

Datasta Tietoon, laskuharjoitusmateriaali, syksy 2011

Sisältö:

1. Esitietotehtäviä, s. 2
2. Paperiharjoituksset 1-5, s. 10
3. Bonuspistetehtävät 1-5 (siltä erää kun valmiita), s. 42
4. Tietokoneharjoituksset 1-5, s. 43
5. Matlab-komentoja, s. 46
6. Kaavakokoelma, s. 47

Notaatioita:

- datanäytteet tai havainnot, otos \mathbf{X} , joka sisältää n kappaletta d -ulotteisia datapisteitä. Kun $d = 1$, niin tyypillisesti yksi datapiste merkitään x , ja kun taas $d > 1$ niin \mathbf{x} . Datamatriisi \mathbf{X} kirjoitetaan niin, että eri piirteet tulevat riveiksi ja havainnot sarakkeiksi

$$\mathbf{X} = [\mathbf{x}(1) \quad \mathbf{x}(2) \quad \dots \quad \mathbf{x}(n)] = \begin{bmatrix} x_1(1) & x_1(2) & \dots & x_1(n) \\ x_2(1) & x_2(2) & \dots & x_2(n) \\ \vdots & \vdots & \ddots & \vdots \\ x_d(1) & x_d(2) & \dots & x_d(n) \end{bmatrix} = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ x_{d1} & x_{d2} & \dots & x_{dn} \end{bmatrix}$$

Esimerkki. Mitataan pituus ja paino Kallelta ja Villettä. Kallen pituus 180 cm ja paino 73 kg, Villen vastaavasti 174 ja 65. Tällöin $\mathbf{x}(1) = [180 \ 73]^T$ ja $\mathbf{x}(2) = [174 \ 65]^T$ ja matriisina

$$\mathbf{X} = \begin{bmatrix} 180 & 174 \\ 73 & 65 \end{bmatrix}$$

Jos sinulla ei ole kotikoneella Matlabia, niin lataa ja asenna GNU Octave (Matlab-kloonii, octave.org). Suurin osa Matlab-komennoista toimii sellaisenaan Octavessa. Tarjolla Windows-, Mac- ja Linux-ympäristöihin. Asennuksen voi tehdä helposti lisäpaketin (Octave-Forge, ei luultavasti tarvita tällä kurssilla) kanssa osoitteesta <http://octave.sourceforge.net>, ja tälle halutessasi vielä graafinen käyttöliittymä (Windows) <http://www.guioctave.com>. Katso lisätietoa kurssin Noppa-sivulta.

Kommentit ja korjaukset t612010@ics.tkk.fi.

Datasta Tietoon, syksy 2011, esitietotehtäviä

E1. Kombinatoriikkaa ja potensseja. Muista joitakin laskusääntöjä

$$\begin{aligned}x^0 &= 1 \\x^{B+C} &= x^B \cdot x^C \\x^{-B} &= 1/x^B \\(x^B)^C &= x^{B \cdot C}\end{aligned}$$

Huomaa vielä, että $2^{10} = 1024 \approx 10^3$ (k), $2^{20} = 2^{10} \cdot 2^{10} = 1048576 \approx 10^6$ (M), $2^{30} = 2^{10} \cdot 2^{10} \cdot 2^{10} \approx 10^9$ (G), jne.

- a) Jokeriarvonnassa arvotaan seitsemän numeroa, joista jokainen voi saada arvon 0, ..., 9. Kuinka monta vaihtoehtoa on olemassa?
- b) Tarinan “Shakkilaudan joka ruudulla riisinjyvien lukumäärä kaksinkertaistuu” perusteella esitä luvulle $2^{64} = 2^4 \cdot 2^{60}$ suuruusluokka 10-kantaisessa järjestelmässä.
- c) Tutkitaan “DataMatrix” / “UpCode”-tyyppistä 2-ulotteista bittikarttaa, jossa kuvan koko on 2×2 kuvapisteitä ($2 \times 2 = 4$ pikseliä) ja kukin pikseli on joko musta (0) tai valkeaa (1). Kuinka monta erilaista esitystä saadaan? Voit myös piirtää?
- d) Tutkitaan “thumbnail”-valokuvaa, jonka koko on $19 \times 19 = 361$ pikseliä, ja jokainen pikseli on esitetynä harmaasävyarvolla 8 bitillä. Vaihtoehtoja yhdelle pikselille on tällöin $2^8 = 256$, jolloin 0 vastaa mustaa ja 255 valkeaa. Kuinka monta erilaista kuva voidaan esittää?

Huomaa, että d-kohdassa $19 \cdot 19 \cdot 256 = 92416$ on väärä vastaus. Tulos on suurempi. Reilusti suurempi.

Matlabissa ja Octavessa

```
2^64
log(8)
log2(8)
log10(8)
exp(1)
```



E2. Lasketaan tässä tehtävässä logaritmeja. Muutamia logaritmien laskusääntöjä ja -esimerkkejä ovat

$$\begin{aligned}\log_A B = C &\Leftrightarrow A^C = B \\ \log(A \cdot B) &= \log(A) + \log(B) \\ \log(A/B) &= \log(A) - \log(B) \\ A \cdot \log(B^C) &= A \cdot C \cdot \log(B) \\ \log_A B &= \log_C B / \log_C A \\ \log_A A^B &= B \log_A A = B\end{aligned}$$

Logaritmeissa käytetään erilaisia kantalukuja, joista tyypillisimmat ovat 2, e ("luonnollinen logaritmi") ja 10. Esimerkki:

$$\log_2\left(\frac{1}{\sqrt{2}} \cdot 4^4\right) = \log_2(1) - \log_2((2)^{1/2}) + 4 \log_2 4 = 0 - 0.5 + 8 = 7.5$$

Joskus on kivaa esittää jotkut luvut 2-kantaisina tai 10-kantaisina. Esimerkiksi 7^5 :

$$\begin{aligned}7^5 &= 10^x \quad | \log_{10} \\ 5 \cdot \log_{10} 7 &= x \\ x &\approx 4.23 \\ 10^{0.23} \cdot 10^4 &\approx 1.7 \cdot 10^4 = 17000\end{aligned}$$

Taskulaskimissa usein "ln" viittaa luonnolliseen logaritmiin, kirjallisuudessa ln tai \log_e tai log, ja taskulaskimen "log" viittaa usein 10-kantaiseen logaritmiin, log tai \log_{10} . Useissa "kaavojen johtamisissa" ei ole väliä, minkä kantainen logaritmi on.

Laske taskulaskimella

- a) $S = 0.0012 \cdot 0.00046 \cdot 0.00043$.
- b) $T = 0.000073 \cdot 0.0000026 \cdot 0.0000343$.
- c) Laske $\log(S)$ ja $\log(T)$. Varmista myös, että $\log(S) = \log(0.0012) + \log(0.00046) + \log(0.00043)$.
- d) Muunna edellisen tehtävän 19×19 -kokoisten valokuvien lukumäärä 10-kantaiseksi.

Kuten c-kohdasta huomaa, joskus joutuu "arvaamaan" sopivan kannan. Huomaa myös, että koska $S > T$, niin myös $\log(S) > \log(T)$.

Matlabissa ja Octavessa `log2(4)`, `log(exp(1))`, `log10(1000)`.

- E3. Skalaareja, vektoreita ja matriiseja. Tällä kurssilla skaalari (yksi muuttuja) vaikkapa pituus $x = 186$. Vektoriin voidaan tallettaa useita muuttujia, esimerkiksi pituus ja paino: $\mathbf{x} = [186 \ 83]^T$, jossa vaakavektori transponoituu pystyvektoriksi. Viidestä havainnosta (viiden ihmisen pituus ja paino) saadaan sitten 2×5 -matriisi (2 riviä, 5 saraketta)

$$\mathbf{X} = [\mathbf{x}(1) \ \mathbf{x}(2) \ \mathbf{x}(3) \ \mathbf{x}(4) \ \mathbf{x}(5)] = \begin{bmatrix} 186 & 163 & 171 & 1.74 & 190 \\ 83 & 55 & 68 & 80 & 89 \end{bmatrix}$$

Matriisikertolaskussa pitää muistaa, että "dimensiot täsmää". Esimerkkejä matriisien kertolaskusta, vakiolla kertominen:

$$4 \cdot \begin{bmatrix} 186 & 163 & 171 & 1.74 & 190 \\ 83 & 55 & 68 & 80 & 89 \end{bmatrix} = \begin{bmatrix} 744 & 732 & 684 & 6.96 & 760 \\ 332 & 220 & 272 & 320 & 356 \end{bmatrix}$$

matriisilasku $\mathbf{X}^T \mathbf{b}$, jossa $\mathbf{b} = [0.8 \ 0.2]^T$ ("painotettu keskiarvo")

$$\begin{bmatrix} 186 & 83 \\ 163 & 55 \\ 171 & 68 \\ 1.74 & 80 \\ 190 & 89 \end{bmatrix} \cdot \begin{bmatrix} 0.8 \\ 0.2 \end{bmatrix} = \begin{bmatrix} 186 \cdot 0.8 + 83 \cdot 0.2 \\ 163 \cdot 0.8 + 55 \cdot 0.2 \\ 171 \cdot 0.8 + 68 \cdot 0.2 \\ 1.74 \cdot 0.8 + 80 \cdot 0.2 \\ 190 \cdot 0.8 + 89 \cdot 0.2 \end{bmatrix} = \begin{bmatrix} 165.4 \\ 157.4 \\ 150.4 \\ 17.392 \\ 169.8 \end{bmatrix}$$

Yllä olevassa esimerkissä dimensiotarkastelu: $(5 \times 2)(2 \times 1) = (5 \times 1)$. Vielä kolmantena kahden matriisin kertolasku $\mathbf{X} \mathbf{X}^T$, josta tulee 2×2 -matriisi dimensiotarkastelulla:

$$\begin{bmatrix} 186 & 163 & 171 & 1.74 & 190 \\ 83 & 55 & 68 & 80 & 89 \end{bmatrix} \cdot \begin{bmatrix} 186 & 83 \\ 163 & 55 \\ 171 & 68 \\ 1.74 & 80 \\ 190 & 89 \end{bmatrix} = \begin{bmatrix} (186 \cdot 186 + 163 \cdot 163 + 171 \cdot 171 + 1.74 \cdot 1.74 + 190 \cdot 190) & (...) \\ (83 \cdot 186 + 55 \cdot 163 + 68 \cdot 171 + 80 \cdot 1.74 + 89 \cdot 190) & (...) \end{bmatrix} \approx \begin{bmatrix} 133430 & 54180 \\ 54180 & 28859 \end{bmatrix}$$

- a) Jos matriisi \mathbf{X} on kokoa 361×92 ja matriisi \mathbf{P} on kokoa 92×27 , niin mitkä seuraavista matriisituloista ovat sallittuja operaatioita: \mathbf{XP} , $\mathbf{X}^T \mathbf{P}$, $\mathbf{X}^T \mathbf{P}^T$, \mathbf{XP}^T , \mathbf{PX} , $\mathbf{P}^T \mathbf{X}$, $\mathbf{P}^T \mathbf{X}^T$, \mathbf{PX}^T . Anna sallittujen matriisitulojen koot.
- b) Laske käsin (voit varmistaa koneella)

$$\begin{bmatrix} 3 & -2 \\ 4 & 1 \end{bmatrix} \cdot \begin{bmatrix} 2 & 5 & 3 \\ -2 & 0 & 0 \end{bmatrix}$$

Tarkistustulos alkuun: tulomatriisin vasemman yläurkan arvo on 10.

Matlabissa ja Octavessa

```
X = [186 183 171 1.74 190; 83 55 68 80 89]
4*X
b = [0.8 0.2]',
X'*b
(X'*b)'
X*X'
```

E4. Tutkitaan vektorien välistä etäisyyksiä. Olkoon tunnettuna neljän kaupungin sijannit xy -koordinaatistossa:

Helsingrad (HSG)	24.8	60.2
Öby (ÖBY)	22.3	60.4
Kurjuu (KRJ)	24.7	62.3
Ulaporin (UPI)	25.5	65.0

Tässä etäisyysmatriisi on neliömatriisi, jossa diagonaalilla on nollia: kaupungin etäisyys itsestään on nolla. Vertaa maantiekartaston etäisyyystaulukkoon.

Laske etäisyysmatriisi $\mathbf{D} = (d_{ab})$ käyttäen

- a) euklidista etäisyyttä L_2 $d_{ab} = \sqrt{(a_x - b_x)^2 + (a_y - b_y)^2}$
- b) L_∞ -metriikkaa $d_{ab} = \max_i \{|a_i - b_i|\}$
- c) Manhattan-etaisyyttä (Cityblock) $d_{ab} = \sum_{i=1}^2 |a_i - b_i|$

Entä jos kaupungeista olisi lisäksi ilmoitettu korkeus ja veroprosenttitiedot? Miten etäisyydet laskettaisiin nyt? Matlabissa ja Octavessa

```
X = [24.8 22.3 24.7 25.5; 60.2 60.4 62.3 65.0]
n = size(X,2); % 1km
D = zeros(n, n);
for a = [1 : n]
    for b = [1 : n]
        D(a,b) = sqrt((X(1,a)-X(1,b))^2 + (X(2,a)-X(2,b))^2);
    end;
end;
D
D1 = squareform(pdist(X', 'euclidean'))
D2 = squareform(max(pdist(X', 'chebychev')))
D3 = squareform(pdist(X', 'cityblock'))
```

Huomaa, että Matlabissa ja Octavessa matriisi \mathbf{X} on toisin päin (transponoitu) kuin täällä kursilla. Toisin sanoen Matlabissa riveillä havainnot (lukumäärä n) ja sarakkeissa piirteet (dimensio d). Tästä syystä koodissa käytetään \mathbf{X}' eli \mathbf{X}^T .

E5. Derivointisääntöjä ja -esimerkkejä löytyy matematiikan kirjoista

$$\begin{aligned}\frac{d}{dx} ax^n &= a \frac{d}{dx} x^n = anx^{n-1} \\ \frac{d}{dx} ae^{kx} &= ake^{kx} \\ \frac{d}{dx} \log_e(x) &= 1/x \\ \frac{d}{dx} (p(x) + q(x)) &= \frac{d}{dx} p(x) + \frac{d}{dx} q(x) \\ \frac{d}{dx} (p(x) \cdot q(x)) &= (p(x) \cdot \frac{d}{dx} q(x)) + (\frac{d}{dx} p(x) \cdot q(x))\end{aligned}$$

Osittaisderivoinnissa derivoidaan kerrallaan yhden muuttujan suhteen ja pidetään muita vakioina. Tällöin esimeriksi saman lausekkeen derivointi eri muuttujien suhteiden antaa

$$\begin{aligned}\frac{\partial}{\partial x} (x \cdot e^{-x\mu}) &= (x \cdot (-\mu) \cdot e^{-x\mu}) + (1 \cdot e^{-x\mu}) \\ \frac{\partial}{\partial \mu} (x \cdot e^{-x\mu}) &= x \cdot (-x) \cdot e^{-x\mu}\end{aligned}$$

jossa siis jälkimmäisessä x on vakio derivoinnin suhteen.

