

# 1. TILASTOLLINEN HAHMONTUNNISTUS

Tilastollisissa hahmontunnistusmenetelmissä piirteitä tarkastellaan tilastollisina muuttujina

Luokittelussa käytetään hyväksi seuraavia tietoja: luokkien *a priori* tn:iä, luokkien ehdollisia tnjakaumia ja tehtyjä havaintoja eli opetusdataa

Hahmon luokka valitaan korkeimman *a posteriori* tn:n tai siitä johdetun funktion mukaisesti tai minimoimalla päätökseen liittyvän riskin odotusarvoa

## 1.1 Ongelman asettelu

- Hahmo esitetään piirrevektorin  $\mathbf{x} \in \mathbb{R}^n$  avulla
- Hahmot halutaan jakaa  $M$ :ään luokkaan  $\omega_1, \dots, \omega_M$
- Luokkien *a priori* tn:t ovat  $P(\omega_1), \dots, P(\omega_M)$
- Luokkien ehdolliset tnjakaumat ovat  $p(\mathbf{x}|\omega_1), \dots, p(\mathbf{x}|\omega_M)$

- Jos edellä mainittuja tn:iä ja tnjakaumia ei tunneta, ne voidaan estimoida opetusdatasta:
  - Kun opetusnäytteitä yhteensä  $N$  kpl ja luokasta  $\omega_i$  niitä on  $N_i$  kappaletta,  $\hat{P}(\omega_i) = N_i/N$
  - Luokkien ehdollisten tnjakaumien estimointia käsitellään myöhemmin
- Mitkä ovat luokkien *a posteriori* tnjakaumat?
- Ol., että jokaisen luokittelutapahtumaan voidaan liittää kustannus: Mitkä ovat eri päätösten riskien odotusarvot?
- Jaetaan piirreavaruus osiin  $R_1, \dots, R_M$  ja tehdään luokittelupäätös seuraavasti: jos  $\mathbf{x} \in R_i$ , valitaan luokka  $\omega_i$
- Mitkä ovat eri luokkia vastaavat alueet piirreavaruudessa, mitkä ovat aluejaon kriteerit?

## 1.2 “Bayes Decision Theory”

- Optimaalinen tapa suorittaa luokittelu
- Tarkastellaan aluksi kahden luokan,  $\omega_1$  ja  $\omega_2$ , tapaus
- Käyttäen Bayes-sääntöä (Bayes rule) *a posteriori* tnt:t saadaan lasketua seuraavasti:

$$P(\omega_i|\mathbf{x}) = \frac{p(\mathbf{x}|\omega_i)P(\omega_i)}{p(\mathbf{x})}, \quad (1)$$

missä

$$p(\mathbf{x}) = \sum_{i=1}^2 p(\mathbf{x}|\omega_i)P(\omega_i) \quad (2)$$


- Jaetaan piirreavaruus osiin  $R_1$  ja  $R_2$  siten, että valitaan aina se luokka, jonka *a posteriori* tn on korkeampi. Luokittelu tehdään siis seuraavasti:

$$\begin{aligned} \text{Jos } P(\omega_1|\mathbf{x}) &> P(\omega_2|\mathbf{x}), \mathbf{x} \text{ kuuluu luokkaan } \omega_1 \\ \text{Jos } P(\omega_1|\mathbf{x}) &< P(\omega_2|\mathbf{x}), \mathbf{x} \text{ kuuluu luokkaan } \omega_2 \end{aligned} \quad (3)$$

- Jos luokkien *a priori* tn:t ovat samat, saadaan:

$$p(\mathbf{x}|\omega_1) \geq p(\mathbf{x}|\omega_2) \quad (4)$$

- Kohtaa, jossa luokkien *a posteriori* tn:t ovat samat, kutsutaan päätösraja ja se jakaa piirreavaruuden alueiksi  $R_1$  ja  $R_2$



## Luokitteluvirheen tn:n minimointi

- Täydellisen, virheettömän luokittelun saavuttaminen ei ole aina edes teoriassa mahdollista
- Luokitteluvirheen tn voidaan laskea seuraavasti:

$$P_e = P(\mathbf{x} \in R_2, \omega_1) + P(\mathbf{x} \in R_1, \omega_2) \quad (5)$$

- Edellinen kaava voidaan kirjoittaa myös näin:

$$\begin{aligned} P_e &= P(\mathbf{x} \in R_2 | \omega_1)P(\omega_1) + P(\mathbf{x} \in R_1 | \omega_2)P(\omega_2) \\ &= P(\omega_1) \int_{R_2} p(\mathbf{x} | \omega_1) d\mathbf{x} + P(\omega_2) \int_{R_1} p(\mathbf{x} | \omega_2) d\mathbf{x} \\ &= \int_{R_2} P(\omega_1 | \mathbf{x})p(\mathbf{x}) d\mathbf{x} + \int_{R_1} P(\omega_2 | \mathbf{x})p(\mathbf{x}) d\mathbf{x} \end{aligned} \quad (6)$$

