

Využitie Travisových čiastočných súm vo Wheelerových grafoch a nástroj Wheeler Graph Toolkit: Report za letný semester

Ondrej Škorňák

Jún 2024

1 Úvod

Tento semester som sa mal zamerať na štúdium a implementáciu metódy Travisových čiastočných súm (TPS) a jej využitie vo Wheelerových grafoch. Hlavným cieľom bolo pochopiť, ako TPS môže zlepšiť techniky kompresie dát, najmä v kontexte Burrows-Wheelerovej transformácie (BWT) a jej implementácie v blokových kompresoroch ako Bzip2. Pre tento semester sa upustilo od implementácie BWT do Bzip2 z dôvodu toho, že po finálnej konzultácii v zimnom semestri, nám prišlo zaujímavejšie skúsiť zlepšiť priamo BWT pomocou daných špeciálnych čiastočných súm.

2 Ciele projektu

Projekt mal dva hlavné ciele:

- Štúdium BWT a jeho využitie v kompresii dát.
- Implementácia tunelovacích metód v Bzip2 s cieľom vytvoriť plne funkčný kompresný algoritmus.

Počas letného semestra sa sústredím stále na prvý cieľ, so špecifickým zameraním na pochopenie TPS a ich aplikácie v BWT ako aj možné využitie aj v iných prípadoch.

3 Travisové čiastkové sumy

Travisové čiastkové sumy (TPS) sa využívajú v komprimovaných dátových štruktúrach a indexovaní na zlepšenie efektivity kompresie dát a rýchlejšie spracovania dotazov. TPS sú nevyhnutné pre:

- **Kompresia dát:** Zlepšenie kompresných algoritmov využitím dátových štruktúr na minimalizáciu redundancie a ich zrýchlenie.
- **Analýza sekvencií:** Efektívne reprezentovanie dátových štruktúr, ako sú de Bruijnové grafy, na spracovanie veľkých genomických dát.
- **Všeobecné dátové štruktúry:** Zlepšenie dátových štruktúr, ako sú tries a suffix trees, pre rýchlejšie spracovanie dotazov a zníženie požiadaviek na úložný priestor.

4 Využitie Travisových čiastočných súm vo Wheelerových grafoch

TPS sú obzvlášť užitočné vo Wheelerových grafoch pre:

- **Reprezentácia de Bruijnových grafov:** Efektívne ukladanie a dotazovanie sekvencií stupňov, čo je kľúčové pre úlohy ako skladanie genómov.
- **Dotazy na stupne:** Rýchle dotazy na in-degrees a out-degrees vrcholov.
- **Kompaktná reprezentácia grafov:** Kompaktné reprezentovanie grafových štruktúr a zlepšenie efektivity dotazov.
- **Praktické aplikácie:** Optimalizácia procesov skladania genómov a efektívne spracovanie veľkých dát.

5 Popis algoritmu pre konštrukciu indexu a spracovanie dotazov

5.1 Konštrukcia indexu

Konštrukcia indexu zahŕňa vytvorenie štyroch hlavných dátových štruktúr:

5.1.1 Dotazy na súčty out-stupňov (D_{out})

- **Inicializácia sekvencie:** Začneme so sekvenciou out-stupňov D_{out} pre všetky vrcholy vo Wheelerovom grafe.
- **Komprimácia sekvencie:** Použijeme kompresie založenej na empirickej entropii pre úsporu miesta.
- **Úprava sekvencie:** Vylepšenie komprimovanej sekvencie pomocnými štruktúrami na uľahčenie dotazov na súčty v konštantnom čase.

5.1.2 Dotazy na rank označení hrán (L)

- **Zoradenie označení hrán:** Vytvoríme zoznam L označení hrán zoradených podľa ich východiskových bodov.
- **Vytvorenie štruktúry na podporu rank:** Použijeme dátovú štruktúru ako wavelet tree pre efektívne rank dotazy.
- **Pomocné informácie:** Uloženie pomocných polí alebo bitových vektorou na zrýchlenie výpočtov rank.

5.1.3 Dotazy na súčty frekvencií označení hrán (C)

- **Výpočet frekvencií:** Určíme frekvencie každého označenia hrany.
- **Kumulatívna suma:** Vytvorenie kumulatívnej sumy C , kde každá položka $C[a]$ predstavuje súčet frekvencií označení hrán lexicograficky menších ako a .
- **Efektívne uloženie:** Použitie kompresnej techniky na efektívne uloženie C .

