

Prof. Dr. Knut Reinert  
Enrico Siragusa  
Sascha Meiers  
Christoph Hartmann

Institut für Informatik  
AG Algorithmische Bioinformatik

## Algorithmen und Datenstrukturen in der Bioinformatik

### Neuntes Übungsblatt WS 11/12

Abgabe Montag, 02.01.2011, 15:00 Uhr, diesmal auch per E-Mail

Name:

Übungsgruppe:

A  B  C

Matrikelnummer:

---

Niveau I

---

#### Aufgabe 1: Pidgeonhole Principle

Beweisen Sie das Lemma 1 aus dem Skript, Kapitel 6.2.

**Lemma 1.** *Gegeben sei ein Match zwischen einem Text  $Occ$  und einem Pattern  $P$  mit  $k$  Fehlern, desweiteren sei  $P = p^1, \dots, p^j$  eine beliebige Konkatenation von Infixen (= Teilstrings) von  $P$  und seien  $a_1, \dots, a_j$  nicht-negative Ganzzahlen mit  $A = \sum_{i=1}^j a_i$ . Dann gilt: es existiert ein  $i \in [1 \dots j]$ , so dass  $Occ$  ein Infix enthält, welches  $p^i$  mit höchstens  $\lfloor a_i k / A \rfloor$  Fehlern matcht.*

*Hinweis:* Es empfiehlt sich ein relativ simpler Widerspruchsbeweis.  $a_1, \dots, a_j$  sind dabei willkürliche gewählte Zahlen. Die vorangehende Aussage ("Teilt man das Pattern in  $k+1$  Teile ...") ist ein Spezialfall dieses Lemmas, bei dem man  $a_i = 1 \quad \forall i$  wählt.

---

#### Aufgabe 2: Approximate Matching

Finden Sie das Pattern  $P = \text{WIRSING}$  mit maximal  $k = 3$  Abweichungen im Text  $T = \text{WIRSINDIRRSINNIG}$ . Benutzen Sie dafür den Algorithmus mit hierarchischer Verifizierung aus dem Skript, Kapitel 6.4. Wenn Sie wollen, können Sie die exakten Treffer der Teilworte mit dem Aho-Corasick-Algorithmus suchen; ansonsten reicht es aus die Treffer per Hand zu finden.

---

Niveau II

---

### Aufgabe 3: PEX

Der PEX-Algorithmus ist ein Algorithmus zur approximativen Stringsuche, der das Schubfachprinzip nutzt. Im Skript, Kapitel 6.5 sind die Pseudocodes für die Baumerstellung und Suchphase des PEX-Algorithmus gegeben. Benutzen Sie diese, um

- a) einen Suchbaum für das Wort BRAUN für  $k = 2$ , also maximal zwei abweichende Zeichen, zu erstellen
- b) mit diesem Suchbaum den Text BLAUKRAUT zu durchsuchen.

---

### Programmieraufgabe (Abgabe Montag, 9.01.2012, 15:00)

---

**P-Aufgabe 5:** Implement a program to map a set  $\mathcal{R}$  of genomic reads to a reference genome  $G$  with at most  $k$  mismatches. To this end, your program should perform the following steps:

- a) Read the reference genome  $G$  and the reads  $\mathcal{R}$  from their corresponding input files (Template code given)
- b) Construct a  $q$ -gram Index over  $G$
- c) For each read  $R \in \mathcal{R}$ 
  - i) Partition  $R$  into  $k + 1$  pieces
  - ii) Search each piece in  $G$  using the  $q$ -gram Index (Each occurrence of a piece of  $R$  in  $G$  is called a *hit*)
  - iii) Verify that  $R$  matches with at most  $k$  mismatches the substring of  $G$  surrounding each hit
  - iv) Write end positions of all approximate occurrences of  $R$  in  $G$  into an output file (Beware of reporting each approximate occurrence only once)

Hints:

- The underlying Alphabet is  $\Sigma = \{\mathbf{A}, \mathbf{C}, \mathbf{G}, \mathbf{T}\}$ .
- Reads are short sequences of length 36–400. For simplicity, all reads will have the same length.
- A naive algorithm for Hamming Distance can be used to verify that a read  $R$  matches a substring of  $G$  with at most  $k$  mismatches.
- Your program must take the file containing the reference genome  $G$  as the first command-line argument, the file containing the set of reads  $\mathcal{R}$  as the second argument, the number of mismatches  $k$  as the third argument, the output file as the fourth argument.
- The reference genome  $G$  is stored on a single line.
- Each read  $R \in \mathcal{R}$  is stored on a single and distinct line.
- Each approximate occurrence must be written in a separate row of the output file, following the format:  $\langle \text{Read } R \rangle, \langle \text{End position in } G \rangle, \langle \text{Mismatches} \rangle$

- You can download the code template at <https://svn.imp.fu-berlin.de/agbio/aldabi/ws11/documents/aufgabe5>.

Example:

- File with reference genome  $G$ :  
AAGATACATTTTTAAAAAAAAAACAATTT
- File with reads  $\mathcal{R}$ :  
GATACA  
CATTTT
- Output file:  
GATACA,7,0  
CATTTT,11,0  
CATTTT,28,1

Evaluation:

- This exercise will be evaluated with 6 points instead of 3.