- Hahmottele funktion käyrä $p(x) = x^2 + 3x + 4$. Laske sen derivaatan nollakohta eli $\frac{d}{dx}(x^2 + 3x + 4) = 0$, josta tulee yksi ratkaisu. Ääriarvopiste kertoo, missä kohdassa $p(x)$ saa minimin/maksimin (kumman?) Laske tuossa pisteessä funktion arvo.
- Pitäisi etsiä μ :lle ääriarvo derivoimalla lauseke, asettamalla se nollaksi ja ratkaisemalla μ :n arvo:

$$\frac{d}{d\mu} \left((K \cdot e^{-(190-\mu)^2/162}) \cdot (K \cdot e^{-(171-\mu)^2/162}) \cdot (K \cdot e^{-(174-\mu)^2/162}) \right) = 0$$

Koska logaritmi on monotoninen funktio eli ei muuta ääriarvokohtien sijaintia, lasketaankin derivaatta alkuperäisen sijaan logaritmista

$$\begin{aligned}&\frac{d}{d\mu} \log_e \left((K \cdot e^{-(190-\mu)^2/162}) \cdot (K \cdot e^{-(171-\mu)^2/162}) \cdot (K \cdot e^{-(174-\mu)^2/162}) \right) \\ &= \frac{d}{d\mu} \left(\log_e(K \cdot e^{-(190-\mu)^2/162}) + \log_e(K \cdot e^{-(171-\mu)^2/162}) + \log_e(K \cdot e^{-(174-\mu)^2/162}) \right) \\ &= \frac{d}{d\mu} \left(\log_e K + (-(190-\mu)^2/162) + \log_e K + (-(171-\mu)^2/162) \right. \\ &\quad \left. + \log_e K + (-(174-\mu)^2/162) \right) \\ &= \dots \\ &= 0\end{aligned}$$

Johda lausekkeen pyörittely loppuun siistiin muotoon ja ratkaise μ :n ääriarvokohta. Huomaa, että $\frac{d}{d\mu} C = 0$, jos C on vakio μ :n suhteen. Vastaavasti $\frac{d}{d\mu} Kp(\mu) = K \frac{d}{d\mu} p(\mu)$, eli vakiot voi nostaa eteen.

Matlabissa ja Octavessa

```
x = [-5 : 0.01 : 5];
p = x.^2 + 3*x + 4;
plot(x, p);
[minValue, minIndex] = min(p)
x(minIndex)
p(minIndex)
```

E6. Todennäköisyyslaskentaa. Mitataan ihmisten (mies) pituuksia. Saadaan havainnot

$$\mathbf{X} = [174 \ 181 \ 179 \ 165 \ 190 \ 171 \ 188 \ 185 \ 192 \ 173 \ 196 \ 184 \ 188 \ 180 \ 178]$$

- a) Hahmottele pistetet lukusuoralle x
- b) Hahmottele histogrammiesitys, jossa kunkin lokeron leveys on 5 cm
- c) Sovita ainestoon (käsivaralta hahmotellen) Gaussin normaalijakauma keskiarvolla μ ja keskihajonnalla σ

Voit ajaa Matlabin tai Octaven komentoriviltä komentoja:

```
% octave / matlab
X      = [174 181 179 165 190 171 188 185 192 173 196 184 188 180 178];
plot(X, ones(size(X)), '*');

%
figure,
hist(X, [162.5 : 5 : 200]);
% matlabissa:
[muHattu, sigmaHattu] = normfit(X);
xc = [150 : 200];
pc = normpdf(xc, muHattu, sigmaHattu);
figure,
plot(xc, pc);
```

E7. Yksiulotteisen normaalijakauman (Gauss) tiheysfunktio on

$$p(x) = \frac{1}{\sqrt{2\pi}\sigma} \cdot e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

(ONGELMA tulostetussa PDF:ssä: eksponentin jakajassa pitäisi olla 2 kertaa sigma toiseen ($2\sigma^2$), mutta sigmaa ei tule printteristä ulos vaikka näkyy ruudulla Acrobat Readerissä?!)

Aivan sama kaava voidaan kirjoittaa hieman eri notaatioilla. Usein yritetään välttää noita hyvin pieniä kirjasinkokoja:

$$p(x) = (2\pi\sigma^2)^{-1/2} \cdot \exp(-(x-\mu)^2/(2\sigma^2))$$

Laske taskulaskimella arvo $p(x) = \frac{1}{\sqrt{2\pi}\sigma} \cdot e^{-\frac{(x-\mu)^2}{2\sigma^2}}$, kun

- a) $\sigma = 9$, $\mu = 174$ ja $x = 174$.
- b) $\sigma = 9$, $\mu = 174$ ja $x = 190$.
- c) $\sigma = 9$, $\mu = 174$ ja $x = 171$.

Muistuta mieliin, miltä käyrä $y = p(x)$ näyttää (katso kaava yllä tai katso netistä "normaalijakauma"). Huomaa, että $p(x) > 0$ aina ja symmetrinen μ :n suhtein. Huomaa myös, että $p(x)$:n lopputulos on siis yksi lukuarvo ja se ei tässä esimerkissä ole todennäköisyysarvo; voidaan kysyä, mikä on todennäköisyys $P(X < 174)$, mutta ei ole järkevästi kysyä mikä on todennäköisyys $P(X = 174)$.

Hahmottele piirtämällä $p(x)$ yllä olevilla arvoilla $\mu = 174$ ja $\sigma = 9$. Katso $p(x)$:n arvot yllä mainituissa kohdissa x_i . b-kohdan vastaus pitäisi olla välillä (0.008, 0.212).

Voit ajaa Matlabin tai Octaven komentoriviltä komentoja:

```
% octave / matlab
sigma = 9;
mu    = 174;
x     = [130:210]; % x-akselin arvot
K     = 1/(sqrt(2*pi)*sigma);
M     = -(x-mu).^(2./2*sigma.^2);
p     = K*exp(M); % y-akselin arvoiksi p(x)
plot(x, p); % piirtokomento
```

E8. a) Esimerkki neliöksi täydentämisestä:

$$\begin{aligned} 3x^2 + 4x + 7 &= 3 \cdot (x^2 + (4/3)x + (7/3)) \\ &= 3 \cdot (x^2 + 2 \cdot (2/3)x + (2/3)^2 - (2/3)^2 + (7/3)) \\ &= 3 \cdot ((x + (2/3))^2 + (17/9)) \end{aligned}$$

b) Kaksi normaalitihesjakaumaa $p_1(x|\mu_1, \sigma)$ ja $p_2(x|\mu_2, \sigma)$, joilla on sama varianssi σ^2 kerrotaan keskenään ja joilla molemmissa siten sama kerroin $K = 1/(\sqrt{2\pi\sigma^2})$:

$$\begin{aligned} p_1(x|\mu_1, \sigma) &= K \cdot e^{-\frac{(x-\mu_1)^2}{2\sigma^2}} \\ p_2(x|\mu_2, \sigma) &= K \cdot e^{-\frac{(x-\mu_2)^2}{2\sigma^2}} \\ p_1(x|\mu_1, \sigma) \cdot p_2(x|\mu_2, \sigma) &= K \cdot e^{-\frac{(x-\mu_1)^2}{2\sigma^2}} \cdot K \cdot e^{-\frac{(x-\mu_2)^2}{2\sigma^2}} \\ &= K^2 \cdot e^{-\frac{(x-\mu_1)^2+(x-\mu_2)^2}{2\sigma^2}} \\ &= \dots \\ &= K_n \cdot e^{-\frac{(x-\mu_n)^2}{2\sigma_n^2}} \end{aligned}$$

Miten tulkitset alinta riviä? Mitä on μ_n lausuttuna $\mu_1:n$ ja $\mu_2:n$ avulla? Pura auki ja täydennä neliöksi puuttuvalla rivillä. Huomaa, että jos a on vakio ja x muuttuja, niin $e^{a+x} = e^a \cdot e^x$, jossa e^a on myös vakio (skaalaustermi).

c) Tee vastaava kertolasku kun yllä b-kohdassa mutta tiheysfunktioille $p_1(x|\mu_1, \sigma_1)$ ja $p_2(x|\mu_2, \sigma_2)$, joiden varianssit ovat myös erilaisia. Mikä on nyt μ_n ?

Voit ajaa Matlabin tai Octaven komentoriviltä komentoja:

```
% octave / matlab
sigma = 9;
mu1 = 174;
mu2 = 191;
x = [140:220]; % x-akselin arvot
K = 1/(sqrt(2*pi)*sigma);
M1 = -(x-mu1).^2./(2*sigma.^2);
M2 = -(x-mu2).^2./(2*sigma.^2);
p1 = K*exp(M1); % y-akselin arvoiksi p1(x)
p2 = K*exp(M2); % y-akselin arvoiksi p2(x)
hanska= 42;
pn = p1.*p2*hanska; % skaalataan hanskavakiolla
plot(x, p1, 'b', x, p2, 'g', x, pn, 'k'); % piirtokomento
```

Datasta Tietoon, syksy 2011, paperiharjoitukset 1-5

HARJOITUSTEHTÄVÄT 1

[pe 4.11.2011, ma 7.11.2011]

H1 / 1. (Konvoluutiosuodin)

Konvoluutiosuodin lasketaan kaavalla

$$g_k = \sum_{m=-\infty}^{\infty} f_m s_{k-m},$$

missä f_k on (diskreetti) tulosignaali, s_k on suodinjono, ja g_k on lähtösignaali. Laske ja piirrä lähtösignaali kun

a)

$$f_0 = 1, f_m = 0 \text{ muuten}; \quad (1)$$

$$s_0 = 2, s_1 = 1, s_n = 0 \text{ muuten} \quad (2)$$

b)

$$f_0 = 2, f_1 = -1, f_m = 0 \text{ muuten}; \quad (3)$$

$$s_0 = -1, s_1 = 2, s_2 = 1, s_n = 0 \text{ muuten}. \quad (4)$$

H1 / 2. (Suodatus taajuusalueessa)

Taajuusalueessa Tehtävän 1 konvoluutiokaava tulee muotoon

$$G(\omega) = H(\omega)S(\omega)$$

missä funktiot ovat vastaavien diskreettisignaalien diskreettiaikaisia Fourier-muunnoksia (DTFT)

$$F(\omega) = \sum_{m=-\infty}^{\infty} f_m e^{-i\omega m}$$

a) Osoita että Tehtävän 1 b jonoille f ja s saadaan Fourier-muunnokset $F(\omega) = 2 - e^{-i\omega}$ ja $S(\omega) = -1 + 2e^{-i\omega} + e^{-2i\omega}$. Laske näiden tulo $G(\omega) = H(\omega)S(\omega)$ ja vertaa saadun polynomien kertoimia Tehtävän 1 b lopputulokseen g .

H1 / 3. (Fourier-muunnos)

Diskreettiaikainen Fourier-muunnos (DTFT) on määritelty

$$F(\omega) = \sum_{m=-\infty}^{\infty} f_m e^{-i\omega m}$$

a) Osoita että käänteismuunnos on

$$f_n = \frac{1}{2\pi} \int_{-\pi}^{\pi} F(\omega) e^{i\omega n} d\omega$$

b) Ideaalisen alipäästösuoimen Fourier-muunnos (väillä $-\pi \leq \omega \leq \pi$) on

$$H(\omega) = 1 \text{ jos } |\omega| \leq \omega_0, 0 \text{ muuten}. \quad (5)$$

Käyttäen käänteismuunnosta laske vastaava jono h_n ja piirrä se kun $\omega_0 = \pi/2$.

H1 / 4. (Alimerkkijonohistogrammit)

DNA-molekyylit voidaan kirjoittaa merkkijonona, jossa on 4 eri kirjainta A, C, G, T, esim. ...AAGTACCGTGACGGAT ... Oletetaan että koko merkkijonon pituus on miljoona merkkiä. Haluamme muodostaa histogrammeja n :n pituisille osamerkkijonoille (jos $n = 1$, niin merkeille A, C, G, T; jos $n = 2$, niin pareille AA, AC, ... TT jne.). Kuinka suureksi voi n :n valita, jos kuhunkin histogrammin lokeroon halutaan osuvan keskimäärin 10 osamerkkijonoa?

H1 / 5. (Korkeaulotteiset avaruudet)

d -ulotteiset datavektorit ovat tasaisesti jakautuneita hyperkuutioon, jonka sivun pituus on 1. Määritellään sisäpisteiksi ne, joiden etäisyys hyperkuution pinnasta on vähintään $\epsilon > 0$. Osoita että sisäpisteiden joukon suhteellinen tilavuus menee nollaan kun $d \rightarrow \infty$, toisin sanoen hyvin suurissa dimensioissa lähes kaikki pistet ovat hyperkuution pinnalla.

H1 / 6. (Korkeaulotteiset avaruudet)

Luennoilla mainittiin ilman todistusta että n :n pisteen keskimääräinen etäisyys d -ulotteisessa hyperkuutiossa on

$$D(d, n) = \frac{1}{2} \left(\frac{1}{n} \right)^{\frac{1}{d}}$$

Tämä on likimääräinen kaava. Katsotaan erikoistapausta: n pistettä on sijoittunut n :n pienemmän samanlaisen hyperkuution keskipisteisiin, missä pienet hyperkuutiot eivät leikkaa toisiaan mutta niiden unioni on koko hyperkuutio. Osoita että pisteiden etäisyydet ovat

$$D(d, n) = \left(\frac{1}{n} \right)^{\frac{1}{d}},$$

kun kahden pisteen $\mathbf{x}_1, \mathbf{x}_2$ etäisyys määritellään siten että se on $\max_i |x_{i1} - x_{i2}|$. Kokeile tapausta $d = 2$, $n = 4$ ja totea että tulos pätee.

H1 / Problem 1.

Convolution sum is computed as

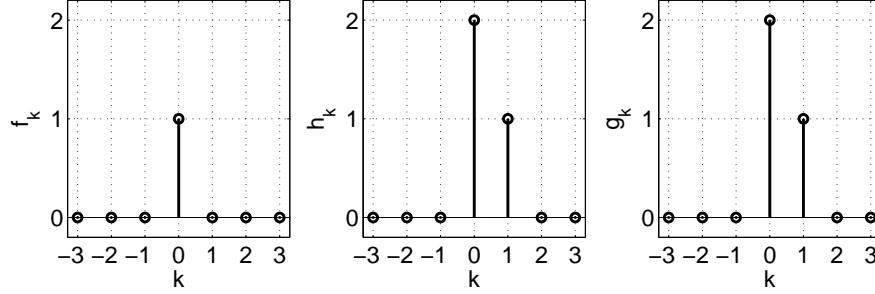
$$g_k = \sum_{m=-\infty}^{\infty} f_m s_{k-m} = \dots + f_{-2}s_{k+2} + f_{-1}s_{k+1} + f_0s_k + f_1s_{k-1} + f_2s_{k-2} + \dots$$

a) Now

$$f_0 = 1, f_m = 0 \text{ otherwise}; \quad (6)$$

$$s_0 = 2, s_1 = 1, s_n = 0 \text{ otherwise} \quad (7)$$

Thus $g_k = f_0 s_{k-0} = s_k$, which is $g_0 = 2$, $g_1 = 1$, and $g_k = 0$ elsewhere.



The other sequence f_k was an identity sequence (only one at $k = 0$, zero elsewhere), so it just copies the other sequence s_k into the output.

b) Now

$$f_0 = 2, f_1 = -1, f_m = 0 \text{ otherwise}; \quad (8)$$

$$s_0 = -1, s_1 = 2, s_2 = 1, s_n = 0 \text{ otherwise}. \quad (9)$$

Thus

$$g_k = f_0 s_{k-0} + f_1 s_{k-1} = 2s_k - s_{k-1}$$

and we get

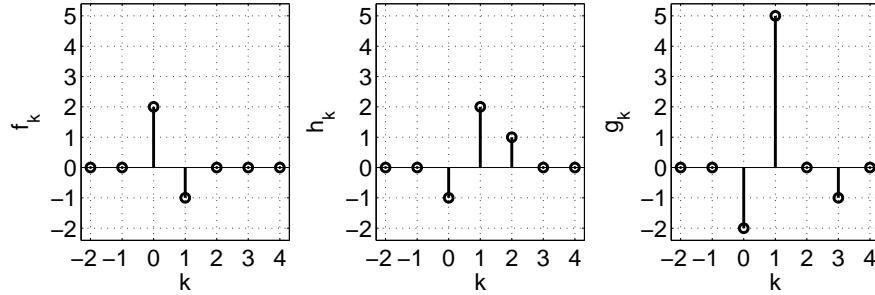
$$g_0 = 2s_0 - s_{-1} = -2 \quad (10)$$

$$g_1 = 2s_1 - s_0 = 4 + 1 = 5 \quad (11)$$

$$g_2 = 2s_2 - s_1 = 2 - 2 = 0 \quad (12)$$

$$g_3 = 2s_3 - s_2 = -1 \quad (13)$$

$$g_k = 0 \text{ otherwise} \quad (14)$$



Sequence $f_k = \{-2, 1\}$ was now a sum sequence of an identity filter multiplied by two ($f_0 = 2$) and a shifted identity filter multiplied by -1 ($f_1 = -1$). Therefore the output consisted of a sum of s_k multiplied by two and a shifted s_k multiplied by -1 .

$$\begin{aligned} 2s_k - s_{k-1} &= 2 \cdot \{-2, 1\} - 1 \cdot \{0, 1\} \\ &= \{-2+0, 4+1, 2-2, 0-1\} = \{-2, 5, 0, -1\} \end{aligned}$$

See more examples in the computer session **T1**.