- Koska  $R_1$ :n ja  $R_2$ :n unioni kattaa koko piirreavaruuden,

$$\int_{R_1} P(\omega_1 | \mathbf{x})p(\mathbf{x}) d\mathbf{x} + \int_{R_2} P(\omega_1 | \mathbf{x})p(\mathbf{x}) d\mathbf{x} = P(\omega_1) \quad (7)$$

- Yhdistämällä kaavat (6) ja (7) saadaan:

$$P_e = P(\omega_1) - \int_{R_1} (P(\omega_1|\mathbf{x}) - P(\omega_2|\mathbf{x}))p(\mathbf{x}) d\mathbf{x} \quad (8)$$

- Edellisestä nähdään helposti, että  $P_e$  minimoituu silloin, kun

$$\begin{aligned} R_1 &: P(\omega_1|\mathbf{x}) > P(\omega_2|\mathbf{x}) \\ R_2 &: P(\omega_2|\mathbf{x}) > P(\omega_1|\mathbf{x}), \end{aligned} \quad (9)$$

- Useamman kuin kahden luokan tapaukselle voidaan johtaa vastaavalla päättelyllä luokitteluvirhetn:n minimoiva päätössääntö:

$$R_i : P(\omega_i|\mathbf{x}) > P(\omega_j|\mathbf{x}) \quad \forall j \neq i \quad (10)$$

## Riskin odotusarvon minimointi

- Luokitteluvirheen minimointi ei ole paras suunnittelukriteeri, silloin jos erilaisiin luokittelupäätöksiin liittyy erilaiset riskit, esim. "Onko palohälytys oikea vai pelkkä testi?"
- Liitetään kaikkiin luokittelutapahtumiin ( $\mathbf{x} \in R_i$ , oikea luokka  $\omega_k$ ) kustannuskertoimet  $\lambda_{ki}$ , jotka voidaan koota matriisiksi  $L(k, i) = \lambda_{ki}$
- Luokkaan  $\omega_k$  liittyvä riski:

$$r_k = \sum_{i=1}^M \lambda_{ki} \int_{R_i} p(\mathbf{x}|\omega_k) d\mathbf{x}, \quad (11)$$

missä  $M$  on luokkien lukumäärä



- Kuinka valita piirreavaruuden jako siten, että riskin odotusarvo  $r$  minimoituu?

$$\begin{aligned}
 r &= \sum_{k=1}^M r_k P(\omega_k) \\
 &= \sum_{i=1}^M \int_{R_i} \left( \sum_{k=1}^M \lambda_{ki} p(\mathbf{x}|\omega_k) P(\omega_k) \right) d\mathbf{x}
 \end{aligned} \tag{12}$$

- $r$  minimoituu seuraavalla jaolla:

$$\begin{aligned}
 \mathbf{x} &\in R_i, \text{ jos } l_i < l_j \quad \forall j \neq i \\
 l_m &= \sum_{k=1}^M \lambda_{km} p(\mathbf{x}|\omega_k) P(\omega_k)
 \end{aligned} \tag{13}$$

- Huom! Jos valitaan  $\lambda_{ki} = 1 - \delta_{ki}$  ( $\delta_{ki}$  on Kroneckerin delta-funktio), minimoidaan luokitteluvirhetn:ttä

- Kahden luokan tapaus:

- Eri päätöksiin liittyvät kustannusten odotusarvot:

$$\begin{aligned}l_1 &= \lambda_{11}p(\mathbf{x}|\omega_1)P(\omega_1) + \lambda_{21}p(\mathbf{x}|\omega_2)P(\omega_2) \\l_2 &= \lambda_{12}p(\mathbf{x}|\omega_1)P(\omega_1) + \lambda_{22}p(\mathbf{x}|\omega_2)P(\omega_2)\end{aligned}\tag{14}$$

- Valitaan luokka  $\omega_1$ , kun  $l_1 < l_2$ :

$$(\lambda_{21} - \lambda_{22})p(\mathbf{x}|\omega_2)P(\omega_2) < (\lambda_{12} - \lambda_{11})p(\mathbf{x}|\omega_1)P(\omega_1)\tag{15}$$

- Yleensä  $\lambda_{ij} \geq \lambda_{ii}$ . Silloin:

$$\begin{aligned}R_1 &: \frac{p(\mathbf{x}|\omega_1)}{p(\mathbf{x}|\omega_2)} > \frac{P(\omega_2)}{P(\omega_1)} \frac{\lambda_{21} - \lambda_{22}}{\lambda_{12} - \lambda_{11}} \\R_2 &: \frac{p(\mathbf{x}|\omega_1)}{p(\mathbf{x}|\omega_2)} < \frac{P(\omega_2)}{P(\omega_1)} \frac{\lambda_{21} - \lambda_{22}}{\lambda_{12} - \lambda_{11}}\end{aligned}\tag{16}$$

(*a posteriori* tnjakaumien suhde on ns. “likelihood ratio”)

