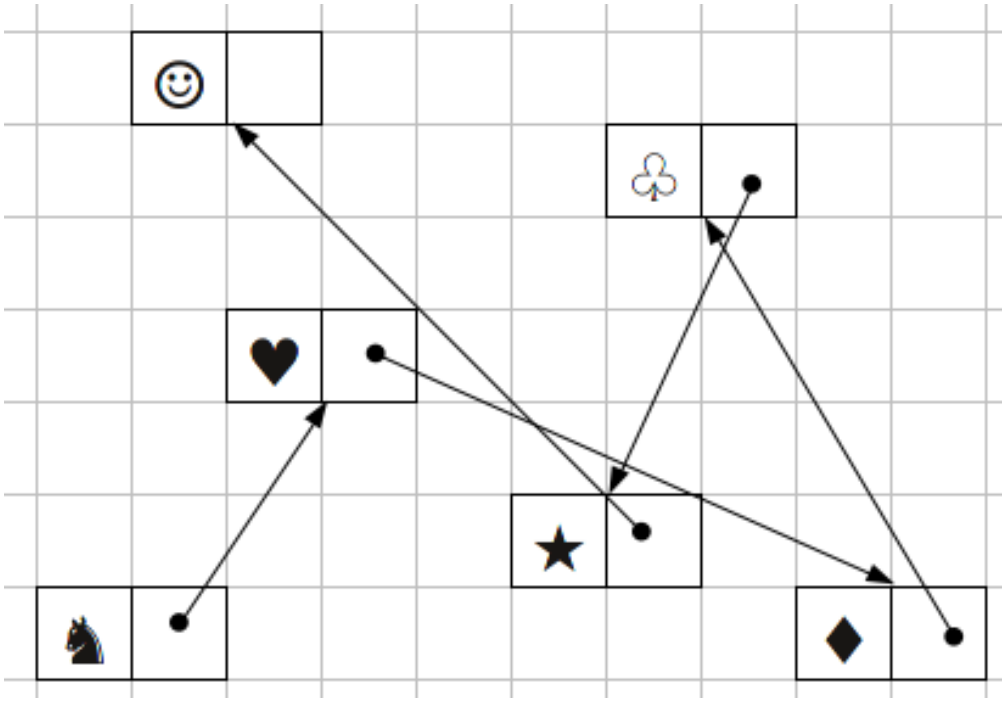

Shrnutí: pole vs. seznam

- pole: rychlejší přístup, pomalejší modifikace
- seznam: pomalejší přístup, rychlejší modifikace
- $\Rightarrow$ vhodnost použití závisí na datech

Hashování

- v předchozích příklade bylo indexem vždy číslo
- můžeme ovšem chtít indexovat např. řetězcem („ke každému slovu přiřaď četnost“)
- nutná transformace nečíselné hodnoty na číslo – vytvoření tzv. *hashe* pomocí *hashovací funkce*

Hashovací funkce I

$h : D \to \mathcal{N}$, kde D je doména dat; požadavky:

- rychlá
- deterministická (pro stejná data vždy stejný výsledek)
- uniformní (výstupní hodnoty mají přibližně stejnou pravděpodobnost, všechny mají stejnou velikost)
- výstup volitelné délky
- obtížná reverzibilita (použití: hesla)
- minimální změna vstupu vyvolá velkou změnu výstupu

Hashovací funkci nazýváme perfektní, je-li její zúžení na konkrétních vstupních datech injektivní.

Hashovací funkce II

- obecně je hashovací funkce vždy neinjektivní a vznikají kolize
- důležitý požadavek: neměnnost vstupních dat po vytvoření hashe (*immutability*)
- Python: list = [], dict = {}

Fronta

- = datová struktura typu FIFO (First In First Out)
- implementace pomocí pole nebo spojového seznamu
- Python: list.append(), list.pop(0), ale pomalé (collections.deque)!
- př. použití: prohledávání stromu do šířky

Zásobník

- = datová struktura typu LIFO (Last In First Out)
- implementace pomocí pole nebo spojového seznamu
- Python: list.append(), list.pop()
- př. použití: prohledávání stromu do hloubky

Vyhledávání v korpusech – CQL

Korpus:

- poziční atributy – slovo, lemma, značka, . . .
- struktury a strukturní atributy – dokument (autor, id, rok, . . .), odstavec, věta
- vyhledávání: Manatee/Bonito/Sketch Engine
- http://corpora.fi.muni.cz
- http://the.sketchengine.co.uk

Today's Corpora in SkE

- **LARGE** (= billions of tokens, and it's going to be worse)
- complex multi-level multi-value annotation
- wide range of languages
- growing demand on complex searching – moving from morphology to syntax and semantics
- search API for automatic information retrieval and post-processing in particular applications needed

CQL

- = Corpus Query Language (Christ and Schulze, 1994)
- positions and positional attributes: `[attr="value"]`
- structures and structural attributes: `<str attr="value»`
- example:

```
[word=".*ing"& tag="V.*"]
   <doc id="20[5-9].*"
```

