

24.05.2005 Asiakastapaaminen

Malleista.

- satunnaismuuttuja (tn. laskennasta), arvojen summa 1.
- diskreetti sm: arvot pisteitä, (pistetodennäköisyys)funktio
- jatkuva: tiheysfunktio, integraali 1. Pisteet eivät kerro mitään, koska pisteen tn on aina 0. (integroi, ja kokeile mitä tapahtuu)
- Kertymäfunktio: laskee kuinka ”todennäköisyysmassa” kertyy tiheysfunktion edetessä. Tämä introa.

Lintu:

linnun pesintä ruudussa:

$x, x \in \{0, 1\}$

obs, joka kertoo havainnon:

$obs \in \{0, 1, 2, 3\}$

(dataa)

$$p(x, obs) = p(x) p(obs|x) \text{ yhteisjakauma, (ehdollinen todennäköisyys)}$$

Tämä yhteisjakauma vastaa mallia:



Tarkoituksena muodostaa ilmiön suureille yhteisjakauma, kaikki suureet eivät ole tuntemattomia, jotkin ovat dataa. Idea on että yhteistodennäköisyysfunktiossa kiinnittämällä data voidaan päätellä jotain tuntemattomista muuttujista. Tässä esimerkissä halutaan päätellä x:stä jotakin.

$p(obs|x)$  uskottavuusfunktio, kuinka uskottavaa on että lintu havaitaan, kun oletetaan että pesii/ei pesi.

Esimerkki:

Taulukko: (arvot hatusta)

	Obs = 0	Obs = 1	Obs = 2	Obs = 3
x = 0	0.7	0.2	0.1	0
x = 1	0.1	0.3	0.3	0.3

Ja vaikkapa  $p(x = 1) = 0.5$ ,  $p(x = 0) = 0.5$ .

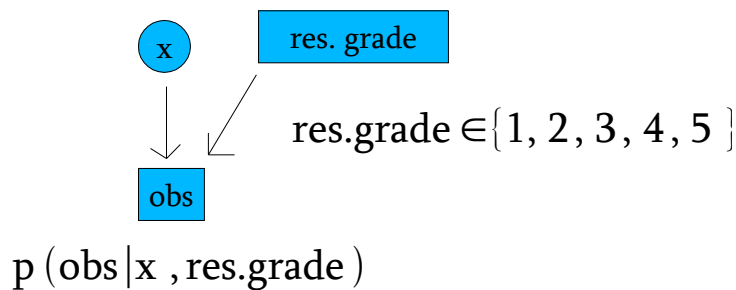
Nyt on määritelty yhteisjakauma.

Esim.  $p(x = 1, \text{obs} = 2) = p(x = 1) p(\text{obs} = 2 | x = 1) = 0.5 \cdot 0.3 =$

Jos obs on tunnettu:  $p(x | \text{obs}) = \frac{p(x) p(\text{obs} | x)}{p(\text{obs})}$  (Bayesin kaava)

(Esimerkin todennäköisyyksillä):

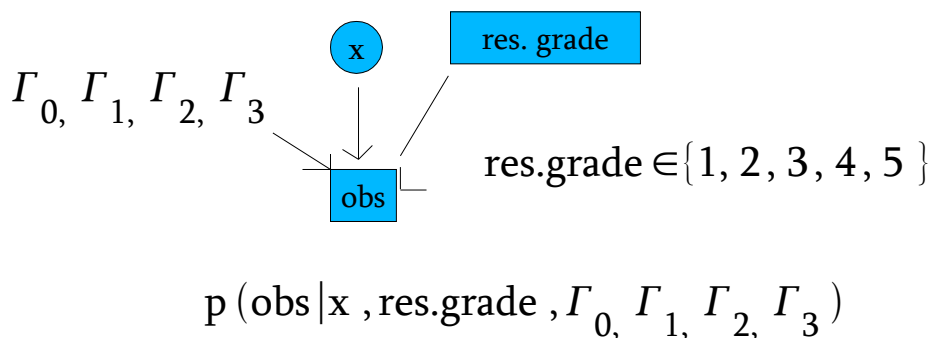
$$p(x = 0 | \text{obs} = 0) = \frac{\frac{1}{2} \cdot \frac{7}{10}}{\frac{1}{2} \cdot \frac{7}{10} + \frac{1}{2} \cdot \frac{1}{10}} = \frac{7}{8}$$



Res. Grade on annettu, sille ei (periaatteessa) tarvita todennäköisyyttä, kun on arvot.