H1 / Problem 2.

a) From Problem 1 b

$$f_0 = 2, f_1 = -1, f_m = 0 \text{ otherwise}; \quad (15)$$

$$s_0 = -1, s_1 = 2, s_2 = 1, s_n = 0 \text{ otherwise} \quad (16)$$

we get using the definition

$$F(\omega) = \sum_{m=-\infty}^{\infty} f_m e^{-i\omega m}$$

$$F(\omega) = f_0 \cdot e^{-i\omega 0} + f_1 e^{-i\omega 1} = 2 - e^{-i\omega} \quad (17)$$

$$S(\omega) = s_0 \cdot e^{-i\omega 0} + s_1 \cdot e^{-i\omega 1} + s_2 \cdot e^{-i\omega 2} = -1 + 2e^{-i\omega} + e^{-2i\omega} \quad (18)$$

Convolution of two sequences in time-domain corresponds multiplication of two transforms in transform/frequency-domain. The real argument ω gets normally values $-\pi \dots \pi$ or $0 \dots \pi$

$$G(\omega) = F(\omega)S(\omega) \quad (19)$$

$$= (2 - e^{-i\omega}) \cdot (-1 + 2e^{-i\omega} + e^{-2i\omega}) \quad (20)$$

$$= -2 + 5e^{-i\omega} - e^{-3i\omega} \quad (21)$$

We find out that the coefficients $\{-2, 5, 0, -1\}$ of the polynomial $G(\omega)$ are equal to the sequence g_k .

Remark. There are several integral transforms that are used in specific cases:

- *Fourier series*, where signal $f(t)$ is analog and periodic (Ω_0), gives discrete and aperiodic Fourier series coefficients F_n with multiples of the fundamental angular frequency Ω_0
- (Continuous-time) Fourier transform, where signal $f(t)$ is analog and aperiodic, gives continuous and aperiodic transform $F(\Omega)$
- Discrete-time Fourier transform, where signal f_k is discrete and aperiodic, gives continuous and periodic transform $F(\omega)$ as above
- Discrete Fourier transform (DFT), where signal f_k is discrete and periodic (length N), gives discrete and periodic transform F_n (length N)

H1 / Problem 3.

a) Substitute $F(\omega)$ into the integral:

$$I = \frac{1}{2\pi} \int_{-\pi}^{\pi} \left[\sum_{m=-\infty}^{\infty} f_m e^{-i\omega m} \right] e^{i\omega n} d\omega = \frac{1}{2\pi} \sum_{m=-\infty}^{\infty} f_m \int_{-\pi}^{\pi} e^{i\omega(n-m)} d\omega$$

with $i = \sqrt{-1}$ the imaginary unit (sometimes also denoted j).

For the integral we get (note that $n, m \in \mathbb{Z}$)

$$\int_{-\pi}^{\pi} e^{i\omega(n-m)} d\omega = \begin{cases} 2\pi & \text{if } n = m, \\ /_{-\pi}^{\pi} \frac{1}{i(n-m)} e^{i\omega(n-m)} = \frac{1}{i(n-m)} (e^{i\pi(n-m)} - e^{-i\pi(n-m)}) & \text{if } n \neq m \end{cases}$$

We can easily see that $e^{i\pi(n-m)} = e^{-i\pi(n-m)}$ because $e^{i\pi} = e^{-i\pi} = -1$. Thus the integral is 2π if $n = m$ and zero otherwise. Substituting this into the full expression gives $I = f_n$ which was to be shown.

b)

$$h_n = \frac{1}{2\pi} \int_{-\omega_0}^{\omega_0} e^{i\omega n} d\omega = \frac{1}{2\pi} /_{-\omega_0}^{\omega_0} \frac{1}{in} e^{i\omega n} \quad (22)$$

$$= \frac{1}{2\pi in} (e^{i\omega_0 n} - e^{-i\omega_0 n}) \quad (23)$$

$$= \frac{1}{2\pi in} [\cos(\omega_0 n) + i \sin(\omega_0 n) - \cos(-\omega_0 n) - i \sin(-\omega_0 n)] \quad (24)$$

$$= \frac{1}{\pi n} \sin(\omega_0 n). \quad (25)$$

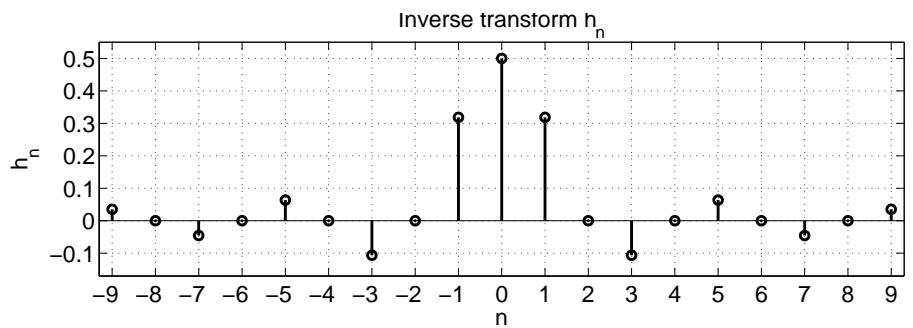
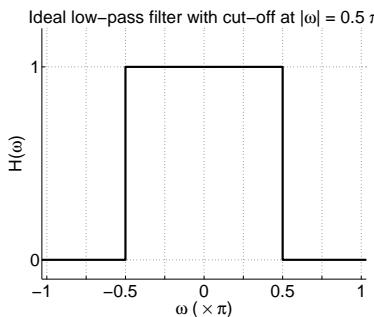
Using the cut-off frequency $\omega = \pi/2$ we get

$$h_n = \frac{1}{\pi n} \sin\left(\frac{\pi n}{2}\right)$$

which is sometimes written as $h_n = (1/2)\text{sinc}(n/2)$, where sinc function is $\text{sinc}(\omega n) = \sin(\pi\omega n)/(\pi\omega n)$. Some values: $h_0 = 0.5$, $h_1 = 1/\pi$, $h_2 = 0$.

Note that at $n = 0$ we end up to 0/0. It can be solved, e.g., either Taylor series $(1/x) \sin(x/2) = (1/2)(2/x) \sin(x/2) = (1/2) - (x^2/48) + \dots$, or l'Hospital's rule by derivating both sides. Thus at zero the value is 0.5. In addition, $\text{sinc}(0) = 1$.

Note also that the sequence h_n is infinitely long.



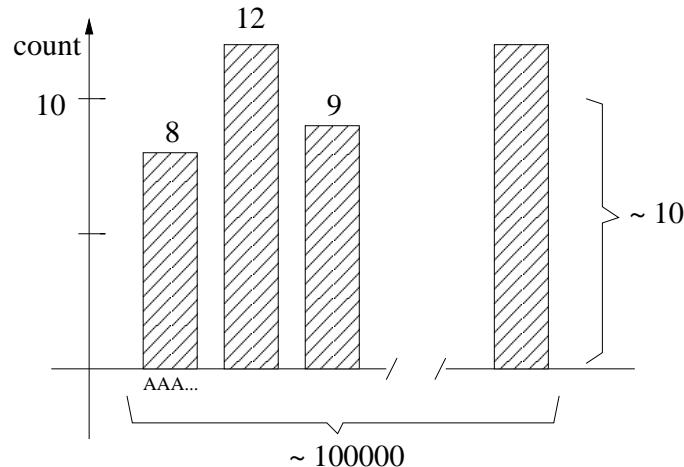
H1 / Problem 4.

Now the number of bins is at most 100000, because the average number of substrings in a bin must be at least 10. The number of different substrings of length n is 4^n . We get

$$4^n \leq 100000$$

giving $n \leq 8$.

An example of a histogram of a data sample given below. It is assumed that letters are drawn independently from uniform distribution, i.e., the total amount of each letter is the same.



Another example on building a histogram with the sequence 'AAGTACCGTGACGGAT'.

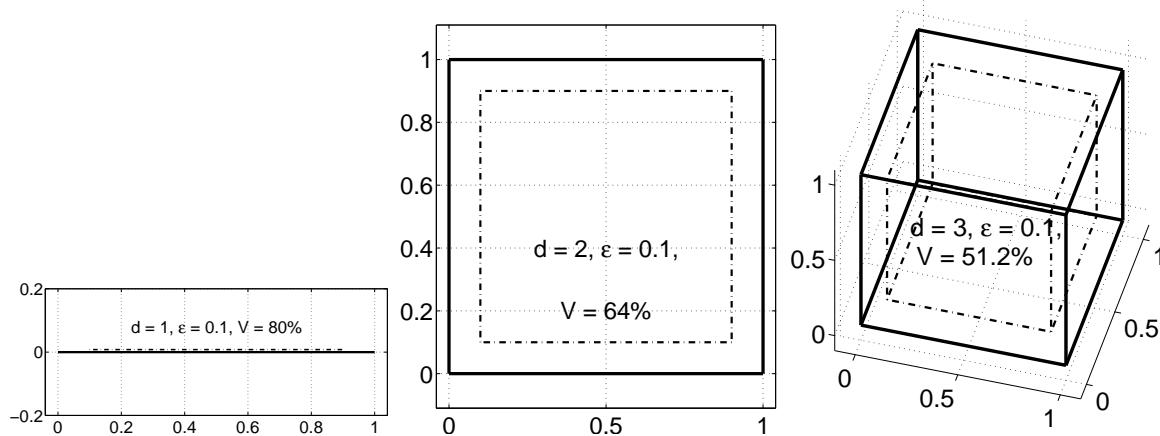
If $n = 1$, all possible substrings are 'A', 'C', 'G', and 'T', shortly A, C, G, T . The number of substrings is $4^1 = 4$. The count for each substring: $|A| = 5$, $|C| = 3$, $|G| = 5$, and $|T| = 3$.

If $n = 2$, all possible substrings are 'AA', 'AC', 'AG', 'AT', 'CA', 'CC', 'CG', 'CT', 'GA', 'GC', 'GG', 'GT', 'TA', 'TC', 'TG', 'TT', that is, $4^2 = 16$ substrings. The count for each substring: $|AA| = 1$, $|AC| = 2$, $|AG| = 1$, $|AT| = 0$, etc.

H1 / Problem 5.

The volume of the unit hypercube is 1 and the volume of the set of inner points is $V_d = (1 - 2\epsilon)^d$. For any ϵ , this tends to 0 as $n \rightarrow \infty$.

Below an illustration of hypercubes in dimensions $d = 1, 2, 3$ with $\epsilon = 0.1$. We can see that the volume of inner points decreases when the dimension increases.

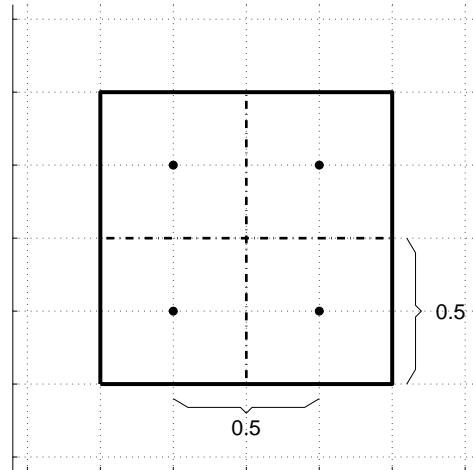
**H1 / Problem 6.**

Now the small hypercubes are similar, hence all have the same volume which must be $\frac{1}{n}$ times the volume of the large unit hypercube. (This is only possible for certain values of (n, d) ; for $d = 2$, n must be 4, 9, 16, ...; for $d = 3$, n must be 8, 27, 64 ... etc.)

Also, we assume here a special distance which is not Euclidean distance but $D(\mathbf{x}_1, \mathbf{x}_2) = \max_i |x_{i1} - x_{i2}|$, that is, the largest distance along the coordinate axes.

Then it is easy to see that the distance of the centres of the small hypercubes is equal to the length of their side s . Because the volume is $s^d = \frac{1}{n}$, we have $s = \frac{1}{n}^{\frac{1}{d}}$.

The case of $d = 2, n = 4$ is shown below.



HARJOITUSTEHTÄVÄT 2

[pe 11.11.2011, ma 14.11.2011]

H2 / 1. (Pääkomponenttianalyysi)On annettuna seuraava datamatriisi \mathbf{X} :

$$\mathbf{X} = \begin{bmatrix} 2 & 5 & 6 & 7 \\ 1 & 3 & 5 & 7 \end{bmatrix}$$

- a) Piirrä \mathbf{X} :n sarakkeet (x_1, x_2) - koordinaatistoon
- b) Keskiarvoista \mathbf{X} vähentämällä sarakkeista niiden keskiarvovektori
- c) Muodosta kovarianssimatriisi \mathbf{C} ja laske sen suurinta ominaisarvoa vastaava ominaisvektori. Piirrä sen suunta kohdan a) kuvaan. Miten tuloksia voi tulkita pääkomponenttianalyysin mukaisesti?

H2 / 2. (Pääkomponenttianalyysi)

Olkoon \mathbf{x} nollakeskiarvoinen satunnaisvektori, josta on olemassa otos $\mathbf{x}(1), \dots, \mathbf{x}(n)$. Olkoon \mathbf{w} yksikkövektori (siis $\|\mathbf{w}\| = 1$) ja $y = \mathbf{w}^T \mathbf{x}$. Halutaan maksimoida y :n varianssi $E\{y^2\} = E\{(\mathbf{w}^T \mathbf{x})^2\}$. Osoita että se maksimoituu, kun \mathbf{w} on matriisin $E\{\mathbf{x}\mathbf{x}^T\}$ suurinta ominaisarvoa vastaava ominaisvektori.

H2 / 3. (ML-estimointi)

Laske suurimman uskottavuuden estimaatti eksponentiaalijakauman

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

parametrille λ kun suureesta x on olemassa otos $x(1), \dots, x(n)$.**H2 / 4. (Bayes-estimointi)**On annettu otos $x(1), \dots, x(n)$ suureesta, jonka tiedetään olevan normaalijakautunut

$$p(x|\mu, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}.$$

On syytä olettaa että keskiarvo μ on lähellä nollaa. Koodataan tämä olettamus priorijakaumaan

$$p(\mu) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}\mu^2}.$$

Laske Bayes-MAP-estimaatti odotusarvolle μ ja tulkitse sitä kun varianssi σ^2 vaihtelee pienestä suureen.

H2 / Problem 1.

a) See the figure below left.

b) Compute first mean and subtract it from \mathbf{X} :

$$E\{\mathbf{x}\} = \frac{1}{4} \sum \mathbf{x}(i) = \begin{bmatrix} 5 \\ 4 \end{bmatrix}$$

Thus the normalized data matrix is

$$\mathbf{X}_0 = \begin{bmatrix} -3 & 0 & 1 & 2 \\ -3 & -1 & 1 & 3 \end{bmatrix}$$

c) The covariance matrix is

$$\mathbf{C}_x = \frac{1}{4} \mathbf{X}_0 \mathbf{X}_0^T = \frac{1}{4} \begin{bmatrix} 14 & 16 \\ 16 & 20 \end{bmatrix}$$

The eigenvalues are computed from $\mathbf{C}_x \mathbf{u} = \lambda \mathbf{u}$, or by multiplying with 4, $\begin{bmatrix} 14 & 16 \\ 16 & 20 \end{bmatrix} \mathbf{u} = \mu \mathbf{u}$ where μ is 4 times λ . (It may be easier to solve the equation if the coefficients are integer numbers).