- established a `within <str/>` query:

```
[tag="N.*"]+ within <s/>
```

  and alternative `meet/union` query:

```
(meet [lemma="take"] [tag="N.*"] -5 +5)
    (union (meet ...) (meet ...))
```

CQL in Manatee/Bonito

- ehnancements and differences to the original CQL syntax
- `within <query>` and `containing <query>`
- `meet/union` (sub)query
- inequality comparisons
- frequency function

within/containing queries

- searching for particles:

```
[tag="PR.*"] within [tag="V.*"] [tag="AT0"]?
[tag="AJ0"]* [tag="(PR.?|N.*)"] [tag="PR.*"]
within <s/>
```

- searching for a Czech idiom “hnout někomu žlučí” (“to get somebody’s goat”):
  word-by-word translated as:
  hnout “move” [V, infinitive]
  někomu “somebody” [N, dative]
  žlučí “bile” [N, instrumental].

```
<s/> containing [lemma="hnout"] containing
[tag=".*c3.*"] containing [word="žlučí"]
```

within/containing queries

- structure boundaries: begin: `<str>`, whole structure: `<str/>`, end: `</str>`
- changes: `within <str>` not allowed anymore, use `within <str/>`

meet/union queries

- combined with regular query: <s/>

```
containing (meet [lemma="have"] [tag="P.*"] -5 5)
containing (meet [tag="N.*"] [lemma="blue"])
```

- changes: meet/union queries can be used on any position, they can contain labels and no MU keyword is required (and deprecated):
  `(meet 1:[] 2:[]) & 1.tag = 2.tag`

Inequality comparisons

- former comparisons allowed only equality and its negation: `[attr="value"] [attr!="value"]`
- inequality comparisons implemented: `[attr<="value"] [attr>="value"] [attr!<="value"] [attr!>="value"]`
- intended usage:

`[tag="AJ.*"] [tag="NN.*"] within <doc year>="2009»`

- sophisticated comparison performed on the attribute value: `<doc id<="CC20101031B»` matches e.g. `BB20101031B`, `CC20091031B`, `CC20101030B` `CC20101031A`.

Fixed string comparisons

- normally the CQL values are regular expressions
- sometimes this is not desirable (batch processing needs escaping of metacharacters)
- new == and !== operator introduced for fixed strings comparison
- no escaping needed except for '“ and '\'
- examples: ".", "$", " "matches a single dot, dollar sign and tilda, respectively, "\n"matches a backslash followed by the character n,

Frequency function

- a frequency constraint allowed in the global conditions part of CQL:

```
1:[tag="PP.*"] 2:[tag="NN.*"] & f(1.word) > 10
```

Performance evaluation

Tabulka : Query performance evaluation – corpora legend: ∘ BNC (110M tokens), • BiWeC (version with 9.5G tokens), ∗ Czes (1.2G tokens)

query	# of results	time (m:s)
∘ `[lemma="time"]`	179,321	0.07
∘ `[lemma="t.*"]`	14,660,881	3.12
∘ Ex: particles	1,219,973	33.36
• Ex: particles	97,671,485	32:26.48
∗ Ex: idioms	66	1:6.86
∘ Ex: meet/union	3	8.47
• Ex: meet/union	1457	7:13.12

Rozhraní systému Manatee

- podrobnější dokumentace k CQL: http://trac.sketchengine.co.uk/wiki/SkE/CorpusQuerying
- `corpquery CORPUSNAME QUERY`
- `lsclex CORPUS ATTR`
- `lsslex CORPUS STRUCT ATTR`

Zkuste si

Na korpusu DESAM a czes vyzkoušejte:

- hledat výskyty přechodníků (přítomných i minulých)
- hledat jmenné fráze s genitivní vazbou
- hledat věty obsahující reflexivní slovesa
- hledat výskyty svého oblíbeného idiomu
- hledat shodné jmenné fráze do délky 4

Termín: do 24. 5. 2013, do odevzdávárny vložte textový soubor s příslušnými dotazy v CQL

sed, diff, comm

- `sed` – zkratka z „stream editor“
- `sed 's/REGEX/NAHRADA/'` – provede náhradu regulárního výrazu REGEX za řetězec NAHRADA
- `diff` – zkratka z „difference“
- `diff SOUBOR1 SOUBOR2` – porovná soubory a vypíše nalezené rozdíly
- `comm` – zkratka z „compare“
- `comm -1 -2 -3 SOUBOR1 SOUBOR2` – vynechá řádky vyskytující se pouze v souboru 1 / 2 / obou (soubory musí být seřazené).
- `ajka, majka, desamb`