5.1.4 Dotazy na vyhľadavanie in-stupňov (D_{in})

- **Inicializácia sekvencie:** Začneme so sekvenciou in-stupňov D_{in} pre všetky vrcholy.
- **Komprimácia sekvencie:** Aplikujeme kompresiu založenú na empirickej entropii na D_{in} .
- **Augmentácia sekvencie:** Vylepšime D_{in} štruktúrami, ktoré podporujú rýchle vyhľadávacie operácie.

5.2 Spracovanie dotazov

Pomocou skonštruovaného indexu nasledujúce kroky opisujú, ako efektívne spracovať rôzne typy dotazov:

5.2.1 Dotazy na súčty out-stupňov

- **Vstup:** Index i .
- **Operácia:** Získajme $D_{out}.sum(i)$ pomocou upravenej dátovej štruktúry.
- **Výstup:** Súčet out-stupňov až po i -ty vrchol.

5.2.2 Dotazy na rank označení hrán

- **Vstup:** Označenie hrany a a index i .
- **Operácia:** Vypočítajme $L.rank_a(i)$ pomocou dátovej štruktúry podporujúcej rank.
- **Výstup:** Rank a medzi prvými i označeniami hrán.

5.2.3 Dotazy na súčty frekvencií označení hrán

- **Vstup:** Označenie hrany a .
- **Operácia:** Prístup ku kumulatívnej sume C na získanie $C.sum(a)$.
- **Výstup:** Súčet frekvencií označení hrán menších ako a .

5.2.4 Dotazy na vyhľadavanie in-stupňov

- **Vstup:** Hodnota j .
- **Operácia:** Vykonajme binárne vyhľadavanie alebo priame vyhľadavanie v augmentovanom D_{in} na nájdenie najväčšieho indexu i , kde $D_{in}.search(j) \leq j$.
- **Výstup:** Index i .

6 Nástroj Wheeler Graph Toolkit (WGT)

Nástroj Wheeler Graph Toolkit (WGT) je open-source balík (MIT licencia) určený na generovanie, rozpoznávanie a vizualizáciu Wheelerových grafov. Centrálnou súčasťou WGT je "Wheelie", rýchly algoritmus na rozpoznávanie Wheelerových grafov. Tu je prehľad príkazov a ich funkcií.

6.1 Moduly vo WGT

- **Recognizer:** Určuje, či je daný graf Wheelerovým grafom.
- **Visualizer:** Vizualizuje Wheelerové grafy v bipartitnej reprezentácii.
- **Generators:** Generuje rôzne typy grafov, ako sú tries, de Bruijnové grafy a reverzné deterministické grafy.

6.2 Generátory grafov

6.2.1 Generátor de Bruijnových grafov

Usage:

```
DeBruijnGraph_generator.py
  [-h / --help] [-v / --version] [-o / --ofile FILE]
  [-k / --kmer k-mer length] [-l / --seqLen sequence length]
  [-a / --alnNum alignment number] sequence FATA file
```

Optional arguments:

```
-h / --help : Print the usage of "DeBruijnGraph_generator.py".
-v / --version : Print the version of the program.
-o / --ofile : The name of the output file. Default is "tmp.dot".
-k / --kmer : The k-mer length. Default is "3".
-l / --seqLen : Maximum sequence length for each entry in the FASTA file.
                Default is the full sequence length.
-a / --alnNum : The number of alignments (sequences) used for creating the
                De Bruijn graph. Default is "3".
```

6.2.2 Generátor reverzných deterministických grafov

Usage:

```
RevDetGraph_generator.py [-h / --help] [-v / --version] [-o / --ofile FILE]
                        [-l / --seqLen sequence length] [-a / --alnNum
                        alignment number]
                        multiple sequence alignments (MSA) FASTA file
```

Optional arguments:

```
-h / --help : Print the usage of "RevDetGraph_generator.py".
-v / --version : Print the version of the program.
-o / --ofile : The name of the output file. Default is "tmp.dot".
-l / --seqLen : Maximum sequence length for each entry in the FASTA file.
                Default is the full sequence length.
-a / --alnNum : The number of alignments (sequences) used for creating the
                De Bruijn graph. Default is "3".
```

6.2.3 Generátor tries

Usage:

```
Trie_generator.py [-h / --help] [-v / --version] [-o / --ofile FILE]
                  [-l / --seqLen sequence length] [-a / --alnNum alignment
                  number]
                  multiple sequence alignments (MSA) FASTA file
```

Optional arguments:

- h / --help : Print the usage of "Trie_generator.py".
- v / --version : Print the version of the program.
- o / --ofile : The name of the output file. Default is "tmp.dot".
- l / --seqLen : Maximum sequence length for each entry in the FASTA file.
Default is the full sequence length.
- a / --alnNum : The number of alignments (sequences) used for creating the
De Bruijn graph. Default is "3".

