


- * Menetelmän merkittävä ongelma: jos jokin tapahtuma ei ole havaittu laisinkaan (pienessä havaintoaineistossa), niin h_{ML} antaa sille nolla-t:n:
- * Muutetaan esim. siten, että riippuen karkin mausta se kääritään probabilistisen säännön perusteella joko punaiseen tai vihreään paperiin



356

- * Nyt tn mallissa on kolme parametria $\theta_1, \theta_1, \theta_2$
- * Bayes-verkon standardisemantikan perusteella voidaan laskea tapahtumien tn:itä; esim.

$$\begin{aligned}
 P(M = s, K = v | h_{\theta_1, \theta_2}) &= P(M = s | h_{\theta_1, \theta_2}) \cdot \\
 P(K = v | M = s, h_{\theta_1, \theta_2}) &= \theta \cdot (1 - \theta_1)
 \end{aligned}$$

- * Avaamme nyt n makeista, joista s on salmiakkia ja h hedelmää, joiden käärepaperien värien lkm:t ovat p_s, v_s, p_h ja v_h
- * Tämän aineiston uskottavuus $P(\vec{d} | h_{\theta_1, \theta_2})$ on $\theta^s (1 - \theta)^h \theta_1^{p_s} (1 - \theta_1)^{v_s} \theta_2^{p_h} (1 - \theta_2)^{v_h}$

357

- * Oletetaan logaritmi edellisestä:

$$\begin{aligned}
 L &= [s \log \theta + h \log(1 - \theta)] \\
 &+ [p_s \log \theta_1 + v_s \log(1 - \theta_1)] \\
 &+ [p_h \log \theta_2 + v_h \log(1 - \theta_2)]
 \end{aligned}$$

- * Parametrien suhteen derivoimalla ja hakemalla nolllakohta saadaan

$$\begin{aligned}
 \frac{\partial L}{\partial \theta} = \frac{s}{\theta} - \frac{h}{1 - \theta} = 0 &\Rightarrow \theta = \frac{s}{s + h} \\
 \frac{\partial L}{\partial \theta_1} = \frac{p_s}{\theta_1} - \frac{v_s}{1 - \theta_1} = 0 &\Rightarrow \theta_1 = \frac{p_s}{p_s + v_s} \\
 \frac{\partial L}{\partial \theta_2} = \frac{p_h}{\theta_2} - \frac{v_h}{1 - \theta_2} = 0 &\Rightarrow \theta_2 = \frac{p_h}{p_h + v_h}
 \end{aligned}$$

- * θ :n arvo on kuten ennenkin ja θ_1, θ_2 :n arvo on punaisen käärepaperin osuus salmiakkikarkkien joukossa (θ_2 vast.)
- * Näin oppimisongelma jakaantuu erillisiksi oppimistehtäviksi kullekin parametrille

358

Naiivi Bayes

- * Luokkamuuttuja C on Bayes-verkon juuri ja attribuutit X_i ovat sen lehtiä
- * Naiivi oletus on, että attribuutit ovat ehdollisesti riippumattomia toisistaan annettuna luokka
- * Kun käytössä on Boolean muuttujat, niin parametrit ovat

$$\begin{aligned}
 \theta &= P(C = \text{true}) \\
 \theta_{x_1} &= P(X_1 = \text{true} | C = \text{true}) \\
 \theta_{x_2} &= P(X_2 = \text{true} | C = \text{false})
 \end{aligned}$$

- * Näiden arvot löydetään kuten edellä
- * Kun verkko on opetettu, niin havainto $\langle x_1, \dots, x_n \rangle$, jonka luokkamuuttujan C arvo on tuntematon, voidaan luokitella $\bar{P}(C | x_1, \dots, x_n) = \alpha \bar{P}(C) \prod_i \bar{P}(x_i | C)$

