

- Ehkä 1 jäsen lisää?
  - 2. vuoden tutkijalinjalainen
- Esa Junttila – ”tekninen asiantuntija”
- Asiakas Salmenkivi
- Ehkä joku toinenkin asiakas Heikki Lokki?
- Wikla: ”Suunnitelkaa Javalla, tehkää Fortranilla!”
- Aiheesta:
  - mallintamista, prob, stat
  - päätellään kamaa aineistosta, ei visuaalista, vaan probalistista
  - esimerkki: kolikon tasapuolisuus. Data = ”1000” 1 on kr. p = ”tn että tulee 1”

$$\Pr(D | p = 1/2) = (1/2)^4 = \frac{1}{16} = \frac{16}{256}$$

$$\Pr(D | p = 1/4) = \frac{1}{4} \cdot \left(\frac{3}{4}\right)^3 = \frac{27}{256}$$

paras näistä kolmesta. Itseasiassa kaikista

mahd.

$$\Pr(D | p = 3/4) = \frac{3}{4} \cdot \left(\frac{1}{4}\right)^3 = \frac{3}{256}$$

Päätelläänkö että lantti on painotettu  $P(1) = 1/4$  ?

Ei, olisi tarvittu lisää dataa.

Otetaan aiempi tieto huomioon.

Kaavio lantin kruunan tnästä: jakauma jossa piikki puolikkaan kohdalla.

Tai oletetaan tasajakauma, kuten aluksi.

$$\Pr(p | D) = \frac{\Pr(p) \cdot \Pr(D | p)}{\Pr(D)}$$

Missä  $\Pr(p)$  on ennakkokäsitys jakaumasta.

Ongelma on  $\Pr(D)$ . datan tn kaikkien yli... Mutta sitä ei tarvitse aina laskea, sillä

$$\Pr(p | D) \cdot a = \Pr(p) \cdot \Pr(D | p)$$

Käydään läpi p arvoilla 0.01, ..., 0.99

Saadaan kuvaaja, suhteet kiinnostavat, eivät itsessään tnät.

Kolikkotapauksessa saataisiin ehkä jakauma, joka olisi vähän lähempänä 1/4 aa.

$\Pr(D | p)$  sanotaan uskottavuudeksi (Likelihood)

$\Pr(p | D)$  on meidän posteriori-tn.

Entäs jos on paljon parametreja?

Kaikkien kokeilu ei välttämättä ole järkevää 1000-ulotteisessa.

Tehdään datasta päättelyä, approksimaatiota.

Kun arvataan p jonka tn joka on suuri, kokeillaan sen vierestä... hill climbing

- Idea: ei hirveän monimutkaisia konkreettisia malleja, jotka sopisivat moniin ongelmiin, ongelmat hyvin samanlaisia. Ohjelman pystyttävä ratkaisemaan pari yleistä mallia.
- Hyvin dokumentoitu, voitaisiin käyttää näitä komponentteja tekemään kääntäjä joka laskee erilaisia ongelmia... epämääräistä.
- Ongelma malleissa on kokeiltavien vaihtoehtojen määrä... mitä enemmän parametreja, sitä työläämpi, vaikeampi löytää hyviä p.
- Läjä yhteentoimivia metodeja
- malli syötteenä, ratkaistaan ongelma
- periaatteessa ei väliä, mitkä ovat dataa...
- ei-datan ylimmälle tasolle a priori-tn

Postscript-kalvoista levädatan arviot lämpötilasta  
jakaumat N, Poisson

toinen malli jossa apumuuttuja r johon vaikuttavat opt\_t, tol\_t, scale ja temp.  
R vaikuttaa abundanceen.

Idea:  $r = f(\text{temp}, \text{opt}_t, \text{tol}_t, \text{scale})$   
ja r vaikuttaa stokastisesti abundanceen.  
 $\text{abundance} \sim \text{Poisson}(r)$

ja sitten laitetaan jotkin jakaumat  $\text{opt}_t \sim N(10, 2)$  tai jotain... kaikille param annetaan jokin jakauma.

Kts. Postscriptista

tarkoitus saada selville muinaiset lämpötilat

tai vaikka toiseen suuntaan levän preferenssit.  
Aina ei-datan posteriorijakauma(t).

integraalin approksimointia odotusarvon laskemiseksi

$$\int \mathbf{x} \pi(\mathbf{x}) d\mathbf{x} \approx \frac{1}{N} \sum_{i=1}^N \mathbf{x}_i \quad (\text{monte carlo-integrointi}) \quad (\text{myös postscriptissa})$$

jos ei voida generoida riippumattomia x,  
generoidaan markovin ketjun muodostavia...

$\mathbf{X}_0, \mathbf{X}_1, \mathbf{X}_2, \mathbf{X}_3$  aina seuraava riippuu nykyisestä, ei edellisistä.

Entäs jos  $\pi$  on 100-dimensioinen?

Kun löydetään jokin iso tn, kokeillaan seuraavaksi sen läheltä. Hyväksytään testillä, tai hylätään.  
Markovin ketju-tyyliin. (Metropolis-Hastings-algoritmi)

... lopulta valittujen x ketju noudattaa jakaumaa  $\pi$ .

$\mathbf{X}_0$  on alkuarvo. Kokeillaan vaihtaa jokin  $\mathbf{X}_0$  :n parametri, hyväksytään riippuen sen todennäköisyydestä ja siitä, onko saatu  $\mathbf{X}_0$  ' todennäköisempi kuin alkuarvo.

Esim. Jos nyt jotakin ehdotusta tässä ei hyväksyttäisi, toinen kandidaatti tilalle ja saadaan

$$\mathbf{x}_0 = \begin{pmatrix} \theta_1^0 \\ \theta_2^0 \\ \theta_3^0 \end{pmatrix} \text{ yksi parametri taas kohdalleen.}$$
$$\begin{pmatrix} \theta_1^1 \\ \theta_2^0 \\ \theta_3^0 \end{pmatrix}$$
$$\begin{pmatrix} \theta_1^1 \\ \theta_2^1 \\ \theta_3^0 \end{pmatrix}$$
$$\mathbf{x}_1 = \begin{pmatrix} \theta_1^1 \\ \theta_2^1 \\ \theta_3^1 \end{pmatrix}$$

