



Übung 1

Algorithmische Bioinformatik

WS 15/16

Yvonne Mayer

Allgemeines

Ablauf der Übung

- Insgesamt 7 Übungszettel
- Abgabe in Gruppen von 2 Personen
- Pro Übung ~zwei Wochen Bearbeitungszeit
- 7 Pflichttermine (alle zwei Wochen)
 - × Ausgabe neuer Übungszettel
 - × Vorstellung der Lösungen letzter Übungszettel durch 2-3 Gruppen
- Termine dazwischen
 - × Klärung von Fragen
 - × Übungen nach Wunsch (nach Möglichkeit vorher Email)
- Webseite:
https://www.informatik.hu-berlin.de/de/forschung/gebiete/wbi/teaching/archive/ws1516/ue_algbio/

Termine im Einzelnen

- Pflichttermine/Themen:
 - × 22.10.2015, Naives Stringmatching, alle Gruppen
 - × 03.11.2015/Do 05.11.2015, Boyer Moore
 - × Di 17.11.2015/Do 19.11.2015, q-gram Index
 - × Di 01.12.2015/Do 03.12.2015, Suffix Arrays
 - × Di 15.12.2015/Do 17.12.2015, Globales Alignment
 - × Di 12.01.2016/Do 14.01.2016, Approximatives Stringmatching
 - × Di 26.01.2016/Do 28.01.2016, Neighbor Joining
- Ansonsten jeden Dienstag/Donnerstag Klärung von Fragen
Ausnahme nächste Woche: keine Übung am 29.10.2015
(stattdessen 4. VL Molekularbiologie), ein Übungstermin für alle am 27.10.2015

Übungsschein

- Schein: Voraussetzung für die Prüfung
- Abgabe der Übungszettel in Gruppen von 2 Personen
 - × Mindestens **51% der Punkte von jedem Zettel** benötigt
 - × Gruppen bestehen/scheitern nur als Ganzes
- Vorstellung der Lösungen der letzten Übung durch 2-3 Gruppen
 - × Wir losen vorstellende Gruppen aus
 - × Ein Student der Gruppe muss Lösung vortragen
 - **immer einen Vortrag parat haben**
 - × Wir behalten uns vor den Student zu bestimmen
 - × Ziel: Jeder Student trägt einmal vor

Aufgaben

- Übungen sind implementationsintensiv
- Implementationen in JAVA
- I.d.R. sind Eingabe, Ausgabe und Aufrufform vorgegeben
- Textaufgaben
 - × Abgabe als PDF
 - × Müssen Gruppennamen beinhalten
- Code-Abgaben
 - × Abgabe als Jar (class und source files!)
 - × Abgaben ohne Quellcode werden ignoriert
 - × Dateiname: AssignmentX_GrXY.jar
 - × Kompilierung unter Java 1.7 (oder niedriger)
 - × Jar Datei auf gruenau2 testen!
- Nichteinhaltung der Regeln: Punkteabzug

Wettbewerb

- Einige Aufgaben (4-7) sind als Wettbewerb konzipiert
- Punkte gibt es (unabhängig von den Punkten für korrekte Lösungen) für die schnellste Lösung
- Messungen auf gruenau2:
 - `java version "1.7.0_85"`
 - `OpenJDK Runtime Environment (IcedTea 2.6.1) (suse-24.21.1-x86_64)`
 - `OpenJDK 64-Bit Server VM (build 24.85-b03, mixed mode)`
- Wir messen mehrmals mittels Linux „time“
 - Parallelisierung lohnt sich nicht
- Beste Gruppe bekommt am Ende der Veranstaltung eine kleine Überraschung

Gruppeneinteilung

(1) Aufteilung in zwei Gruppen (Di/Do)

- wenn > 20 angemeldete Teilnehmer
- ansonsten: Abstimmung Übung Di oder Do

(2) Aufteilung in Gruppen von 2 Personen zur Abgabe der Übungszettel

- Gruppen bitte bis Dienstag in Goya eintragen als „GruppeX“

Gruppe1: X, Y

Gruppe2:

Gruppe3:

Gruppe4:

Gruppe5:

Gruppe6:

Gruppe7:

Übung 1

Übung 1.1

(1) Sequenzen lesen (5 Punkte)

- Für die Aufgaben müssen Sie die Dateien einlesen, die DNA Sequenzen enthalten
- Die Dateien sind im Fasta Format
 - Zitat: „A sequence in FASTA format begins with a single-line description, followed by lines of sequence data. The description line is distinguished from the sequence by a greater-than symbol („>“) in the first column. ... The sequence ends if another line starting with a „>“ appears; this indicates the start of another sequence“
 - Beispiel:

```
> gi|5524211|gb|AAD44166.1| cytochrome b
LCLYTHIGRNIYYGSYLYSETWNTGIMLLLITMATAFMGYVLPWGQMS
EWIWGGFSVDKATLNRFFAFHFILPFTMVALAGVHLTFLHETGSNNPL
LLLLLALLSPDMLGDPDNHMPADPLNTPLHIKPEWYFLFAYAILRSVP
GLMPFLHTSKHRSMMLRPLSQALFWTLTMDLLTLTWIGSQP
>gi|5454351|gb| cytochrome x
LLLITMATAFMGYVLPWGQMSLCLYTHIGRNIYYGSYLYSETWNTGIM
LLLITMATAFMGYVLPWGQMS
```