359

Jatkuvaa-arvoiset muuttujat

- * Tarkastellaan yhden muuttujan Gaussisen tiheydfn:n parametrien oppimista
- * Aineiston siis tuottaa

$$P(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right)$$

- * Mallin parametrit ovat keskiarvo μ ja hajonta σ
- * Olk. havaitut arvot x_1, \dots, x_n , nyt uskottavuuden logaritmi on

$$\begin{aligned}
 L &= \sum_{j=1}^n \log \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x_j - \mu)^2}{2\sigma^2}\right) \\
 &= n(-\log \sqrt{2\pi} - \log \sigma) - \sum_{j=1}^n \frac{(x_j - \mu)^2}{2\sigma^2}
 \end{aligned}$$

360

- * Osittaisderivaattojen nolllakohdat:


$$\begin{aligned}
 \frac{\partial L}{\partial \mu} &= -\frac{1}{\sigma} \sum_{j=1}^n (x_j - \mu) = 0 \\
 &\Rightarrow \mu = \frac{\sum_{j=1}^n x_j}{n} \\
 \frac{\partial L}{\partial \sigma} &= -\frac{n}{\sigma} + \frac{1}{\sigma^3} \sum_{j=1}^n (x_j - \mu)^2 = 0 \\
 &\Rightarrow \sigma = \sqrt{\frac{\sum_{j=1}^n (x_j - \mu)^2}{n}}
 \end{aligned}$$

- * Siis keskiarvon maksimaalisen uskottavuuden arvo on havaintojen keskiarvo ja hajonnan vastaava arvo on varianssin neliöjuuri
- * Jälleen saatiin siis intuitiivisesti oikeat arvot

361

EM-algoritmi

- * Havainnot eivät käytännössä ole täydellisiä, kuten edellä oletettiin
- * Sen sijaan on olemassa piilomuuttujia l , *latentteja muuttujia*, joiden arvoja ei ole mukana havainnoissa
- * Latentin muuttujan ottaminen mukaan Bayes-verkkoon voi vähentää tarvittavien parametrien lkm:tä oleellisesti ja siten helpottaa verkon oppimista



362

- * Kun edellisessä esimerkissä kullakin muuttujalla on 3 mahdoll. arvoa ovat Bayes-verkkojen parametrien lkm:t 78 ja 708
- * Piilomuuttujat kuitenkin hankaloittavat oppimisongelmaa
- * Kuinka esim. oppia solmun *Sydän-sirtaus* ehdolliset tn:t annettuna sen vanhemmat, koska muuttujan arvoa ei voida havainnoida?
- * Sama ongelma koskee oikeiden tn:ikaunien oppimista
- * EM-algoritmi (expectation-maximization) on yleinen algoritmi tämän ongelman ratkaisemiseksi

363

Ohjattamaton klusterointi


- * Tapaukset, joita saamme nähtäväksemme, ovat luokittelemattomia
- * Sitä huolimatta usein voidaan tunnistaa tapausluokkia
- * Peruslähdekohalta luokittelemalle on, että havaintoaineiston on tuottanut *sekoitajakautta* P (mixture distr.), jossa on osana k jakautmaa
- * Tapauksen generoimiseksi ensin valitaan komponenttajakautta ja sitten arvotaan satunnainen otos valitun jakauman mukaan
- * Olk. C valittua komponenttia vastaava satunnaisuuttuja, jonka mahdolliset arvot ovat $1, \dots, k$

364

- * Sekoitejakautta on

$$P(\vec{x}) = \sum_{i=1}^k P(C=i)P(\vec{x} | C=i),$$
 missä \vec{x} on tapauksen attribuuttiarvot
- * Jatkuvavarjoiselle datalle luonteva valinta komponenttajakautaksi on monimuuttujainen (multivariate) normaalijakautta
- * Sekoitejakautta on siis *mixture of Gaussians*, jonka Parametrit ovat
 - ◊ Komponenttijaakauttien painot $w_i = P(C=i)$ sekä
 - ◊ kunkin komponentin keskiarvo μ_i ja kovarianssi Σ_i
- * Tehtävänä on löytää aineiston perusteella sekoitemalli, joka olisi voinut tuottaa havaintoaineiston