We have determinant $\begin{vmatrix} 14 - \mu & 16 \\ 16 & 20 - \mu \end{vmatrix} = 0$ which gives the characteristic equation $(14 - \mu)(20 - \mu) - 256 = 0$ or $\mu^2 - 34\mu + 24 = 0$. The roots are 33.28 and 0.72, hence the eigenvalues λ of the covariance matrix are these divided by 4, $\lambda_1 = 8.32$ and $\lambda_2 = 0.18$.

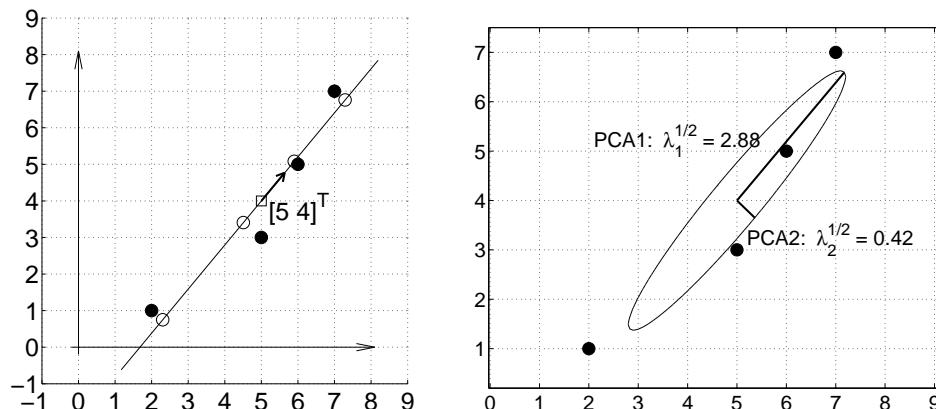
The eigenvector \mathbf{u} corresponding to the larger eigenvalue λ_1 can be computed from $\mathbf{C}_x \mathbf{u} = \lambda_1 \mathbf{u}$ by

$$\begin{aligned} \begin{bmatrix} 14 & 16 \\ 16 & 20 \end{bmatrix} \begin{bmatrix} u_1 \\ u_2 \end{bmatrix} &= 33.28 \begin{bmatrix} u_1 \\ u_2 \end{bmatrix} \\ \begin{cases} 14u_1 + 16u_2 = 33.28u_1 \\ 16u_1 + 20u_2 = 33.28u_2 \end{cases} &\Rightarrow u_1 = 0.83u_2 \\ \Rightarrow \mathbf{u}_1 &= a \begin{bmatrix} 0.83 \\ 1 \end{bmatrix}, \quad a \in \mathbb{R} \end{aligned}$$

After normalization to the unit length ($\mathbf{u}/\|\mathbf{u}\|$) the eigenvector corresponding largest eigenvalue λ_1 is $\mathbf{u} = [0.64 \ 0.77]^T$.

The empty circles in the figure (below, left) are the projections onto 1D hyperplane (PCA1 line) by $Y = \mathbf{u}_1^T \mathbf{X}_0 = [-4.23 \ -0.77 \ 1.41 \ 3.59]$. First PCA1 axis explains $8.32/(8.32 + 0.18) \approx 97.9\%$ of the total variance.

In the other figure (right) it can be seen that the proportional length of the axis of an ellipse in direction PCA1 is $\sqrt{\lambda_1} \approx 2.88$, and in direction PCA2 $\sqrt{\lambda_2} \approx 0.42$. The ellipse is derived from the Gaussian covariance matrix \mathbf{C}_x .



In PCA the original coordinate axis system (x_1, x_2) is shifted by mean and rotated by $[\mathbf{u}_1 \ \mathbf{u}_2]$. The variance of the data is maximized in direction PCA1. Data is linearly uncorrelated in the new axis system (PCA1, PCA2).

H2 / Problem 2.

We can use the *Lagrange optimization* principle for a constrained maximization problem. The principle is saying that if we need to maximize $E\{(\mathbf{w}^T \mathbf{x})^2\}$ under the constraint $\mathbf{w}^T \mathbf{w} = 1$, we should find the zeroes of the gradient of

$$E\{(\mathbf{w}^T \mathbf{x})^2\} - \lambda(\mathbf{w}^T \mathbf{w} - 1)$$

where λ is the Lagrange constant.

We can write $E\{(\mathbf{w}^T \mathbf{x})^2\} = E\{(\mathbf{w}^T \mathbf{x})(\mathbf{x}^T \mathbf{w})\} = \mathbf{w}^T E\{\mathbf{x}\mathbf{x}^T\} \mathbf{w}$ because inner product is symmetrical and the E or expectation means computing the mean over the sample $\mathbf{x}(1), \dots, \mathbf{x}(n)$, thus \mathbf{w} can be taken out.

We need the following general result: if \mathbf{A} is a symmetrical matrix, then the gradient of the quadratic form $\mathbf{w}^T \mathbf{A} \mathbf{w}$ equals $2\mathbf{A}\mathbf{w}$. It would be very easy to prove this by taking partial derivatives with respect to the elements of \mathbf{w} . This is a very useful formula to remember.

Now the gradient of the Lagrangian becomes:

$$2E\{\mathbf{x}\mathbf{x}^T\} \mathbf{w} - \lambda(2\mathbf{w}) = 0$$

or

$$E\{\mathbf{x}\mathbf{x}^T\} \mathbf{w} = \lambda \mathbf{w}$$

This is the eigenvalue - eigenvector equation for matrix $E\{\mathbf{x}\mathbf{x}^T\}$. But there are d eigenvalues and vectors: which one should be chosen?

Multiplying from the left by \mathbf{w}^T and remembering that $\mathbf{w}^T \mathbf{w} = 1$ gives

$$\mathbf{w}^T E\{\mathbf{x}\mathbf{x}^T\} \mathbf{w} = \lambda$$

showing that λ should be chosen as the largest eigenvalue in order to maximize $\mathbf{w}^T E\{\mathbf{x}\mathbf{x}^T\} \mathbf{w} = E\{y^2\}$. This was to be shown.

H2 / Problem 3.

Problem: Given data sample \mathbf{X} , compute estimator $\hat{\lambda}_{\text{ML}}$ with which data has been most probably generated. The maximum likelihood (ML) method is summarized as (p. 233. Milton, Arnold: Introduction to probability and statistics. Third edition. McGraw-Hill, 1995)

1. Obtain a random sample $\mathbf{X} = \{x(1), x(2), \dots, x(n)\}$ from the distribution of a random variable X with density p and associated parameter θ

2. Define a likelihood function $L(\theta)$ by

$$L(\theta) = \prod_{i=1}^n p(x(i))$$

3. Find the expression for θ that maximizes the likelihood function. This can be done directly or by maximizing $\ln L(\theta)$

4. Replace θ by $\hat{\theta}$ to obtain an expression for ML estimator for θ

5. Find the observed value of this estimator for a given sample

Let us assume that data samples $\mathbf{X} = \{x(1), x(2), \dots, x(n)\}$ are i.i.d., that is, they are independent and identically-distributed. Independence means that joint density function $P(A, B, C)$ can be decomposed to product of marginal density functions: $P(A, B, C) = P(A) \cdot P(B) \cdot P(C)$. Each sample $x(i)$ is from the same (identical) distribution $p(x|\lambda)$ with the same λ . One-dimensional exponential probability density function is $p(x|\lambda) = \lambda e^{-\lambda x}$ where rate $\lambda = 1/\mu$.

In this case the likelihood function $L(\lambda)$ ("uskottavuusfunktio") is

$$L(\lambda) = p(\mathbf{X}|\lambda) = p(x(1), x(2), \dots, x(n)|\lambda) \stackrel{\text{i.i.d.}}{=} \prod_{i=1}^n p(x(i)|\lambda) = \prod_{i=1}^n \lambda e^{-\lambda x(i)}$$

Because samples $x(i)$ are known, likelihood is a function of λ only.

In order to find estimator $\hat{\lambda}_{\text{ML}}$ we maximize likelihood by, e.g., setting derivative to zero. Because we are finding the extreme point, we can take logarithm and still find the same maximum point of likelihood function. The computation comes much easier because $\ln(A \cdot B \cdot C) = \ln A + \ln B + \ln C$. The log-likelihood:

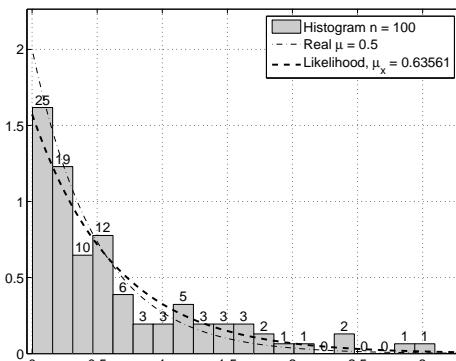
$$\begin{aligned} \ln L(\lambda) &= \ln p(\mathbf{X}|\lambda) = \ln \prod_{i=1}^n [\lambda e^{-\lambda x(i)}] \\ &= \sum_{i=1}^n [\ln \lambda - \lambda x(i)] \\ &= n \ln \lambda - \lambda \sum_{i=1}^n x(i) \end{aligned}$$

Putting the derivative with respect to λ to zero gives the solution $\hat{\lambda}_{\text{ML}}$

$$\begin{aligned} \frac{d}{d\lambda} \ln L(\lambda) &= \frac{d}{d\lambda} \left\{ n \ln \lambda - \lambda \sum_{i=1}^n x(i) \right\} = \frac{n}{\lambda} - \sum_{i=1}^n x(i) = 0 \\ \frac{1}{\lambda} &= \frac{1}{n} \sum_{i=1}^n x(i) \end{aligned}$$

Thus the ML (maximum likelihood) estimate for λ is the inverse of the mean value of the sample.

An example in the figure below. $n = 100$ samples $x(1), \dots, x(100)$ are drawn from the exponential distribution with $\mu = 0.5 \Leftrightarrow \lambda = 1/\mu = 2$. Sample mean $1/\hat{\lambda}_{\text{ML}} = \bar{X} = 0.636$ at this time.

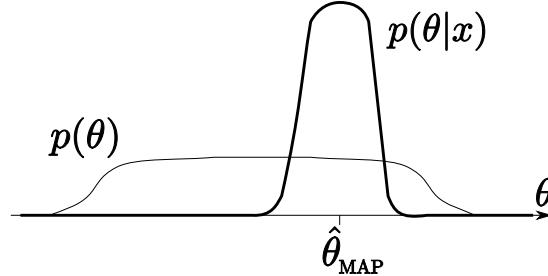


H2 / Problem 4.

Problem: Given data sample \mathbf{x} and prior distribution for μ , compute estimator $\hat{\mu}_{\text{MAP}}$. This Bayesian maximum posterior (MAP) method follows that of maximum likelihood (Problem H2/3) but now the function to be maximized is not likelihood but posterior = likelihood \times prior. Inference using Bayes' theorem can be written as

$$p(\theta|x) = \frac{p(x|\theta)p(\theta)}{p(x)}$$

where $p(\theta|x)$ is posterior, $p(x|\theta)$ likelihood, $p(\theta)$ prior and $p(x)$ evidence, which is just a scaling factor. θ contains all parameters. This results to a posterior distribution (our knowledge after seeing data) with respect to θ which is more exact (with smaller variance) than prior (our knowledge or guess before seeing any data), see figure below. Note that here we have a distribution for θ whereas the maximum likelihood gives a point estimate. Finally, however, the MAP estimate is a single value that maximizes the posterior.



Let us again assume that data samples $\mathbf{X} = \{x(1), x(2), \dots, x(n)\}$ are i.i.d., that is, they are independent and identically-distributed. The one-dimensional normal (Gaussian) density function is

$$p(x|\mu, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

Each sample $x(i)$ is from the same (identical) distribution $p(x|\mu, \sigma)$ with the same μ and σ .

Likelihood function is

$$L(\mu, \sigma) = p(\mathbf{X}|\mu, \sigma) \stackrel{\text{i.i.d.}}{=} \prod_{i=1}^n p(x(i)|\mu, \sigma)$$

Our prior for μ (with hyperparameters $\mu_0 = 0$ and $\sigma_0 = 1$) is

$$p(\mu) = \frac{1}{\sqrt{2\pi}} e^{-\frac{\mu^2}{2}}$$

Posterior is

$$p(\mu, \sigma|\mathbf{X}) \propto L(\mu, \sigma)p(\mu)p(\sigma)$$

where the constant denominator $p(\mathbf{X})$ can be omitted when searching maximum. The symbol \propto can be read "is proportional".

Taking logarithm of likelihood function and setting the derivative with respect to μ to zero follows computation as in Problem H2/3. The log-likelihood:

$$\begin{aligned} \ln L(\mu, \sigma) = \ln p(\mathbf{X}|\mu, \sigma) &= \ln \prod_{i=1}^n \left[\frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x(i)-\mu)^2}{2\sigma^2}} \right] \\ &= \sum_{i=1}^n \left[\ln \left(\frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x(i)-\mu)^2}{2\sigma^2}} \right) \right] \\ &= \sum_{i=1}^n \left[-\ln \sigma - \ln(\sqrt{2\pi}) - \frac{(x(i)-\mu)^2}{2\sigma^2} \right] \end{aligned}$$

The log-prior probability for μ is

$$\ln p(\mu) = -\ln(\sqrt{2\pi}) - \frac{1}{2}\mu^2$$

The log-posterior can be written with Bayes' theorem as a sum of log-likelihood and log-prior

$$\ln p(\mu, \sigma|\mathbf{X}) \propto \ln L(\mu, \sigma) + \ln p(\mu) + \ln p(\sigma)$$

In other words, all parts depending on μ in the Bayesian log-posterior probability are:

$$-\frac{1}{2\sigma^2} \sum_{i=1}^n [(x(i) - \mu)^2] - \frac{1}{2}\mu^2$$

Setting derivative of log-posterior with respect to μ to zero gives

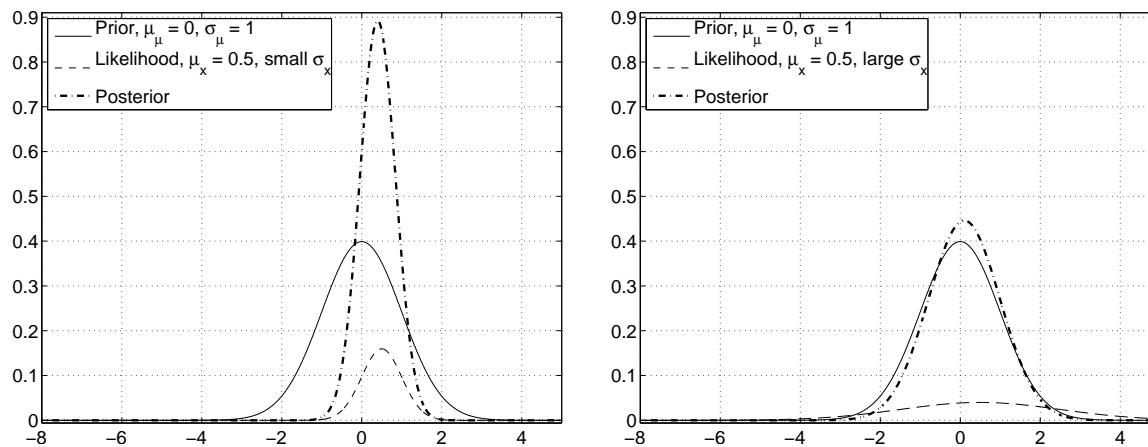
$$\begin{aligned} 0 &= \frac{d}{d\mu} \left\{ \left(-\frac{1}{2\sigma^2} \right) \sum_{i=1}^n [(x(i) - \mu)^2] - \frac{1}{2}\mu^2 \right\} \\ &= -\frac{1}{2\sigma^2} \sum_{i=1}^n [2(x(i) - \mu)(-1)] - \mu \\ &= \sum_{i=1}^n [x(i)] - n\mu - \sigma^2\mu \end{aligned}$$

which finally gives $\hat{\mu}_{\text{MAP}}$

$$\mu = \frac{1}{n + \sigma^2} \sum_{i=1}^n x(i)$$

The interpretation is as follows: if the variance σ^2 of the sample is very small, then the sample can be trusted. Therefore μ is very close to the sample mean $\frac{1}{n} \sum_{i=1}^n x(i)$ (likelihood estimate). See an example in the figure below left: $\hat{\mu}_{\text{MAP}} \approx 0.48$ (posterior) is close to $\mu_{\text{ML}} = 0.5$ (likelihood).

