

## CS-C3110 Datasta tietoon

Hollmén

Tentti, 3.4.2017

Information for English speakers: You can answer in English, however, the questions are only available in Finnish.

1. Vastaa seuraaviin väittämiin joko TOSI tai EPÄTOSI.

- a) Kun tasoihitaista algoritmia ajetaan 0-1 -datalle, kaikki kandidaattijoukot ovat kattavia.
- b) Vain osa kattavan joukon osajoukoista on kattavia.
- c) PageRank -algoritmillä haetaan kattavia joukkoja.
- d) Mahdollisten kattavien joukkojen määrä  $d$ -ulotteiselle 0-1 -datalle on  $2^d$ .
- e)  $c$ -means -algoritmissä klusterikeskukset esitetään vektoreina data-avaruudessa.
- f) Hierarkisen klusteroinnin tuloksena saadaan datan ryhmittely optimaaliseen määrään ryhmiä.
- g) Hierarkinen klusterointi antaa kaikki klusterointitulokset yhdestä klusterista  $d$  klusteriin, jossa  $d$  on datavektoreiden dimensio.
- h)  $k$ :n lähimmän naapurin luokittelijassa valitaan  $k$ :n arvoksi aina parillinen kokonaisluku.
- i)  $k$ :n lähimmän naapurin luokittelijassa parhaan tuloksen antaa aina kaikkein pienimmät  $k$ :n arvot.
- j) PageRank -algoritmi esittää verkon solmujen relevanssin keskuspainojen ja auktoriteetti-painojen avulla.
- k) Keskukset ja auktoriteetit -algoritmi esittää verkon solmujen relevanssin kahdella erilisellä painovektorilla.
- l) Bayesin kaavassa prioritermi riippuu datasta.
- m) MAP -estimoinnissa priorijakauman vaikutus on sitä pienempi, mitä enemmän mittausdataa on käytettävissä.
- n) Bayesin kaavassa prioritermi kuvaa käsitystä parametrin todennäköisyysjakaumasta mittauksen jälkeen.
- o) lineaarinen suodin voidaan toteuttaa konvoluution avulla
- p) Kahden signaalin konvoluutio aikatasossa voidaan toteuttaa niiden taajuusmuunnosten avulla tulona taajuustasossa.
- q) Kun yksiulotteisen SOM-kartan yksiköt ovat kerran järjestyneet moniulotteisessa data-avaruudessa, ne eivät voi enää mennä epäjärjestykseen.
- r) Itseorganisoiva kartta -algoritmi on kehitetty Suomessa.

2.  $d$ -ulotteiset datavektorit ovat tasaisesti jakautuneita hyperkuution, jonka sivun pituus on  $s$ . Määritellään sisäpisteiksi ne, joiden etäisyys hyperkuution pinnalta on vähintään  $\epsilon > 0$ . Osoita, että sisäpisteiden joukon kokonaistodennäköisyys (tasainen tiheysjakauma integroituna sisäpisteiden joukon yli) menee nolnaan kun  $d \rightarrow \infty$ , toisin sanoen hyvin suurissa dimensioissa melkein kaikki datapisteet ovat hyperkuution pinnalla.

3. Laske suurimman uskottavuuden estimaatti eksponentiaalijakauman

$$p(x|\lambda) = \lambda e^{-\lambda x}$$

parametrille  $\lambda$  kun suureesta  $x$  on olemassa otos  $x(1), \dots, x(n)$ .