

# Merkkijonomenetelmät (syksy 2008)

## Harjoitus 2

Niko Välimäki ti 16.09. klo 10.15–12 CK111

1. Luennolla mainittu Horspool-algoritmi käyttää vain esiintymäheuristiikkaa. Jos aakkosto on pieni, keskimääräinen siirtymä jää lyhyeksi. Tilannetta voi parantaa tekemällä siirto yhden merkin sijasta  $q$ :n merkin perusteella.
  - (a) Analysoi algoritmin keskimääräistä aikavaatimusta  $q$ :n merkin esiintymäheuristiikalla. (Asymptoottinen aikavaatimus riittää.)
  - (a) Mikä on optimaalinen  $q$ :n arvo? (Asymptoottinen arvo riittää.)

Tehtävässä oletetaan, että aakkoston  $\Sigma$  kukin merkki esiintyy samalla todennäköisyydellä  $1/\sigma$  jokaisessa  $P$ :n ja  $S$ :n positiossa.

2. Triviaali- ja KMP-algoritmit ovat *aakkostoriippumattomia*: ne tekevät vain merkivertailuja ja niiden toiminta ei riipu aakkostosta, erityisesti niiden pahimman tapauksen aikavaatimus ei riipu aakkoston koosta. BM-algoritmin toiminta sen sijaan riippuu aakkostosta.
  - (a) Anna esimerkkejä tilanteista, joissa aakkostoriippuvuus rajoittaa BM-algoritmin käyttökelpoisuutta.
  - (b) Saadaanko BM-algoritmista aakkostoriippumaton, jos toinen sen heuristikoista poistetaan?
  - (c) Ovatko Karp-Rabin-algoritmi ja shift-or-algoritmi aakkostoriippumattomia? Onko jollakin niistä aakkostoriippuvuus erilaista eli enemmän tai vähemmän rajoittavaa kuin BM-algoritmilla?
3. Hahmottele seuraavien algoritmien yleistys monen hahmon tapaukseen:
  - (a) Karp-Rabin
  - (b) Shift-or

Aikavaatimuksen tulee olla parempi kuin kunkin hahmon etsiminen erikseen saman algoritmin perusversiolla.

4. Muodosta AC-algoritmin mukainen jononsovitusautomaatti hahmojoukolle  $\{\text{SAKARI, SAKU, ARI, MARKO, ILMARI}\}$ .
5. Kehitä menetelmä, jolla NFA, joka säännölliselle lausekkeelle  $A$  löytää  $L(A)$ :n esiintymät tekstistä  $S$ , pystyy tulostamaan myös ne  $L(A)$ :n jonot, jotka ko. paikassa esiintyvät. Esim. hahmolla  $P = b(\text{ac} \cup \text{b})^*\text{ba}$  tekstistä  $S = \text{cbbbacacabacc}$  tulisi löytää 5 esiintymää:  $S[2 \dots 5]$ ,  $S[3 \dots 5]$ ,  $S[2 \dots 10]$ ,  $S[3 \dots 10]$  ja  $S[4 \dots 10]$ .