On the other hand, if σ^2 is very large, then the sample cannot be trusted and the prior information dominates. Density function of μ becomes close to that of prior assumption. See an example in the figure below right: $\hat{\mu}_{\text{MAP}} \approx 0.04$ (posterior) is close to $\mu_{\text{PRIOR}} = 0$.



In case of maximum likelihood, the estimator is $\hat{\mu}_{\text{ML}} = \frac{1}{n} \sum_{i=1}^n x(i) = \bar{X}$. The only, but remarkable difference is the variance term in the denominator.

HARJOITUSTEHTÄVÄT 3

[pe 18.11.2011, ma 21.11.2011]

H3 / 1. (MLE-regressio)

On annettu n mittausparia $(y(i), x(i))$, $i = 1, \dots, n$ joistakin muuttujista x, y joiden välillä arvellaan olevan lineaarinen yhteyts: $y = \theta x$. Mittauksiin sisältyy kuitenkin virhettä: $y(i) = \theta x(i) + \epsilon(i)$ missä $\epsilon(i)$ on mittausvirhe ("kohina") i :nessä pisteessä. Oletetaan että mittausvirhe $\epsilon(i)$ on normaalijakautunut keskiarvolla 0 ja keskihajonnalla σ .

Ratkaise kulmakerroin θ suurimman uskottavuuden estimoinnilla.

H3 / 2. (Bayes-regressio)

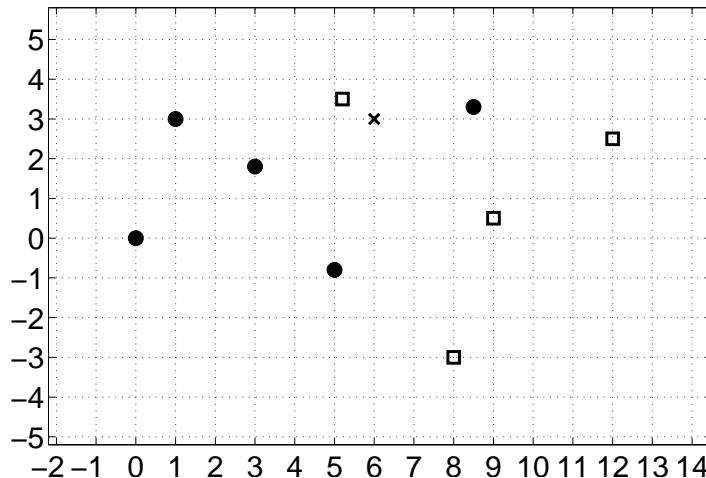
Lisätään edelliseen tehtävään etukäteistietoa:

1. Arvellaan, että kulmakerroin θ on suunnilleen 1. Mallitetaan tähän liittyvä epävarmuus olettamalla normaalinen priorijakauma jonka keskiarvo on 1 ja keskihajonta 0.5.

2. Arvellaan, että regressiosuoran ei ehkä kuitenkaan pitäisi kulkea origon kautta, jolloin se onkin muotoa $y = \alpha + \theta x$. Mittausten välinen yhteyts on silloin $y(i) = \alpha + \theta x(i) + \epsilon(i)$. Mallitetaan uuteen parametriin α liittyvä epävarmuus olettamalla että sillä on normaalinen priorijakauma jonka keskiarvo on 0 ja keskihajonta 0.1. Laske Bayes-estimaatit parametreille α, θ .

H3 / 3. (Lähimmän naapurin luokitin, k-NN)

Oheisessa kuvassa on 2 dimensiossa 2 luokkaa (ympyrät ja ruudut). Käytetään lähimmän naapurin luokitinta mihin luokkaan uusi piste $\mathbf{x} = (6, 3)$ kuuluu, kun $k = 1$ (vain lähin). Entä jos $k = 3$? Piirrä kuvaan lähimmän naapurin luokittimen (1-NN-luokittimen) rajapinta luokkien välille.

**H3 / 4. (Bayes-luokitin)**

Oletetaan kaksi luokkaa skalaarimuuttujalle x . Luokkien tiheysfunktiot $p(x|\omega_1), p(x|\omega_2)$ ovat normaalijakautuneita siten että molempien keskiarvo on 0 mutta hajonnat σ_1, σ_2 ovat erisuuret. Prioritodennäköisyydet ovat $P(\omega_1), P(\omega_2)$. Piirrä tiheysfunktiot. Mihin laittaisit luokkarajat? Johda Bayes-luokittimen luokkarajat.

H3 / Problem 1.

About regression: See lectures slides, chapter 5. A typical example of regression is to fit a polynomial curve into data $(x(j), y(j))$ with some error $\epsilon(j)$:

$$y = b_0 + b_1 x + b_2 x^2 + \dots + b_P x^P + \epsilon$$

We often assume that $\epsilon(j)$ is, e.g., Gaussian noise with zero-mean and variance σ_2 . After estimating b_k , a regression output (missing $y(j)$) can be derived for any new sample x_{new} by

$$y_{new} = b_0 + b_1 x_{new} + b_2 x_{new}^2 + \dots + b_P x_{new}^P$$

About ML: See lectures slides, chapter 5. See also H2/3 and H2/4. Given a data set $\mathbf{X} = (x(1), x(2), \dots, x(n))$ and a model of a probability density function $p(x|\theta)$ with an unknown constant parameter vector θ , maximum likelihood method ("suurimman uskottavuuden menetelmä") estimates vector $\hat{\theta}$ which maximizes the likelihood function: $\hat{\theta}_{ML} = \max_{\theta} p(\mathbf{X}|\theta)$. In other words, find the values of θ which most probably have generated data \mathbf{X} .

Normally the data vectors \mathbf{X} are considered independent so that likelihood function $L(\theta)$ is a product of individual terms $p(\mathbf{X}|\theta) = p(x(1), x(2), \dots, x(n)|\theta) = p(x(1)|\theta) \cdot p(x(2)|\theta) \cdots p(x(n)|\theta)$. Given a numerical data set \mathbf{X} , likelihood is function of only θ . Because the maximum of the likelihood $p(\mathbf{X}|\theta)$ and log-likelihood $\ln p(\mathbf{X}|\theta)$ is reached at the same value θ , log-likelihood function $L(\theta)$ is preferred for computational reasons. While $\ln(A \cdot B) = \ln A + \ln B$, we get $\ln L(\theta) = \ln p(\mathbf{X}|\theta) = \ln \prod_j p(x(j)|\theta) = \sum_j \ln p(x(j)|\theta)$.

Remember also that $p(x, y|\theta)$ can be written with conditional probabilities $p(x, y|\theta) = p(x)p(y|x, \theta)$.

In this problem the model is $y(i) = \theta x(i) + \epsilon(i)$ which implies $\epsilon(i) = y(i) - \theta x(i)$. If there were no noise ϵ , θ could be computed from a single observation $\theta = y(1)/x(1)$. However, now the error ϵ is supposed to be zero-mean Gaussian noise with standard deviation σ : $\epsilon \sim N(0, \sigma)$, that is $E(\epsilon) = 0$, $Var(\epsilon) = \sigma^2$. This results to

$$\begin{aligned} E(y(i)|x(i), \theta) &= E(\theta x(i) + \epsilon(i)) = E(\theta x(i)) + E(\epsilon(i)) = \theta x(i) \\ Var(y(i)|x(i), \theta) &= Var(\theta x(i) + \epsilon(i)) \\ &= E((\theta x(i) + \epsilon(i))^2) - (E(\theta x(i) + \epsilon(i)))^2 \\ &= E((\theta x(i))^2 + 2\theta x(i)\epsilon(i) + \epsilon(i)^2) - \overbrace{(E(\theta x(i)) + \epsilon(i))^2}^{\text{see above}} \\ &= E((\theta x(i))^2) + \overbrace{E(2\theta x(i)\epsilon(i))}^{=0 \text{ no correlation}} + E(\epsilon(i)^2) - (\theta x(i))^2 \\ &= E(\epsilon(i)^2) = Var(\epsilon(i)) = \sigma^2 \end{aligned}$$

Hence $(y(i)|x(i), \theta) \sim N(\theta x(i), \sigma)$ the density function is

$$p(y(i)|x(i), \theta) = \frac{1}{\sqrt{2\pi}\sigma} \cdot e^{-\frac{(y(i)-\theta x(i))^2}{2\sigma^2}} \quad (26)$$

The task is to maximize $p(x, y|\theta) = p(x)p(y|x, \theta)$ with respect to (w.r.t.) θ . Assuming data vectors independent we get likelihood as

$$L(\theta) = \prod_i p(x(i))p(y(i)|x(i), \theta)$$

After taking logarithm the log-likelihood function is

$$\ln L(\theta) = \text{const} + \sum_{i=1}^n \left(\ln \frac{1}{\sqrt{2\pi}\sigma} - \frac{(y(i) - \theta x(i))^2}{2\sigma^2} \right) \quad (27)$$

$$= \text{const}_2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (y(i) - \theta x(i))^2 \quad (28)$$

Maximizing $L(\theta)$ (or $\ln L(\theta)$) is equal to minimizing its opposite number:

$$\min_{\theta} \frac{1}{2\sigma^2} \sum_{i=1}^n (y(i) - \theta x(i))^2 = \min_{\theta} \frac{1}{2\sigma^2} \sum_{i=1}^n (\epsilon(i))^2$$

This equals to least squares estimation ("pienimmän neliösumman menetelmä") because of the certain properties of ϵ in this problem.

Minimum is fetched by setting the derivative w.r.t. θ to zero (the extreme point):

$$0 = \frac{\partial}{\partial \theta} \sum_{i=1}^n (y(i) - \theta x(i))^2 \quad (29)$$

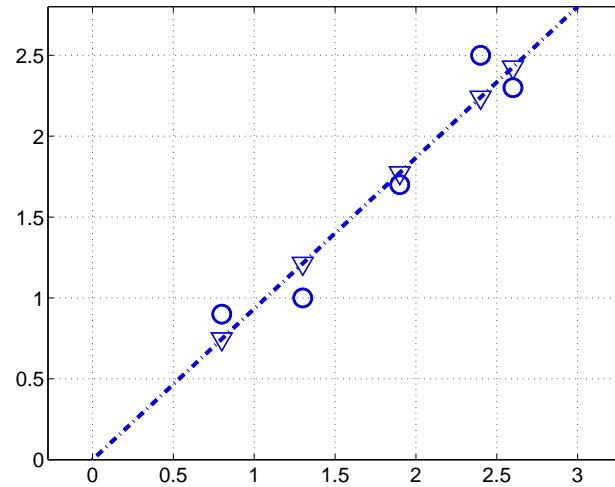
$$= \sum_{i=1}^n (2(y(i) - \theta x(i))(-x(i))) \quad (30)$$

$$= -2 \sum_{i=1}^n y(i)x(i) + 2\theta \sum_{i=1}^n (x(i))^2 \quad (31)$$

which gives finally the estimator $\hat{\theta}_{ML}$

$$\hat{\theta}_{ML} = \frac{\sum_{i=1}^n x(i)y(i)}{\sum_{i=1}^n x(i)^2} \quad (32)$$

Example. Consider dataset $\mathbf{X} = \{(0.8, 0.9)^T, (1.3, 1.0)^T, (1.9, 1.7)^T, (2.4, 2.5)^T, (2.6, 2.3)^T\}$. Now $\hat{\theta}_{ML} = 0.9334$, $f(x(i), \hat{\theta}_{ML}) = \{0.7467, 1.2134, 1.7734, 2.2401, 2.4268\}$, and $\sum_i (y(i) - f(x(i), \hat{\theta}_{ML}))^2 = 0.1580$.



H3 / Problem 2.

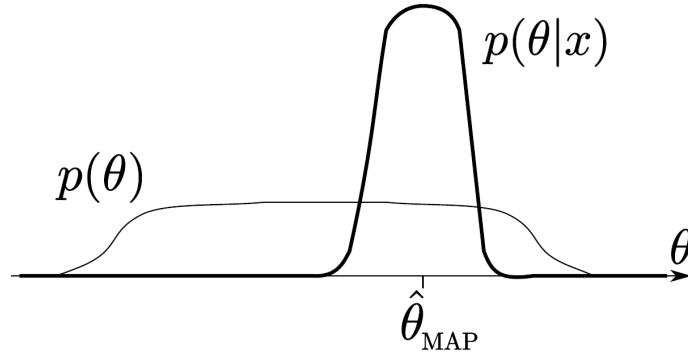
See lectures slides, chapter 5, and Problems H3/1, H2/3, and H2/4. Bayes rule is

$$p(\theta|x) = \frac{p(x|\theta)p(\theta)}{p(x)} \quad (33)$$

$$p(\text{model}|\text{data}) = \frac{p(\text{data}|\text{model})p(\text{model})}{p(\text{data})} \quad (34)$$

$$\text{posterior} \propto \text{likelihood} \times \text{prior} \quad (35)$$

The parameters are now variables with densities. Prior gives us belief what the parameters probably are before seeing any data. After seeing data (likelihood) we have more exact information about parameters.



Often only the maximum posterior estimate of θ (MAP) is computed. Taking logarithm gives $\ln p(\theta|x) = \ln p(x|\theta) + \ln p(\theta) - \ln p(x)$, and the derivative w.r.t. θ is set to zero: $\frac{\partial}{\partial \theta} \ln p(x|\theta) + \frac{\partial}{\partial \theta} \ln p(\theta) = 0$. Compared to ML-estimation (Problem 1), there is an extra term $\frac{\partial}{\partial \theta} \ln p(\theta)$.