365



366

- * Jos tietäisimme mikä komponenttijaakautista tuotti minkäkin pisteen, voisimme noudattaa normaalia Gaussin jakauman oppimista
- * Jos toisaalta tietäisimme komponenttijaakautien parametrit, niin pisteen (probabilistinen) jakaminen komponentteihin olisi helppoa
- * Kumpakaan ei kuitenkaan tunneta
- * EM-algoritmi toimii kuin tuntisimme mallin parametrien arvot ja sen perusteella lasketaan tn.:t kaikille pisteille kaikkiin komponentteihin kuuluneelle
- * Sen jälkeen kukin komponentti sovitaan uudelleen koko aineistoon, pisteet painotettuna ko. komponenttiin kuuluneen tn.:llä

367

- * Edellä mainittuja askelita toistetaan kunnes menetelmä konvergoituu
- * Menetelmä täydentää aineistoa päätellen piilomuuttujien jakaumia nykyisen mallin perusteella
- * Piilomuuttajia tässä tapauksessa ovat pisteiden kuuluneista komponenttijaakauttiin indikoivat binääriset satunnaisuuttujat Z_{ij} :

$$Z_{ij} = \begin{cases} 1 & \text{jos } \vec{x}_j \text{ on tuottanut } i\text{:s komponenttijaakautta} \\ 0 & \text{muuten} \end{cases}$$

- * Sekoitemallin parametrit alustetaan satunnaisesti ja sen jälkeen toistetaan seuraavia askelita

368

1. **E-askel:** Laske todennäköisyydet, että havainnon \vec{x}_j on tuottanut komponenttijaakautta $i, p_{ij} = P(C=i | \vec{x}_j)$
 - * Bayesin kaavan perusteella $p_{ij} = \alpha P(\vec{x}_j | C=i)P(C=i)$
 - * Tekijä $P(\vec{x}_j | C=i)$ on i :nnen Gaussin jakauman tn. pisteessä \vec{x}_j
 - * $P(C=i)$ on i :nnen jakauman painoparametrin arvo
 - * Olk. $p_i = \sum_j p_{ij}$
2. **M-askel:** Päivitä mallin parametrit:

$$\begin{aligned} \mu_i &\leftarrow \sum_j p_{ij} \vec{x}_j / p_i \\ \Sigma_i &\leftarrow \sum_j p_{ij} \vec{x}_j \vec{x}_j^T / p_i \\ w_i &\leftarrow p_i \end{aligned}$$

369

- * E-askel laskee piilomuuttujien Z_{ij} odotusarvot p_{ij}
- * M-askel puolestaan hakee mallin parametreille uudet arvot, jotka maksimoivat aineiston log-uskottavuuden annettuna odotusarvot p_{ij}
- * EM-algoritmi parantaa aineiston log-uskottavuutta joksella iteraatiolla
- * Joissain tapauksissa EM:n voidaan todistaa saavuttavan uskottavuuden lokaali maksimi (huom. ilman askelkokoa)
- * Ongelmailanteita:
 - ◊ Komponenttijaakautta supistuu kattamaan vain yhden havainnon, varianssi $= 0 \Rightarrow$ uskottavuus $= \infty$
 - ◊ Kaksi komponenttia kattavat samat pisteet (niillä on samat keskiarvot ja varianssit)
- * Bayes-verkossa piilomuuttujat ovatkin havaisematomien muuttujien arvot kullakin esimerkillä
- * Pilo-Markov-mallissa (hiddeden Markov model, HMM) piilomuuttujat ovat tilasitrymän.:t
- * EM-algoritmita saadaan eri instanssinaatioita erilaisiin malleihin
- * Yleisimmässä muodossaan algoritmi tyypistyy päivityssäännöksi $\vec{\theta}^{(t+1)} = \arg \max_{\vec{\theta}} \sum_{\vec{z}} P(\vec{Z} = \vec{z} | \vec{x}, \vec{\theta}^{(t)}) L(\vec{x}, \vec{Z} = \vec{z} | \vec{\theta})$,
 - \vec{x} on kaikki havaitut arvot,
 - \vec{Z} on kaikki piilomuuttujat
 - $\vec{\theta}$ on kaikki parametrit
- * Summaus vastaa E-askelta ja maksimointi M-askelta