Gramatika

- $\rightarrow$ PLIN004: $G = (\Sigma, N, P, S)$
- Chomského hierarchie, podle omezení na podobu pravidel ($A, B \in N, a \in \Sigma, \alpha, \beta \in (N \cup \Sigma)^*$):
  - typ 3: regulární gramatika: $A \rightarrow a, A \rightarrow aB$,
  - typ 2: bezkontextová gramatika: $A \rightarrow \beta$,
  - typ 1: kontextová gramatika: $\alpha \rightarrow \beta, |\alpha| \leq |\beta|$,
  - typ 0: frázová gramatika: $\alpha \rightarrow \beta$.
- pojetí gramatiky coby **generátoru** – regulární gramatika generuje regulární jazyk (a obdobně pro ostatní typy)
- potřeba „protikusu“ ke generátoru (syntetizátoru) – analyzátor
- $\rightarrow$ GRAMATIKA – JAZYK – ANALYZÁTOR
- z PLIN004 již znáte: regulární gramatika – regulární jazyk (popsatelný regulárním výrazem) – konečný automat

Gramatika a analyzátor

- s postupnou relaxací omezení na tvar pravidel roste **vyjadřovací síla** gramatiky („složitost“ generovatelného jazyka)
- pochopitelně s tím rostou i nároky na analyzátor, zejména časová složitost analýzy (n značí délku vstupního řetězce):
  - regulární gramatika: $O(n)$ – proč?
  - bezkontextová gramatika: $O(n^3)$
  - kontextová gramatika: $O(n^6)$
- komplexní gramatické formalismy, některé zahrnující i sémantiku (LFG, HPSG, TAG, CCG, . . .) – viz IB030

Přirozené jazyky a gramatiky

- Jak složité jsou přirozené jazyky?
- Lze přímočaře uplatnit Chomského hierarchii?
- Co je úkolem syntaktického analyzátoru přirozeného jazyka?
- Jaké jsou důsledky teorie formálních jazyků pro syntaktickou analýzu přirozeného jazyka?

Bezkontextová gramatika, zásobníkový automat

- bezkontextová gramatika = context-free grammar = CFG
- konečný automat = finite-state automaton = FSA
- zásobníkový automat = pushdown automaton = PDA
- podobně jako jazyk generovaný reg. gramatikou lze analyzovat FSA, můžeme jazyk generovaný CFG analyzovat pomocí PDA
- PDA: analýza shora dolů a zdola nahoru

ZPJ a teorie formálních jazyků

- skripta a slidy (s poděkováním) Shuly Wintner, University of Haifa: http://cs.haifa.ac.il/~shuly/teaching/09/nlp/complexity-handout.pdf a ve studijních materiálech
- skripta Černá-Kučera-Křetínský – FI:IB005 Formální jazyky a automaty: http://is.muni.cz/elportal/estud/fi/js06/ib005/Formalni_jazyky_a_automaty_I.pdf

Nedeterministická bezkontextová analýza

- shora dolů (Lookup-Rewrite)
  - na začátku analýzy obsahuje zásobník počáteční neterminál
  - operace: Lookup (najdi shodný prefix zásobníku a vstupu; odmaž – „přečti“), Rewrite (přepiš vrchol zásobníku podle pravidla gramatiky – nahraď pravou stranou)
  - nedeterminismus: vhodná volba pořadí operací Lookup-Rewrite
  - úspěšná analýza: prázdný zásobník, vstup byl celý přečten
- zdola nahoru (Shift-Reduce)
  - na začátku analýzy je zásobník prázdný
  - operace: Shift (vlož do zásobníku další slovo ze vstupu), Reduce (přepiš vrchol zásobníku podle pravidla gramatiky – nahraď levou stranou)
  - nedeterminismus: vhodná volba pořadí operací Shift-Reduce
  - úspěšná analýza: zásobník obsahuje právě počáteční neterminál, vstup byl celý přečten

Handling ambiguity

- Backtracking – try all options sequentially (usually degrades to factorial time complexity)
- Determinism – choose one option (preferably a good one) and keep to it
- Parallelism – try all options in parallel
- Underspecification – do not specify the ambiguous phenomenon

Deterministická analýza

- CKY / CYK (zdola nahoru, vyžaduje CNF)
- Earleyho parser (shora dolů)
- GLR (Generalized Left-to-right Right-most derivation parser) (zdola nahoru)
- Chart parser (zdola nahoru / shora dolů / řízený hlavou)
- $\rightarrow$ IB030

- složková analýza (phrase structure analysis)
- závislostní analýza (dependency analysis)
- co je cílem syntaktické analýzy?
- metody vyhodnocování (LAA, Parseval)

Příprava korpusu

1. Ujasnění obsahu korpusu (K čemu má sloužit? Jak získám vhodný text?)
2. Získání dat (Crawling, ne Google; wget, links)
3. Základní anotace (dokument, odstavce, specifické atributy)
4. Tokenizace (unitok.py, don't, A4)
5. Segmentace do vět (tecky.pl, MUDr., atd.)
6. Morfologická anotace / desambiguace (ajka / majka / desamb)
7. Další specifická anotace (např. syntaktická)
8. Zakódování (Manatee / encodevert; Corpus Architect)