6.3 WGT Recognizer

Usage:

```
recognizer <in.dot> [--version] [-h / --help] [-v / --verbose] [-o / --  
  outDir]  
      [-s / --solver <smt / p>] [-w / --writeIOL] [-r / --writeRange]  
      [-i / --label_is_int] [-b / --benchmark] [-e / --  
        exhaustive_search]  
      [-f / --full_range_search]
```

Options:

version : Print the current version (0.1.0).
help : Print the usage message.
verbose : Run in the verbose mode.
outDir : The directory for the files to be outputted.
solver : Specify which solver to use ('SMT' or 'p'). Default is 'SMT'.
writeIOL : Output the I, O, L three-bitarray data structure.
writeRange : Output the range information produced by the renaming heuristic.
label_is_int : Specify if the edge labels are integers. Default is strings.
benchmark : Run in benchmark mode, outputting results in columns.
exhaustive_search : Run in exhaustive search mode.
full_range_search : Run in full range search mode, skipping the renaming
heuristic.

6.4 WGT Visualizer

Usage:

```
python3 visualizer.py [-h] [-o / --ofile output file] <Wheeler graph in DOT  
  format>
```

Example:

```
python3 visualizer.py ../data/example/out__example/graph.dot
```

7 Relevancia pre môj projekt

Štúdium a implementácia TPS sú kľúčové pre ciele môjho projektu, najmä pri zlepšovaní kompresnej efektivity algoritmu Bzip2. Pochopením a aplikáciou TPS sa snažím dosiahnuť:

- Zlepšenie kompresného pomeru Bzip2 prostredníctvom efektívneho spracovania sekvencií stupňov vo Wheelerových grafoch.

- Implementácia a optimalizácia tunelovacích metód na zníženie redundancie dát a zlepšenie celkového výkonu kompresie.
- Využitie TPS na rýchle a efektívne spracovanie dotazov, čo je nevyhnutné pre spracovanie veľkých dát v praktických aplikáciách.

Navyše, znalosti a nástroje z WGT mi poskytli praktické skúsenosti s prácou s Wheelerovými grafmi, rozpoznávaním ich vlastností a vizualizáciou ich štruktúry, čo je nevyhnutné pre implementáciu efektívnych kompresných techník.

8 Záver

Metodológia Travisových čiastočných súm poskytuje významné výhody v kontexte kompresie dát a analýzy sekvencií, najmä pri aplikácii vo Wheelerových grafoch. Zavedením TPS do môjho projektu sa budem snažiť dosiahnuť lepšie kompresné pomery a efektívnejšie spracovanie dát, čo prispieva k pokroku v kompresných algoritmoch ako Bzip2. Nástroj Wheeler Graph Toolkit ďalej zlepšil moje chápanie a schopnosti pri manipulácii a vizualizácii týchto komplexných grafových štruktúr.

9 Zdroje

Pri štúdiu som použil nasledujúce zdroje:

- <https://oparu.uni-ulm.de/server/api/core/bitstreams/c881cc5a-80c3-40bc-a44c-4a80/content>
- <https://www.ncbi.nlm.nih.gov/tools/sviewer/seqtrackdata/>
- <https://ftp.ensembl.org/pub/release-112/fasta/>
- https://github.com/Kuanhao-Chao/Wheeler_Graph_Toolkit
- <https://www.sciencedirect.com/science/article/pii/S0304397517305285>
- <https://arxiv.org/pdf/2204.07916>
- <https://sourceware.org/bzip2/>
- https://www.uni-ulm.de/fileadmin/website_uni_ulm/iui.inst.190/Mitarbeiter/baier/slides_tunneling.pdf
- https://www.uni-ulm.de/fileadmin/website_uni_ulm/iui.inst.190/Intern/medien/slides_dcc_19.pdf
- <https://github.com/waYne1337/tbwt>
- https://www.youtube.com/playlist?list=UUrDmN9uRVJR7KM8aRE_58Zw