371

Tukivektorikoneet

- * Annettuna *esimerkkeisii* koostuva *opetusaineisto S* tarkoituksena on oppia *luokitteija* positiivisten ja negatiivisten tapausien erotteluniseksi toisistaan
- * Esimerkki muodostuu tapauksesta $\vec{x} \in \mathcal{X}$ ja siihen liittyvästä luokasta $y \in \{-1, 1\}$
- * Ennalta kiinnitetty luokitteijoiden joukko \mathcal{H} , josta luokitteija h valitaan
- * Tarkoitus ei ole luokitella vain S :n alkioita oikein, vaan tavoite on oppia yleisemmän (saman todennäköisyysjakauman) tapausien luokittelu

372

Lineaariset koneet

- * Lineaariset koneet kuten Rosenblattin [1958] Perceptron ovat käsitteellisesti yksinkertaisia
- * Lineaarisesti separoituvalla aineistojle Perceptronin voidaan todistaa konvergoivan äärellisellä iteraatioiden lukumäärällä [Novikoff 1962]
- * Myöhemmin yksinkertaisia kynnysy-syksiköitä on keksitty yhdistää neuraverkkoon, jolloin muodostuu huomattavasti ilmaisuvoimaisempia luokitteilioita
- * Neuraaliverkon opettamiseen ja oppimiseen liittyvät laskennalliset kysymykset ovat vaikeita

374

Duaalisitus

- * Kun lähdemme liikkelle nollavektorista, niin lopullinen hypoteesi on opetusesimerkkien lineaarikombinaatio:


$$\vec{w} = \sum_{i=1}^n \alpha_i y_i \vec{x}_i$$

- * Myös hypoteesin luokittelu voidaan kirjoittaa *duaalkoordinaatistossa*:

$$\begin{aligned} h(\vec{x}) &= \text{sgn}(\langle \vec{w}, \vec{x} \rangle + b) \\ &= \text{sgn} \left(\sum_{i=1}^n \alpha_i y_i \langle \vec{x}_i, \vec{x} \rangle + b \right) \end{aligned}$$

378

Kuvataan tapaukset epälineaarisesti (monilotteiseen) piirreavaruuteen



Kuvaus piirreavaruuteen

Lineaariset luokitteijat

- * $f(\vec{x})$ on argumenttinsa lineaarinen funktio

$$f(\vec{x}) = \langle \vec{w}, \vec{x} \rangle + b = \sum_{i=1}^m w_i x_i + b$$

- * Syöte $\vec{x} = (x_1, \dots, x_m)$ luokitellaan positiiviseksi, jos $f(\vec{x}) \geq 0$ ja muuten \vec{x} luokitellaan negatiiviseksi

$$\text{sgn}(f(\vec{x})) = \begin{cases} 1, & f(\vec{x}) \geq 0 \\ -1, & \text{muuten} \end{cases}$$


- * Yhtiön $\langle \vec{w}, \vec{x} \rangle + b = 0$ määräämä hypertaso jakaa syöteavaruuden kahteen puoliavaruuteen

373

Lineaarien

luokitteijoiden rajoitteet:

XOR-funktio



Ei ole olemassa lineaarista luokitteijaa, joka erottaisi mustat ja valkoiset pisteet toisistaan

375

Piirrekuvaus

- * Opetusaineisto voidaan esittää alkuperäisten muuttujien sijaan niistä johdettuna *piirteinä*

$$\vec{x} = (x_1, \dots, x_m) \mapsto (\phi_1(\vec{x}), \dots, \phi_M(\vec{x}))$$