Übung 1.2

(2) Stringmatching (8 Punkte)

- Implementieren Sie einen String-Matching-Algorithmus, der alle Vorkommen eines Patterns (kurzer String) in einem Template (langer String) findet
- Sie müssen diesen Algorithmus selbst implementieren; `STRING.indexof()`, `Pattern.matches()`, etc. reicht nicht!
- Beispiel GATATC:

>Some FASTA Sequence

```
aaaattatttctaaggagatacgcgagaggggcttctcaaattttattcagagatggatggttttagatgggtggtttaagaaaagcagta
ttaaatccagcaaaactagaccttaggtttattaaagcgaggcaataagtttaattggaattgtaaaataattcttcttcatttggtg
gaggaaaactagttaacttcttaccatgcagggatatcccataggggtcgaatacgatctgtcactaagcaaaggaaaatgtgagt
gtagacttttaaacattttttattaatgacttttagagaatcatgcatttgatgttactttcttaacaatgtgaacatatttatgcgat
taagatgagttatgaaaaaggcgaatatattattcagttacatagagattatagctgggtctattcttagttataggacttttgacaa
gatagcttagaaaaataagattatagagcttaataaaaagagaacttcttggaattagctgcctttgggtgcagctgtaatggctattgg
tatgggtccagcttactgggttaggttttaatagaaaaattccccatgattgctaattatatactatcctatttgagaacaacgtgcgaa
gatgagtggcgaattgggttcattattaactgctgggtgctatagtagttatccttagaaaagatatataaatctgataaagcaaaatcc
tggggaaaatattgctaactgggtgctggtaggggtttggggattggattatttcctctacaagaaatttgggtgtttactgatatcctt
ataaataatagagaaaaaattaataaagatgatat
```

Übung 1.1 und 1.2: Programmaufruf und Ausgabe

- Auf der Übungs-Homepage sind zwei Dateien bereitgestellt, die das Template und mehrere Patterns enthalten
 - × Template: Chromosom 20 des Menschen (50MB)
 - × Patterns: Schnittstellen von Restriktionsenzymen
- Programm muss wie folgt aufrufbar sein:
 - × `java -jar Assignment1_GrXY.jar file1 file2`
 - × file1: Dateiname Patterns, file2: Dateiname Template
 - × file1 und file2 sind unkomprimiert
 - × Ausgabe auf STDOUT
 - × Pro Paar (Template/Pattern) muss das Programm ausgeben:
 - Patternlänge
 - Anzahl Fundstellen
 - Startpositionen der ersten 10 Fundstellen

Übung 1.3

(3) Patternlänge und Laufzeit (7 Punkte) (nicht Teil des Wettbewerbs)

- Erstellen Sie einen Plot (PDF), der die Laufzeit in Abhängigkeit der Patternlänge (5-50bp) darstellt.
Diskutieren Sie das Ergebnis.
- Optional: Testen sie wie sich unterschiedliche Alphabetgrößen auf die Laufzeit auswirken.

Wettbewerb

- Umfasst Aufgaben 1.1 und 1.2
- Wir messen die Gesamtlaufzeit Ihres Verfahrens über alle Pattern (mittels Linux „time“)
- × Wur verwenden 20 neue Patterns, deren Länge zwischen 5 und 50 Zeichen liegt (Alphabet $E = \{ACGTN\}$)
- Wettbewerbspunkte:
 - × Platz 1: 3 Punkte
 - × Platz 2: 2 Punkte
 - × Platz 3: 1 Punkt

Zur Orientierung

Anzahl Vorkommen der Pattern im Template

- tccgga: 2506
- gctacc: 6799
- taataa: 28279
- cctcagc: 17520
- cctgcagg: 2425
- ggcgcgcc: 141
- cccccccccc: 140
- aaaaaaaaaa: 52695
- aaaaaaaaaa: 44140
- aaaaaaaaaaaaaaaaaa: 25063
- aaaaaaaaaaaaaaaaaa: 8571

Abgabe

- Abgabe bis Sonntag den 01.11.2015 um 23:59 Uhr
- Abgabe per Email an: mayeryvo@informatik.hu-berlin.de
(gerne auch Fragen zur Übung per Email)
- Abgabe wie beschrieben (PDF mit Plot, Jar Datei mit Quellcode)
- Bitte die geschätzte Bearbeitungszeit mitteilen
(z.B. 10h für zwei Teilnehmer)