In this problem we have also a data set \mathbf{X} and now two variables θ and α to be estimated. The model is $y(i) = \alpha + \theta x(i) + \epsilon(i)$, where $\epsilon \sim N(0, \sigma)$ as in Problem 1. Now $E(y(i)|x(i), \alpha, \theta) = \alpha + \theta x(i)$, and $Var(y(i)|x(i), \alpha, \theta) = Var(\epsilon) = \sigma^2$. Thus $y(i) \sim N(\alpha + \theta x(i), \sigma)$ and the likelihood function is

$$L(\alpha, \theta) = \prod_i p(y(i)|x(i), \alpha, \theta) = \frac{1}{\sqrt{2\pi}\sigma} \cdot e^{-\frac{(y(i)-\alpha-\theta x(i))^2}{2\sigma^2}} \quad (36)$$

$$\ln L(\alpha, \theta) = \ln \prod_i p(y(i)|x(i), \alpha, \theta) = \text{const} - \frac{1}{2\sigma^2} \sum_{i=1}^n (y(i) - \alpha - \theta x(i))^2 \quad (37)$$

Parameters have also normal density functions (“prior densities”)

$$\alpha \sim N(0, 0.1) \rightarrow p(\alpha) = \frac{1}{\sqrt{2\pi} \cdot 0.1} e^{-\frac{(\alpha-0)^2}{2 \cdot 0.1^2}} = \text{const} \cdot e^{-50\alpha^2} \quad (38)$$

$$\theta \sim N(1, 0.5) \rightarrow p(\theta) = \frac{1}{\sqrt{2\pi} \cdot 0.5} e^{-\frac{(\theta-1)^2}{2 \cdot 0.5^2}} = \text{const} \cdot e^{-2(\theta-1)^2} \quad (39)$$

In Bayes MAP-estimation the log posterior probability to be maximized is $\ln p(x, y|\alpha, \theta) + \ln p(\alpha) + \ln p(\theta)$, where the first term is the likelihood and the two latter terms prior densities:

$$\ln p(\alpha) = \text{const} - 50\alpha^2 \quad (40)$$

$$\ln p(\theta) = \text{const} - 2(\theta - 1)^2 \quad (41)$$

Hence, the task is

$$(\hat{\alpha}, \hat{\theta}) = \arg \max_{\alpha, \theta} \left\{ \left(-\frac{1}{2\sigma^2} \sum_{i=1}^n [(y(i) - \alpha - \theta x(i))^2] - 50\alpha^2 - 2(\theta - 1)^2 \right) \right\} \quad (42)$$

First, maximize w.r.t. α ,

$$0 = \frac{\partial}{\partial \alpha} \left(-\frac{1}{2\sigma^2} \sum_{i=1}^n [(y(i) - \alpha - \theta x(i))^2] - 50\alpha^2 - 2(\theta - 1)^2 \right) \quad (43)$$

$$= \left(-\frac{1}{2\sigma^2} \right) \sum_i [2 \cdot (y(i) - \alpha - \theta x(i)) \cdot (-1)] - 100\alpha \quad (44)$$

$$= \sum_i y(i) - n\alpha - \theta \sum_i x(i) - 100\sigma^2\alpha \quad (45)$$

$$\hat{\alpha}_{MAP} = \frac{\sum_i y(i) - \theta \sum_i x(i)}{n + 100\sigma^2} \quad (46)$$

and similarly θ , using previous result of α ,

$$0 = \frac{\partial}{\partial \theta} \left(-\frac{1}{2\sigma^2} \right) \sum_{i=1}^n [(y(i) - \alpha - \theta x(i))^2] - 50\alpha^2 - 2(\theta - 1)^2 \quad (47)$$

$$= \left(-\frac{1}{2\sigma^2} \right) \sum_i [2 \cdot (y(i) - \alpha - \theta x(i)) \cdot (-x(i))] - 4(\theta - 1) \quad (48)$$

$$= \sum_i [y(i)x(i) - \alpha x(i) - \theta x(i)^2] - 4\sigma^2(\theta - 1) \quad | \quad \alpha \leftarrow \hat{\alpha}_{MAP} \quad (49)$$

$$= \sum_i y(i)x(i) - \left(\frac{\sum_i y(i) - \theta \sum_i x(i)}{n + 100\sigma^2} \right) \sum_i x(i) - \theta \sum_i x(i)^2 - 4\sigma^2\theta + 4\sigma^2 \quad (50)$$

$$\hat{\theta}_{MAP} = \frac{\sum_i y(i)x(i) - \frac{(\sum_i y(i))(\sum_i x(i))}{n + 100\sigma^2} + 4\sigma^2}{\sum_i x(i)^2 - \frac{(\sum_i x(i))^2}{n + 100\sigma^2} + 4\sigma^2} \quad (51)$$

Some interpretations of the results. If $\sigma^2 = 0$:

$$\theta = \frac{\sum_i y(i)x(i) - \frac{(\sum_i y(i))(\sum_i x(i))}{n}}{\sum_i x(i)^2 - \frac{(\sum_i x(i))^2}{n}} \quad (52)$$

$$= (1/n) \cdot \frac{\sum_i y(i)x(i) - ((1/n) \cdot (\sum_i y(i)))((1/n) \cdot (\sum_i x(i)))}{(1/n) \cdot \sum_i x(i)^2 - ((1/n) \sum_i x(i))^2} \quad (53)$$

$$= \frac{E(YX) - E(Y)E(X)}{E(X^2) - (E(X))^2} \quad (54)$$

$$= \frac{Cov(X, Y)}{Var(X)} \quad (55)$$

$$\alpha = (1/n) \sum_i y(i) - \theta(1/n) \sum_i x(i) \quad (56)$$

$$= E(Y) - \theta E(X) \quad (57)$$

which are also the estimates of PNS method as well as by least squares.

If $\sigma^2 \rightarrow \infty$:

$$\theta \rightarrow 4/4 = 1 \quad (58)$$

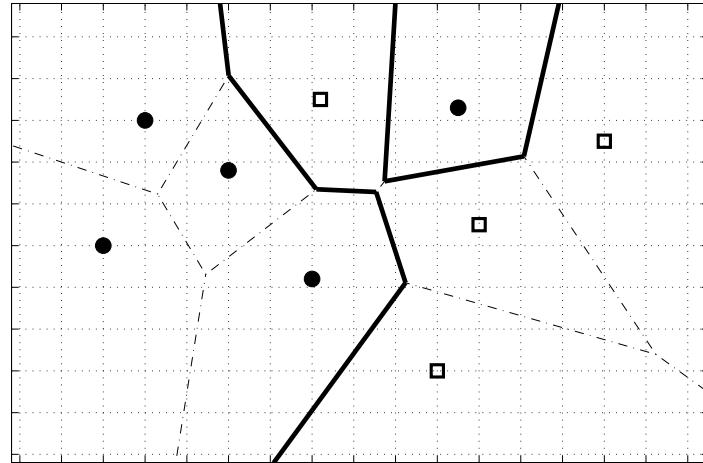
$$\alpha = \frac{\sum_i y(i) - \theta \sum_i x(i)}{n + 100\sigma^2} \quad (59)$$

$$\rightarrow 0 \quad (60)$$

then it is better to believe in the prior information.

H3 / Problem 3.

Using Euclidean distance $d(\mathbf{a}, \mathbf{b}) = \sqrt{(a_1 - b_1)^2 + (a_2 - b_2)^2}$ (taking square root not necessary) we get (a) 1-NN: closest neighbour is square, \mathbf{x} is classified as a square, (b) 3-NN: three closest: square, circle, circle, \mathbf{x} is classified as a circle. See also T3 computer session. 1-NN border plotted with a thick line:

**H3 / Problem 4.**

Bayes rule

$$p(\omega|x) = \frac{p(x|\omega)p(\omega)}{p(x)}$$

Classification rule: when having observation x , choose class ω_1 if

$$p(\omega_1|x) > p(\omega_2|x) \Leftrightarrow \frac{p(x|\omega_1)p(\omega_1)}{p(x)} > \frac{p(x|\omega_2)p(\omega_2)}{p(x)} \Leftrightarrow p(x|\omega_1)p(\omega_1) > p(x|\omega_2)p(\omega_2)$$

Now the both data follow the normal distribution $x|\omega_1 \sim N(0, \sigma_1^2)$ and $x|\omega_2 \sim N(0, \sigma_2^2)$. Assume that $\sigma_1^2 > \sigma_2^2$. The density function of a normal distribution with mean μ and variance σ^2 is

$$p(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

Now the rule is

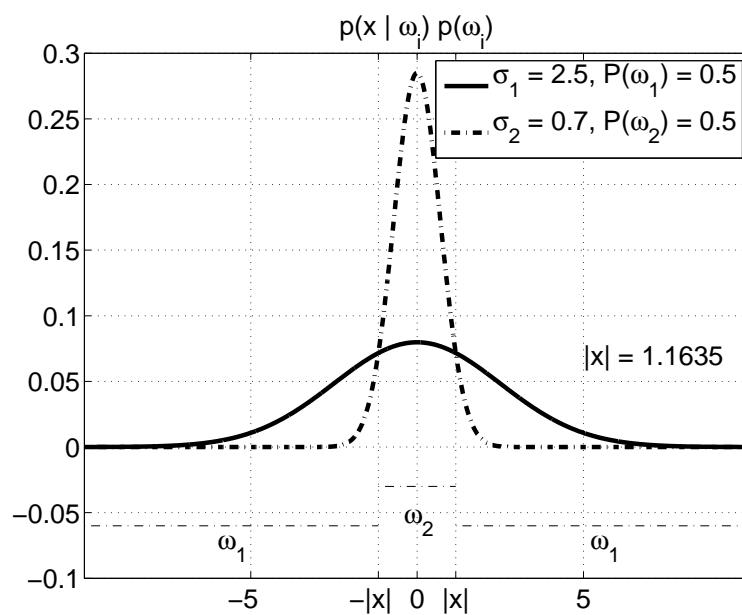
$$\frac{1}{\sqrt{2\pi\sigma_1^2}} e^{-\frac{x^2}{2\sigma_1^2}} p(\omega_1) > \frac{1}{\sqrt{2\pi\sigma_2^2}} e^{-\frac{x^2}{2\sigma_2^2}} p(\omega_2) \quad (61)$$

$$\frac{e^{-\frac{x^2}{2\sigma_1^2}}}{e^{-\frac{x^2}{2\sigma_2^2}}} > \frac{\sigma_1}{\sigma_2} \frac{p(\omega_2)}{p(\omega_1)} \quad | \quad \ln \text{ on both sides} \quad (62)$$

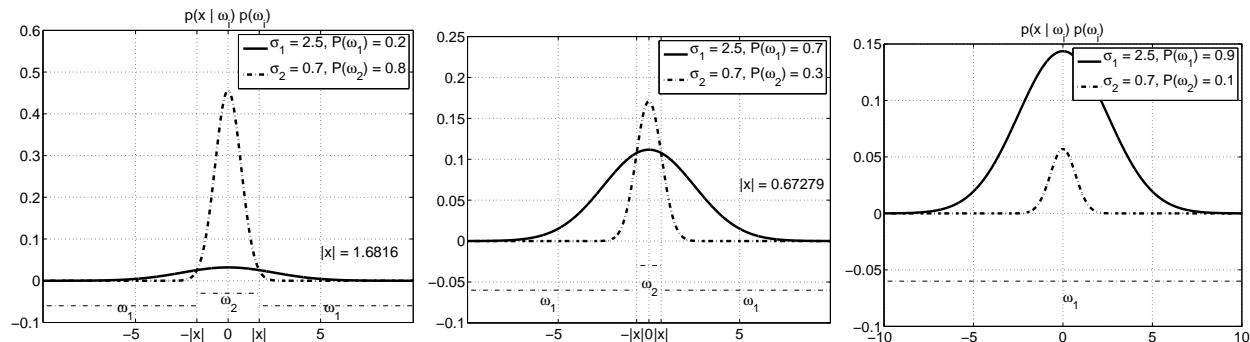
$$\left(\frac{1}{2\sigma_2^2} - \frac{1}{2\sigma_1^2} \right) x^2 > \ln \left(\frac{\sigma_1}{\sigma_2} \frac{p(\omega_2)}{p(\omega_1)} \right) \quad (63)$$

$$x^2 > \frac{2 \ln \left(\frac{\sigma_1}{\sigma_2} \frac{p(\omega_2)}{p(\omega_1)} \right)}{\left(\frac{1}{\sigma_2^2} - \frac{1}{\sigma_1^2} \right)} \quad (64)$$

In the figure below the density functions and class borders when using sample values $\sigma_1 = 2.5$, $\sigma_2 = 0.7$, $P(\omega_1) = 0.5$, and $P(\omega_2) = 0.5$, yielding $x^2 > 1.3536$ and decision borders $|x| = 1.1635$. E.g., if we are given a data point $x = 2$, we choose the class ω_1 .



However, if the class probabilities $P(\omega_i)$ differ, then the optimal border changes. Below there are three other examples. Assume that only 20% / 70% / 90% of samples are from class ω_1 , i.e., $P(\omega_1) = \{0.2, 0.7, 0.9\}$ and $P(\omega_2) = \{0.8, 0.3, 0.1\}$. In the last case data samples from class 2 are so rare that the classifier chooses always class 1.



HARJOITUSTEHTÄVÄT 4

[pe 25.11.2011, ma 28.11.2011]

H4 / 1. (Ryhmittelyanalyysi)

On annettuna n vektoria. Monellako tapaa ne voi jakaa kahteen ryhmään? Ratkaise ainakin tapaukset $n = 2, 3, 4, 5$.

H4 / 2. (Ryhmittelyanalyysi)

On annettuna seuraava datamatriisi:

$$\mathbf{X} = \begin{bmatrix} 0 & 1 & 2.5 & 3 & 3 & 5 \\ 0 & 1 & 2.5 & 2 & 4 & 3 \end{bmatrix}$$

a) Piirrä datavektorit tasoon.

b) Tee vektoreille hierarkinen ryhmittely kuvan avulla. Käytä ryhmien etäisyytenä pienintä niihin kuuluvien vektorien etäisyyttä. Piirrä ryhmittelypuu. Mikä on paras ryhmittely kolmeen ryhmään?

H4 / 3. (Ryhmittelyanalyysi)

On annettuna kolme vektoria $\mathbf{x}, \mathbf{z}_1, \mathbf{z}_2$. Aluksi $C_1 = \{\mathbf{x}\}$, $C_2 = \{\mathbf{z}_1, \mathbf{z}_2\}$.

a) Laske ryhmien C_1, C_2 keskipisteet $\mathbf{m}_1, \mathbf{m}_2$.

b) Ilmenee että $\|\mathbf{z}_1 - \mathbf{m}_1\| < \|\mathbf{z}_1 - \mathbf{m}_2\|$ ja siten c-means-algoritmissa vektori \mathbf{z}_1 siirtyy ryhmästä C_2 ryhmään C_1 .

Merkitätään uusia ryhmiä $C'_1 = \{\mathbf{x}, \mathbf{z}_1\}$, $C'_2 = \{\mathbf{z}_2\}$. Laske uudet keskipisteet $\mathbf{m}'_1, \mathbf{m}'_2$.

c) Todista että

$$\sum_{\mathbf{x} \in C_1} \|\mathbf{x} - \mathbf{m}_1\|^2 + \sum_{\mathbf{x} \in C_2} \|\mathbf{x} - \mathbf{m}_2\|^2 > \sum_{\mathbf{x} \in C'_1} \|\mathbf{x} - \mathbf{m}'_1\|^2 + \sum_{\mathbf{x} \in C'_2} \|\mathbf{x} - \mathbf{m}'_2\|^2$$

eli c-means-ryhmittelyn kriteeri J pienenee.

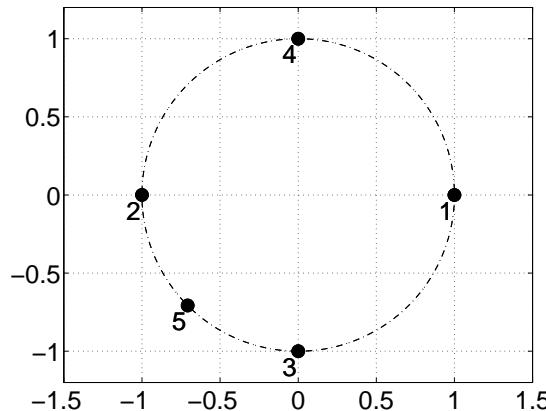
H4 / 4. (SOM)

Tarkastellaan SOM-algoritmin laskennallista vaativuutta. Olkoon kartan koko $N \times N$ yksikköä (neuronia), ja syöte-ja painovektoreiden dimensio olkoon d . Montako kerto- ja yhteenlaskua tarvitaan, kun syötevektorille \mathbf{x} etsitään voittajaneuronin käyttäen euklidista etäisyyttä painovektoriin?

H4 / 5. (SOM)

Oletetaan tässä, että SOM-kartan painovektorit \mathbf{m}_i ja syötteet \mathbf{x} sijaitsevat yksikköympyrällä (ovat 2-dimensioisia yksikkövektoreita). Kartta on 1-ulotteinen 5 yksikön kartta, jonka painovektorit alkutilanteessa on näytetty alla olevassa kuvassa. Naapurusto määritellään nyt syklisesti niin, että yksiköiden $b = 2, 3, 4$ naapurit ovat $b-1, b+1$, yksikön 5 naapurit ovat 4 ja 1 sekä yksikön 1 naapurit ovat 5 ja 2.

Opetuksessa kerroin $\alpha = 0.5$, eli kullakin askelleella voittajayksikön ja sen naapureiden painovektorit siirtyvät ympyränkehää pitkin puoleenväliin kohti pistettä \mathbf{x} . Syötevektorit voi valita vapaasti yksikköympyrältä. Valitse jono syötevektoreita niin, että painovektorit tulevat järjestykseen.