- * Piirreavaruus on

$$\mathcal{F} = \{ \vec{\phi}(\vec{x}) \mid \vec{x} \in \mathcal{X} \}$$

- * Useiden — jopa redundanttien — piirteiden käyttäminen helpottaa opittavan käsitteen esittämistä
- * Moniulotteinen piirreavaruus \Rightarrow laskennallinen raskaus

377

Ydinfunktiot

- * Aineistoon sovelletaan kiinteää epälineaarista muunnosta piirreavaruuteen, jossa lineaarista luokitteijaa käytetään

$$f(\vec{x}) = \sum_{i=1}^M w_i \phi_i(\vec{x}) + b$$

- * Duaalimuodossa esitetyssä lineaarisessa luokitteijassa lasketaan opetusesimerkkien ja luokiteltavan tapauksen sisätulo

$$f(\vec{x}) = \sum_{i=1}^n \alpha_i y_i \langle \phi(\vec{x}_i), \phi(\vec{x}) \rangle + b$$

379

- * Jos piirrevaruuden sisältö

$$\langle \phi(\vec{x}_i) \cdot \phi(\vec{x}_i) \rangle$$

voidaan laskea alkuperäisestä aineistosta, ei eksplisiittistä muunnosta piirrevaruuteen tarvittaisi lainkaan

- * *Ydinfunktiolle* K pätee kaikilla $\vec{x}_i, \vec{z} \in \mathcal{X}$

$$K(\vec{x}_i, \vec{z}) = \langle \phi(\vec{x}_i) \cdot \phi(\vec{z}) \rangle,$$

$$\text{missä } \phi : \mathcal{X} \rightarrow \mathcal{F}$$

- * Yksinkertaisin ydinfunktio on identtinen kuvaus $K(\vec{x}_i, \vec{z}) = (\vec{x}_i \cdot \vec{z})$

- * Epälineaarista kuvauksia puolestaan ovat esim. polynomiset ytimet

$$K(\vec{x}_i, \vec{z}) = ((\vec{x}_i \cdot \vec{z}) + c)^d$$

380

Marginaalit

- * Esimerkin $(\vec{x}_i, y_i) \in \mathcal{X} \times \{-1, 1\}$ marginaali funktion $h \in \mathcal{H}$ suhteen on

$$\gamma_i = y_i h(\vec{x}_i)$$

- * Jos $\gamma_i > 0$, niin (\vec{x}_i, y_i) on luokiteltu oikein

- * Funktion h marginaali aineiston S suhteen on

$$m_S(h) = \min_{(\vec{x}_i, y_i) \in S} \gamma_i$$

- * Geometrisen marginaali on normalisoidun luokittelijan marginaali $\gamma = 1 / \|\vec{w}\|_2$

382

384

toteuttaa maksimaalisen marginaalin hypertason geometrisella marginaalilla $1 / \|\vec{w}^*\|_2$

$$\vec{w}^* = \sum_{i=1}^n y_i \alpha_i^* \vec{x}_i$$

- * Olkoon $S = ((\vec{x}_1, y_1), \dots, (\vec{x}_n, y_n))$ lineaarisesti separoituva aineisto ja α^* kvadraattisen optimointiongelman maksimoi $W(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n y_i y_j \alpha_i \alpha_j \langle \vec{x}_i, \vec{x}_j \rangle$ ehdolla $\sum_{i=1}^n y_i \alpha_i = 0$ ja $\alpha_i \geq 0, i = 1, \dots, n$ ratkaisevat parametrit. Tällöin painovektori