- **Esimerkki 1:**

- Tarkastellaan kahden luokan,  $\omega_1$  ja  $\omega_2$ , ongelmaa ja oletetaan, että  $p(x|\omega_1) \sim N(0, 1/2)$  ja  $p(x|\omega_2) \sim N(1, 1/2)$  eli

$$p(x|\omega_1) = \frac{1}{\sqrt{\pi}} \exp(-x^2)$$

$$p(x|\omega_2) = \frac{1}{\sqrt{\pi}} \exp(-(x - 1)^2)$$

ja että luokkien *a priori* tn:t  $P(\omega_1)$  ja  $P(\omega_2)$  ovat samat

- Silloin luokitteluvirhetn:n minimoiva päätösraja on  $x_0 : \exp(-x^2) = \exp(-(x - 1)^2)$  eli  $x_0 = 1/2$  (katso kaava (10))

- Kun käytetään seuraava kustannusmatriisia  $L$ :

$$L = \begin{bmatrix} 0 & 0.5 \\ 1.0 & 0 \end{bmatrix},$$

$x_0$ :  $\exp(-x^2) = 2 \exp(-(x-1)^2)$  eli  $x_0 = (1 - \ln(2))/2 < 1/2$   
(katso kaava (15))

- Huom! Jos luokkien *a priori* tn:t eivät ole samat,  $P(\omega_1) \leq P(\omega_2)$ , siirtyy päätösraja myöskin vasemmalle tai oikealle

- **Esimerkki 2:**

- Palohälytyksen luokittelu eli juostaanko ulos (tulipalo) vai jäädäänkö sisälle ihmettelemään (väärä hälytys)?
- Olkoot  $\omega_1 =$  “tulipalo”,  $\omega_2 =$  “väärä hälytys”
- Oletetaan *a priori* tn:n sille että talossa on tulipalo olevan 1 päivä 10:ssä vuodessa eli  $P(\omega_1) = 1/3650$  ja  $P(\omega_2) = 3649/3650$

- Piirrevektori  $\mathbf{x}$  koostuu esim. seuraavista havainnoista: kuinka iso osa muista ihmisistä säntää ulos, kuinka sakeaa on savu, näkykö liekkejä jne
- $p(\mathbf{x}|\omega_1)$  ja  $p(\mathbf{x}|\omega_2)$  arvioidaan aikaisempien kokemusten pohjalta
- Liitetään eri luokittelupäätöksiin seuraavat ajassa mitatut kustannukset:  $\lambda_{11}$  = "kymmenen vuoden tulot ja 1 tunti pihalla",  $\lambda_{12}$  = "kymmenen vuoden tulot ja 60 vuotta loppuelämästä",  $\lambda_{21}$  = "1 tunti pihalla",  $\lambda_{22} = 0$
- Kaavan (15) perusteella riskin odotusarvo minimoituu, kun päätös tehdään seuraavasti:

$$\text{tulipalo : } \frac{p(\mathbf{x}|\omega_1)}{p(\mathbf{x}|\omega_2)} > \frac{3649}{525599} \approx 0.007$$

väärä hälytys : muulloin

eli pelkkien havaintojen perusteella pitää olla reilusti yli 100-kertainen luottamus siihen ettei ole tulipaloa, jos aikoo jäädä sisälle

## 1.3 Diskriminanttifunktiot ja päätöspinnat

- Edellisten tarkastelujen pohjalta tiedetään, että kun luokittelu perustuu joko luokitteluvirheen tai riskin odotusarvon minimointiin, piirreavaruus jaetaan  $M$ :ään **päätösalueeseen**  $R_1, \dots, R_M$ , kun luokkia on  $M$  kappaletta
- Mikäli luokkia  $\omega_i$  ja  $\omega_j$  vastaavat, luokitteluvirheen tn:n minimoivat päätösalueet ovat  $R_i$  ja  $R_j$ , määritellään **päätöspinta** (decision boundary, decision surface) seuraavasti:

$$P(\omega_i|\mathbf{x}) - P(\omega_j|\mathbf{x}) = 0 \quad (17)$$

Toisella puolella päätöspintaa erotus on positiivinen ja toisella negatiivinen

- Toisinaan on laskennallisesti kätevää esittää päätöspinnan yhtälö **diskriminanttifunktioiden**  $g_i(\mathbf{x}) = f(P(\omega_i|\mathbf{x}))$  avulla.  $f(\cdot)$  voi olla mikä tahansa monotonisesti kasvava, jatkuva funktio

- Tällöin minivirhetn:n tuottama päätössääntö (10) saa seuraavan muodon:

$$R_i : g_i(\mathbf{x}) > g_j(\mathbf{x}) \quad \forall j \neq i \quad (18)$$

ja päätöspinnat on määritelty seuraavasti:

$$g_{ij}(\mathbf{x}) = g_i(\mathbf{x}) - g_j(\mathbf{x}) = 0 \quad (19)$$