Nyt jokaiselle res.graden arvolle tarvittaisiin erillinen taulukko (esimerkistä).

Heitetään taulukon ensimmäiselle riville arvot  $\Gamma_0, \Gamma_1, \Gamma_2, \Gamma_3$

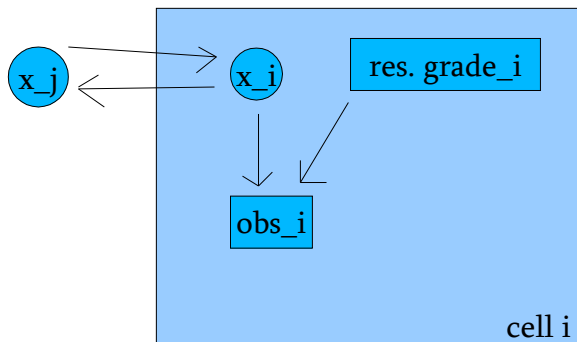


$$\Gamma_0, \Gamma_1, \Gamma_2, \Gamma_3 \sim \text{Dirichlet}(0.3, 0.3, 0.3)$$

Sama toiselle riville...

$$\text{obs} = \begin{matrix} 0 & 1 & 2 & 3 \\ x=0 & \Gamma_{0,0}, \Gamma_{0,1}, \Gamma_{0,2}, \Gamma_{0,3} \end{matrix}$$

$$x=1 \quad \Gamma_{1,0}, \Gamma_{1,1}, \Gamma_{1,2}, \Gamma_{1,3}$$



Ruudut riippumattomia, voidaan laskea

$$\text{yhteistodennäköisyys} \quad p(\mathbf{x}, \text{obs}) = \prod_{\forall i} p(x_i) p(\text{obs}_i | x_i, \text{res. grade}_i)$$

Jos spatiaalinen riippuvuus otetaan mukaan, nämä eivät ole riippumattomia.

$$p(x_i | \bar{x}_{-i}) \quad \text{Näitä aika monta... tarvittaisi aika monta taulukkoa.}$$

Sovitaan, että  $x_i$  riippuu vain naapureistaan.

$$p(x_i | \bar{x}_{-i}) = p(x_i | \bar{x}_j) \quad , i \sim j \text{ (} i \text{ ja } j \text{ naapureita) (esim. Neljä ympäröivää ruutua)}$$

(Markovin satunnaiskenttä)

$$\pi(\bar{x}) = \exp(\beta S(\bar{x})) \cdot Z^{-1}$$

$$S(\bar{x}) = \text{lkm} \{(i, j) \in S \times S : i \sim j, x_i : x_j\}$$

Kaavaan voidaan haluta joitakin muitakin tekijöitä, kuten onko ruutu rannikkoa, yms...

Tässä  $x_j$  :t ovat naapurit,  $\beta$  on tasaava tekijä, joka kertoo kuinka tehokkaasti naapurit vaikuttavat.

Eli iso  $\beta$  tasaa dataa, pieni  $\beta$  lisää "kontrastia".

Jos  $\beta$  :sta tehdään satunnaismuuttuja, hommasta tulee hankalaa.

$$\pi(\bar{x}) = \exp(\beta S(\bar{x})) \cdot Z^{-1}(\beta)$$

$\pi(\mathbf{x})$  on  $\mathbf{x}$ :n priorin, jos spatiaalinen riippuvuus otetaan mukaan.

$$P(\mathbf{x}|\text{obs}) = \pi(\mathbf{x}) p(\text{obs}|\mathbf{x})$$

$$\log \frac{p_i}{1-p_i} = \alpha(C_i) + \beta \sum_{i \sim j} x_j$$

$\alpha$  kuvaa jonkin ruudun ominaisuuden  $C$  voimakkuutta.  $\alpha$  ja  $\beta$  voivat olla globaaleja muuttujia. Tosin  $\alpha$  voitaisiin haluta joka lintuun liittyvänä erikseen.

PIANOS työnimi näillä näkymin.