386

määräämä päätösfunktio $\text{sgn}(f(\vec{x}))$ on ekvivalentti \mathcal{F} :n maksimaalisen marginaalin hypertason kanssa. Sen geometrisen marginaali on $\gamma = (\sum_{i \in \text{sv}} \alpha_i^*)^{-1/2}$

$$f(\vec{x}) = \sum_{i=1}^n y_i \alpha_i^* K(\vec{x}_i, \vec{x}) + b^*$$

- ratkaisevat parametrit. Tällöin funktion ehdolla $\sum_{i=1}^n y_i \alpha_i = 0$ ja $\alpha_i \geq 0, i = 1, \dots, n$ maksimoi $W(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n y_i y_j \alpha_i \alpha_j K(\vec{x}_i, \vec{x}_j)$ optimointiongelman piirrevaruudessa \mathcal{F} ja α^* sekä b^* kvadraattisen optimointiongelman $K(\vec{x}_i, \vec{z})$ implisiittisesti määräämässä Olkoon $S = ((\vec{x}_1, y_1), \dots, (\vec{x}_n, y_n))$ lineaarisesti separoi-

- * Ydinfunktiota käytettäessä duaalin muodon luokitteilu saadaan muotoon

$$f(x) = \sum_{i=1}^n \alpha_i y_i K(\vec{x}_i, \vec{x}) + b$$

- * Tässä esityksessä ei käytetä piirrevaruuden dimensionaalisuutta, joten on mahdollista käyttää suurta piirteiden lukumäärää

- * Myöskään epälineaarinen muunnos ϕ ei enää ole eksplisiittisesti näkyvissä

381

- * Olkoon $S = ((\vec{x}_1, y_1), \dots, (\vec{x}_n, y_n))$ lineaarisesti separoituva aineisto. Hypertaso (\vec{w}, b) , joka ratkaisee optimointiongelman

$$\min_{\vec{w}, b} \langle \vec{w}, \vec{w} \rangle$$

$$\text{ehdolla } y_i (\langle \vec{w}, \vec{x}_i \rangle + b) \geq 1, i = 1, \dots, n$$

toteuttaa maksimaalisen marginaalin hypertason geometrisella marginaalilla $1 / \|\vec{w}\|_2$

- * Primaalisen optimointiongelman duaaliformulointi antaa seuraavan tuloksen

383

- * Optimaalinen hypertaso voidaan ilmaista nyt muodossa

$$f(\vec{z}, \alpha^*, b^*) = \sum_{i \in \text{sv}} y_i \alpha_i^* (\vec{z}_i \cdot \vec{z}) + b^*$$

- * Ns. Karush-Kuhn-Tucker -lisäehtojen seurauksena vain niillä syötteillä \vec{x}_i , jotka ovat lähinnä hypertasoa, voi olla $\alpha_i^* > 0$
- * Kaikilla muilla i on oltava $\alpha_i^* = 0$
- * Painovektorin lausekkeessa $\vec{w}^* = \sum_{i=1}^n y_i \alpha_i^* \vec{x}_i$ riittää ottaa huomioon ne \vec{x}_i :t, joilla $\alpha_i^* \neq 0$
- * Näitä pisteitä kutsutaan *tuikivektoreiksi*, merk. sv:llä kaikkien tukivektoreiden joukkoa

- * Optimaalinen hypertaso voidaan ilmaista nyt muodossa

385

- * Ydinfunktion on toteutettava ns. Mercer-ehdot, joista seuraa, että optimointiongelma on konvekssi
- * Näin ollen maksimaalisen marginaalin optimointiongelma on yksikäsitteinen ratkaisu, joka voidaan löytää tehokkaasti
- * Lokaalien minimien ongelmaa ei esiinny
- * Piirrevaruuden määrääminen tekee optimointiongelmansta "helpon"

387

Yhteenveto

- * Tekoäly on todella laaja tutkimuskenttä, myös metodologisesti
- * Merkitävää kehitystä tutkimuksessa tapahtuu päivittäin
- * Probabilistinen lähestyminen on ajanut ohii loogisen suuntauksen
- * Näytätviä demonstraatioita menetelmien mahdollisuuksista saadaan kiihtyvällä tahdilla
- * Myös vähemmälle julkisuudelle jäivät arkisovellukset lisääntyvät
- * Fyysisen agentin interaktio toimintaympäristönsä sekä ihmisten kanssa kaipaa vielä edistysaskelta