H4 / Problem 1.

Case $n = 2$. There are two vectors $\{1, 2\}$. Only one possibility,

$$C_1 = \{1\}, C_2 = \{2\}$$

Case $n = 3$. There are three vectors $\{1, 2, 3\}$. There are three possible groupings,

$$C_1 = \{1\}, C_2 = \{2, 3\}, \text{ or}$$

$$C_1 = \{2\}, C_2 = \{1, 3\}, \text{ or}$$

$$C_1 = \{3\}, C_2 = \{1, 2\}.$$

Case $n = 4$. There are four vectors $\{1, 2, 3, 4\}$. There are seven possible groupings,

$$C_1 = \{1\}, C_2 = \{2, 3, 4\}, \text{ or}$$

$$C_1 = \{2\}, C_2 = \{1, 3, 4\}, \text{ or}$$

$$C_1 = \{3\}, C_2 = \{1, 2, 4\}, \text{ or}$$

$$C_1 = \{4\}, C_2 = \{1, 2, 3\}, \text{ or}$$

$$C_1 = \{1, 2\}, C_2 = \{3, 4\}, \text{ or}$$

$$C_1 = \{1, 3\}, C_2 = \{2, 4\}, \text{ or}$$

$$C_1 = \{1, 4\}, C_2 = \{2, 3\}.$$

For $n = 5$ there are $5 + 4 + 3 + 2 + 1 = 15$ possible groupings. It seems that the number of groupings for n points is $2^{n-1} - 1$.

Let us prove that the number is $2^{n-1} - 1$. Take a binary vector of length n such that its i -th element

$$b_i = \begin{cases} 0, & \text{if } i\text{-th point is first cluster} \\ 1, & \text{if } i\text{-th point is second cluster} \end{cases}$$

All possible combinations are allowed except $b_i = 0$ for all i , $b_i = 1$ for all i , because then there is only one cluster. Thus the number is $2^n - 2$ (there are 2^n different binary vectors of length n).

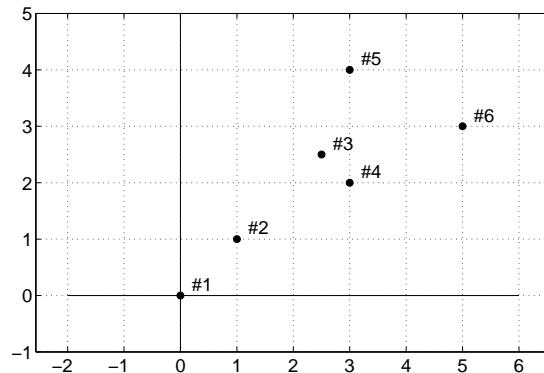
But one half are equivalent to the other half because “first” and “second” cluster can be changed (consider case $n = 2$).

The final number is $\frac{1}{2}(2^n - 2) = 2^{n-1} - 1$.

H4 / Problem 2.

See also c-means clustering and hierarchical clustering examples in computer session T4.

Here we use hierarchical clustering and a dendrogram (“ryhmittelypuu”). Clusters are combined using the nearest distance (often “single linkage”). In the beginning each data point is a cluster. Then clusters are combined one by one, and a dendrogram is drawn. When all clusters are combined to one single cluster and the dendrogram is ready, one can choose where to cut the dendrogram.



In the beginning there are six clusters

$$\{1\}, \{2\}, \{3\}, \{4\}, \{5\}, \{6\}$$

Items 3 and 4 are nearest and combined

$$\{1\}, \{2\}, \{3, 4\}, \{5\}, \{6\}$$

Then the nearest clusters are 1 and 2

$$\{1, 2\}, \{3, 4\}, \{5\}, \{6\}$$

Next, 5 is connected to the cluster {3, 4}, because the distance from 5 to 3 (nearest) is smallest

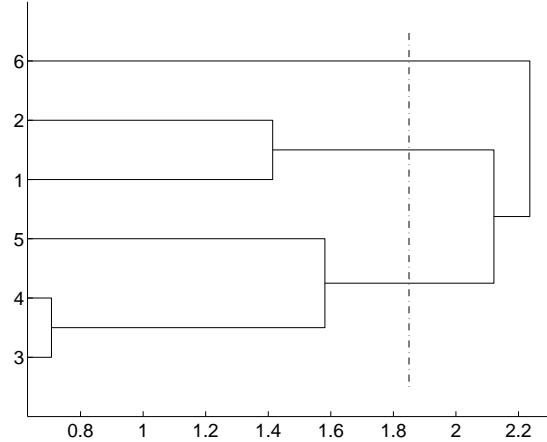
$$\{1, 2\}, \{3, 4, 5\}, \{6\}$$

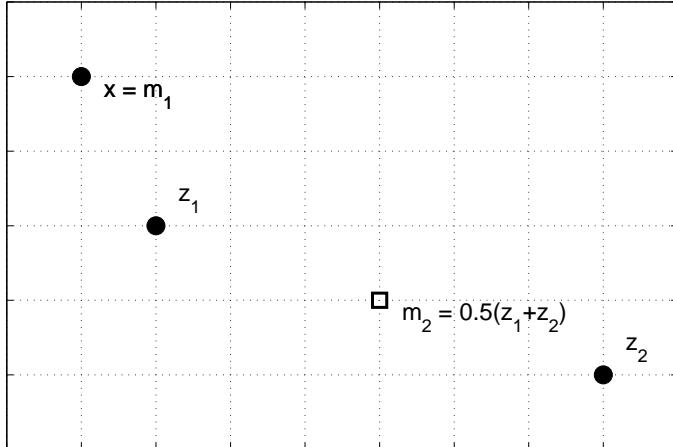
Note that distance between 2 and 3 is smaller than of 6 to 4 or 5, and therefore

$$\{1, 2, 3, 4, 5\}, \{6\}$$

The algorithm ends when all points/clusters are combined to one big cluster.

The result can be visualized using the dendrogram, see the figure below. The x-axis gives the distance of the combined clusters. The best choice for three clusters is {1, 2}, {3, 4, 5}, {6}.



H4 / Problem 3.

Now $\|\mathbf{z}_1 - \mathbf{m}_1\| < \|\mathbf{z}_1 - \mathbf{m}_2\|$ and so \mathbf{z} moves together with \mathbf{x} . New centers are:

$$\mathbf{m}'_1 = 0.5(\mathbf{x} + \mathbf{z}_1), \quad \mathbf{m}'_2 = \mathbf{z}_2$$

$$\begin{aligned} J^{OLD} &= \|\mathbf{z}_1 - \mathbf{m}_2\|^2 + \|\mathbf{z}_2 - \mathbf{m}_2\|^2 + \underbrace{\|\mathbf{x} - \mathbf{m}_1\|^2}_0 \\ &= \|\mathbf{z}_1 - 0.5(\mathbf{z}_1 + \mathbf{z}_2)\|^2 + \|\mathbf{z}_2 - 0.5(\mathbf{z}_1 + \mathbf{z}_2)\|^2 \\ &= 0.25\|\mathbf{z}_1 - \mathbf{z}_2\|^2 + 0.25\|\mathbf{z}_1 - \mathbf{z}_2\|^2 \\ &= 0.5\|\mathbf{z}_1 - \mathbf{z}_2\|^2 \\ J^{NEW} &= \|\mathbf{z}_1 - \mathbf{m}'_1\|^2 + \underbrace{\|\mathbf{z}_2 - \mathbf{m}'_2\|^2}_0 + \|\mathbf{x} - \mathbf{m}'_1\|^2 \\ &= 0.5\|\mathbf{x} - \mathbf{z}_1\|^2 \end{aligned}$$

Now we remember that $\|\mathbf{z}_1 - \mathbf{m}_1\|^2 < \|\mathbf{z}_1 - \mathbf{m}_2\|^2$ (that is why \mathbf{z}_1 moved to the other cluster).

$$\Rightarrow \|\mathbf{z}_1 - \underbrace{\mathbf{x}}_{\mathbf{m}_1}\|^2 < \|\mathbf{z}_1 - \underbrace{0.5(\mathbf{z}_1 + \mathbf{z}_2)}_{\mathbf{m}_2}\|^2 = 0.25\|\mathbf{z}_1 - \mathbf{z}_2\|^2$$

So,

$$J^{NEW} = 0.5\|\mathbf{x} - \mathbf{z}_1\|^2 < 0.5 \cdot 0.25\|\mathbf{z}_1 - \mathbf{z}_2\|^2 < 0.5\|\mathbf{z}_1 - \mathbf{z}_2\|^2 = J^{OLD}$$

H4 / Problem 4.

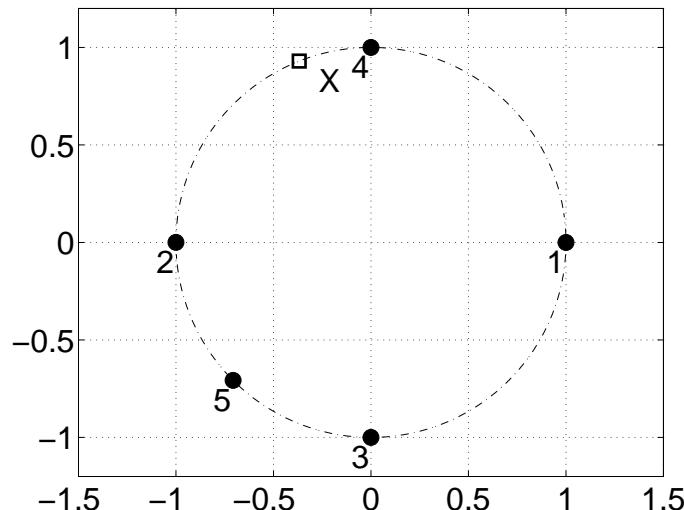
Number of neurons is N^2 . For each neuron j , we have to compute

$$\sum_{i=1}^d (x_i - m_{ij})^2$$

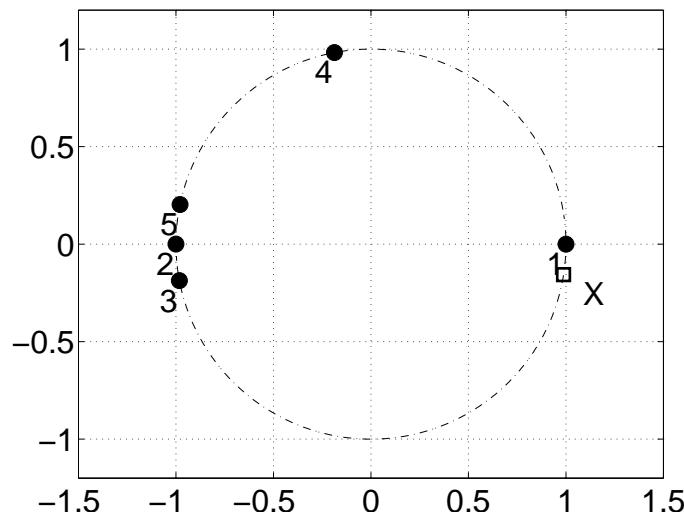
which takes d subtractions, d multiplications, $d - 1$ additions. This means totally $N^2(2d - 1)$ additions (subtraction and addition are usually equivalent) and N^2d multiplications.

H4 / Problem 5.

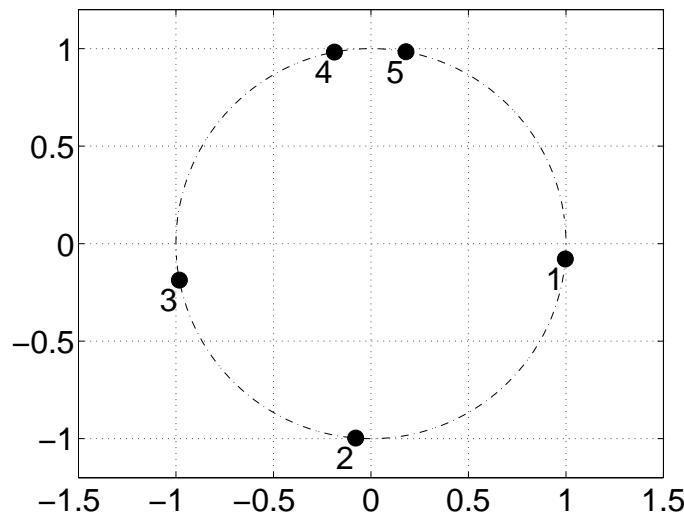
Choose x so that its angle is a little less than 135° .



Now best matching unit (BMU): 4, neighbours: 5 and 3. They move on the circle half-way towards x .



Now choose x so that its angle is very small negative. BMU: 1, neighbours: 5 and 2. They are moving closer to x along unit circle. 5 jumps over 4, and 2 jumps over 3. Now 1D SOM is in order: 1, 2, 3, 4, 5.



HARJOITUSTEHTÄVÄT 5

[pe 2.12.2011, ma 5.12.2011]

H5 / 1. (Kattavat joukot)

Tarkastellaan 0-1 -havaintojoukkoa

<i>a</i>	0	1	1	1	1	0	0	1	1	1
<i>b</i>	1	1	0	1	0	1	1	0	0	1
<i>c</i>	0	0	0	1	1	1	1	1	1	1
<i>d</i>	1	1	0	1	1	1	1	0	0	1

Tässä siis muuttujat ovat *a*, *b*, *c*, *d* ja havaintoja on 10. Etsi kattavat muuttuja{joukot}, kun kynnysarvo $N = 4$.**H5 / 2. (Tasoittainen algoritmi)**

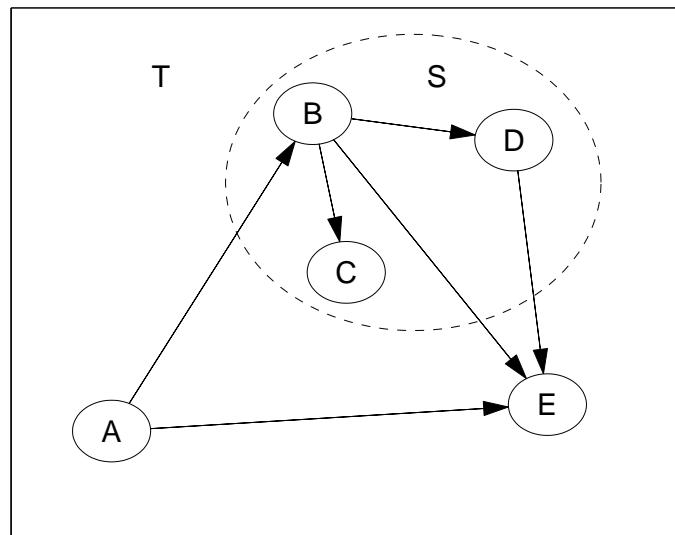
Mikä on tasoittaisen algoritmin aikavaativuus data koon ja tarkasteltavien ehdokasjoukkojen määrän funktiona?

H5 / 3. (Tšernovin raja)

Tutki luennolla mainittua Tšernovin (Chernoff) rajaa. Miten raja käyttäätyy eri parametrien funktiona?

H5 / 4. (Keskukset ja auktoriteetit)

Tutkitaan alla olevan kuvan mukaista webbisivujen, $s = 1, 2, 3, 4, 5$ (nimet 'A', 'B', 'C', 'D', 'E'), linkkien suunnattua verkkoa. Käytä luennolla esitettyä keskusten ja auktoriteettien algoritmia etsimään aineiston hyviä keskuksia ("hubs") ja auktoriteetteja ("authorities"). Alusta kaikkien webbisivujen keskuspainoiksi $k_s = 1/\sqrt{5} \approx 0.447$ ja auktoriteettipainoiksi $a_s = 1/\sqrt{5} \approx 0.447$. Tämän jälkeen iteroi painoja, kunnes muutos on vähäistä. Tulkitse saatua tulosta.



H5 / Problem 1.

Simulate the levelwise algorithm. In the first phase the candidates are all sets of one variable $\{a\}$, $\{b\}$, $\{c\}$ ja $\{d\}$. To be more convenient, we will omit all $\{$ and $\}$ from now on, and write all sets simply a , b , c , and d . The frequencies of these

$$\begin{array}{cccc} a & b & c & d \\ 7 & 6 & 7 & 7. \end{array}$$

Frequencies of all sets are equal or more than the threshold, so all sets are frequent. Now the following level candidates are all sets of two variables (again $ab = \{a, b\}$ and so on):

$$\begin{array}{ccccccc} ab & ac & ad & bc & bd & cd \\ 3 & 5 & 4 & 4 & 6 & 5. \end{array}$$

All sets except ab are frequent. The candidates of 3-size sets are

$$\begin{array}{cc} acd & bcd \\ 3 & 4. \end{array}$$

Here only bcd is frequent. Therefore any larger set (in this case $abcd$) cannot be frequent and algorithm stops.

The frequent itemsets are a , b , c , d , ac , ad , bc , bd , cd , and bcd . (Often the empty set is also considered to be a frequent set.)

You can consider, e.g., observations as bags (customers), and variables as products in a supermarket, for example, a is for apples, b is for bread, c is for cheese, and d is for soda. In the 0-1-matrix each 1 means that the particular item is found in the shopping bag. The first customer has bought bread and soda, the last tenth customer all four products.

H5 / Problem 2.

When computing time complexities of algorithms it is interesting to see the asymptotic behavior of algorithms, that is, when the size of input grows to infinity. In this case time complexity is examined as a function of both input size and number of candidates. The latter connection is more difficult to explain. If the number of candidates were not taken into account, the worst case would be trivially that where the data contains only 1s. In that case all possible variables sets would become candidates, that is exponential case.

The levelwise algorithm shown in the lectures is written with pseudocode below. Let us call the size of data (number of observations) with m , and the number of all processed candidate sets with n . Candidate sets with k size candidate is marked C_k . Let t be the biggest value of k , i.e., the maximum size of candidates. Clearly, $n = \sum_{k=1}^t |C_k|$ and $k \leq t = O(\ln n)$.

While-loop in row 3 is executed t times. At one execution for-loop in row 5 is executed m times, and at one execution step of that for-loop in row 6 is executed $|C_k|$ times. Totally, this for-loop is executed mn times. At one execution the for-loop in row 8 is computed k times, and those operations can be considered as taking a constant time. As well the if-statement in row 11 takes a constant time. Hence, the time complexity of the for-loop in row 5 is $O(mn \ln n)$.

```

1:  $k \leftarrow 1$ 
2:  $C_k \leftarrow \{ \{ a \} \mid a \in \text{variables} \}$ 
3: while  $C_k \neq \emptyset$  do
4:   counter[X]  $\leftarrow 0$  for all  $X$ 
5:   for observation in data do                                ▷ Count frequencies of candidates
6:     for  $X$  in  $C_k$  do                                     ▷ Check if all variables in  $X$  are present
7:       good  $\leftarrow$  True
8:       for var in  $X$  do
9:         if observation[var] = 0 then
10:          good  $\leftarrow$  False
11:        if good then
12:          counter[X]  $\leftarrow$  counter[X] + 1
13:  $F_k \leftarrow \emptyset$ 
14: for  $X$  in  $C_k$  do                                         ▷ Select frequent candidates
15:   if counter[X]  $\geq N$  then
16:      $F_k \leftarrow F_k \cup \{ X \}$ 
17:  $C_{k+1} \leftarrow \emptyset$ 
18: for  $A$  in  $F_k$  do                                         ▷ Generate next candidates
19:   for  $B$  in  $F_k$  do
20:      $X \leftarrow A \cup B$ 
21:     if  $|X| = k + 1$  then
22:       good  $\leftarrow$  True
23:       for var in  $X$  do
24:         if  $X \setminus \{ \text{var} \}$  not in  $F_k$  then
25:           good  $\leftarrow$  False
26:         if good then
27:            $C_{k+1} \leftarrow C_{k+1} \cup \{ X \}$ 
28:  $k \leftarrow k + 1$ 

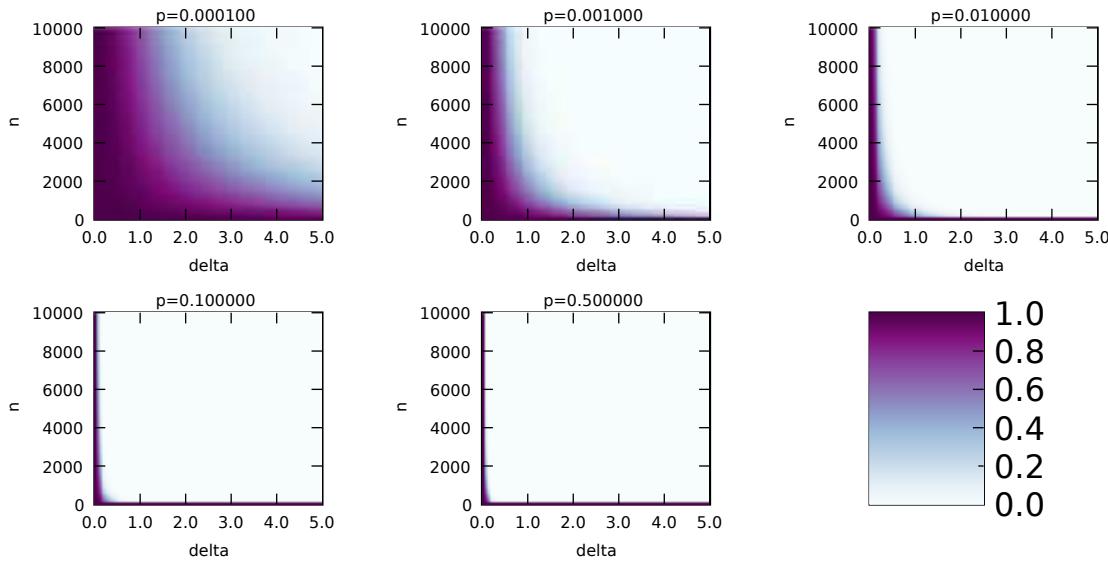
```

The for-loop in row 14 is executed n times and the lines inside it have constant times. The time complexity for rows 13–17 is $O(n)$, and because $n = O(mn \ln n)$, it has not asymptotical meaning.

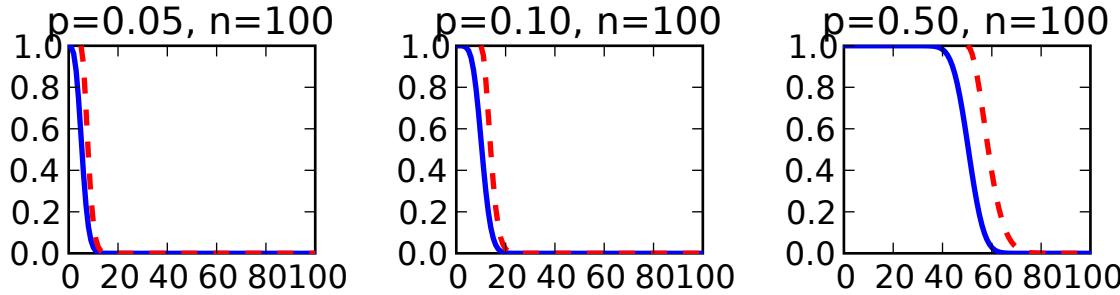
For-loops in rows 18 and 19 are executed totally $t|F_k|^2 \leq t|C_k|^2 = O(n^2 \ln n)$ times. The statement in row 20 takes at most $O(2k) = O(\ln n)$. The for-loop in row 23 is executed $k + 1 = O(\ln n)$ times, and the lines inside it as constants (F_k can be implemented with hash tables where testing is practically constant-time). The for-loop in row 18 is therefore $O(n^2(\ln n)^2)$. Because $mn \ln n$ and $n^2(\ln n)^2$ are not asymptotically comparable, the whole time complexity of the algorithm is $O(mn \ln n + n^2(\ln n)^2)$.

H5 / Problem 3.

The following figures show the behavior of the border.



The distance of the border and true probability can be examined with small enough values of n . In the following the solid curve depicts the probability $\Pr(X \geq x)$ and dashed line Tšernov border:



Tšernov border can be shown quite easily. Consider *Markov's inequality*, which deals non-negative random variables X and for which

$$\Pr(X \geq a) \leq \frac{E[X]}{a}.$$

In this case it is needed for discrete random variables. Let possible values of X be $x_1 < x_2 < \dots$. Let x_j be the biggest of those values, which is smaller than a . Then

$$\begin{aligned} E[x] &= \sum_{i=1}^{\infty} x_i \Pr(X = x_i) \geq \sum_{i=j+1}^{\infty} x_i \Pr(X = x_i) \\ &\geq a \sum_{i=j+1}^{\infty} \Pr(X = x_i) = a \Pr(X \geq x_{j+1}) = a \Pr(X \geq a). \end{aligned}$$

The other needed result is the inequality $1 + x \leq e^x$, which hold for all real values x and can be seen true by examining the function $f(x) = e^x - x - 1$: because $f''(x) = e^x > 0$ and $f'(0) = 0$, $f(x) \geq f(0) = 0$ for all x .

Let Y_1, Y_2, \dots, Y_n be independent random variables, where each gets the value 1 with probability p and the value 0 with probability $1 - p$, and let $X = \sum_{i=1}^n Y_i$. Let $t \geq 0$. Now using Markov's inequality

$$\Pr(X \geq (1 + \delta)np) \leq \Pr(e^{tX} \geq e^{t(1+\delta)np}) \leq e^{-t(1+\delta)np} E[e^{tX}].$$

For the expectation of variable e^{tX} holds (independence)

$$E[e^{tX}] = E[e^{t(Y_1 + \dots + Y_n)}] = E[e^{tY_1} \dots e^{tY_n}] = E[e^{tY_1}]^n.$$

Using the definition of expectation and the inequality proved above, we get

$$E[e^{tY_1}] = pe^t + (1 - p) = 1 + p(e^t - 1) \leq e^{p(e^t - 1)}.$$

By choosing $t = \ln(1 + \delta)$ we get

$$\Pr(X \geq (1 + \delta)np) \leq e^{-\ln(1+\delta)(1+\delta)np} e^{p(1+\delta-1)n} = (1 + \delta)^{-(1+\delta)np} e^{\delta np} = \left(\frac{e^\delta}{(1 + \delta)^{1+\delta}} \right)^{np}.$$

H5 / Problem 4.

Hubs and authorities algorithm for finding relevant web pages. The main idea is that a good hub points to good authorities and there are links coming to good authorities from good hubs. The “circular statement” is solved with iteration. The algorithm:

1. Find pages with requested key words
2. Choose best N pages (heuristically); name this set as S
3. Create a set T so that it includes all pages of S , all pages that point to any page of S , and all pages that are pointed from any page of S
4. Create a set of arcs E : $(u, v) \in E$ when there is a link from page u to page v .
5. Assign a hub weight k_s and an authority weight a_s for each page $s \in T$
6. Initialize all weights $a_s = k_s = 1/\sqrt{n}$ where $n = |T|$
7. Iteratively update the weights until the change is small

(a) sum

$$k_s \leftarrow \sum_{t \in T, (s,t) \in E} a_t, \quad a_s \leftarrow \sum_{t \in T, (t,s) \in E} k_t$$

(b) scale to unity so that $\sum_s a_s^2 = 1$ and $\sum_s k_s^2 = 1$ \square

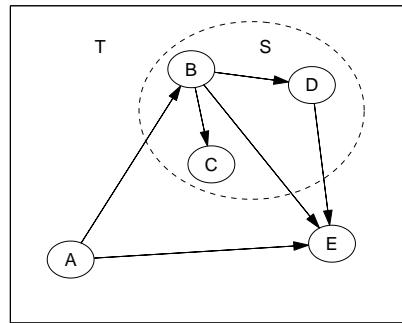
The weights can be thought as vectors $\mathbf{a} = [a_1 \ a_2 \ \dots \ a_n]^T$ and $\mathbf{k} = [k_1 \ k_2 \ \dots \ k_n]^T$ and the graph and its arcs E as a square matrix M of size $(n \times n)$ where $M(s, t) = 1$ if $(s, t) \in E$. Now the final step iterations can be written as

$$\mathbf{a} \leftarrow M^T \mathbf{k}, \quad \mathbf{k} \leftarrow M \mathbf{a}$$

and the scaling as

$$\mathbf{a} \leftarrow \mathbf{a}/\|\mathbf{a}\|, \quad \mathbf{k} \leftarrow \mathbf{k}/\|\mathbf{k}\|$$

In this problem we have five webpages 'A', 'B', 'C', 'D', 'E', with indices $s = 1, 2, 3, 4, 5$, which have links (e.g., ``).



Read carefully what is written in Step 7: $k_s \leftarrow \sum_{t \in T, (s,t) \in E} a_t$. For instance, when computing k_s for node $s = 'B'$ we pick from all values a_t ($T \in \{'A', 'B', 'C', 'D', 'E'\}$) only those there is an arc (s, t) ($E \in \{\{ 'B' \rightarrow 'C' \}, \{ 'B' \rightarrow 'D' \}, \{ 'B' \rightarrow 'E' \}\}$). Therefore $k_B = a_C + a_D + a_E$.

We can write the data matrix M of size $(n \times n)$ (having 1s in the diagonal):

$$M = \begin{bmatrix} 0 & 1 & 0 & 0 & 1 \\ 0 & 0 & 1 & 1 & 1 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix}$$

Assign weights a_s (authority) and k_s (hub) for each page s , and write them as vectors \mathbf{a} and \mathbf{k} . Initialize them so that $\sum_s a_s^2 = 1$ and $\sum_s k_s^2 = 1$.

$$\mathbf{a} = \frac{1}{\sqrt{5}} \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \\ 1 \end{bmatrix} \quad \mathbf{k} = \frac{1}{\sqrt{5}} \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \\ 1 \end{bmatrix}$$

Iteration (as long as needed) can be done by

$$\mathbf{a}_{new} = M^T \mathbf{k} \Leftrightarrow \mathbf{a}_{new}^T = \mathbf{k}^T M , \quad \mathbf{a} \leftarrow \mathbf{a}_{new} / \sqrt{\sum_s a_{new,s}^2}$$

$$\mathbf{k}_{new} = M \mathbf{a} , \quad \mathbf{k} \leftarrow \mathbf{k}_{new} / \sqrt{\sum_s k_{new,s}^2}$$

1st round:

$$\mathbf{a}_{new}^T \approx [0.447 \ 0.447 \ 0.447 \ 0.447 \ 0.447] \cdot \begin{bmatrix} 0 & 1 & 0 & 0 & 1 \\ 0 & 0 & 1 & 1 & 1 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix} = [0 \ 0.447 \ 0.447 \ 0.447 \ 1.342]$$

$$\mathbf{k}_{new} \approx \begin{bmatrix} 0 & 1 & 0 & 0 & 1 \\ 0 & 0 & 1 & 1 & 1 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix} \cdot \begin{bmatrix} 0.447 \\ 0.447 \\ 0.447 \\ 0.447 \\ 0.447 \end{bmatrix} = \begin{bmatrix} 0.894 \\ 1.342 \\ 0 \\ 0.447 \\ 0 \end{bmatrix}$$

$$\mathbf{a} \approx \mathbf{a}_{new} / \sqrt{0 + 0.447^2 + 0.447^2 + 0.447^2 + 1.342^2} \approx \begin{bmatrix} 0 \\ 0.289 \\ 0.289 \\ 0.289 \\ 0.867 \end{bmatrix}$$

$$\mathbf{k} \approx \mathbf{k}_{new} / \sqrt{0.894^2 + 1.342^2 + 0 + 0.447^2 + 0} \approx \begin{bmatrix} 0.535 \\ 0.802 \\ 0 \\ 0.267 \\ 0 \end{bmatrix}$$

2nd round:

$$\mathbf{a}_{new}^T \approx [0.535 \ 0.802 \ 0 \ 0.267 \ 0] \cdot \begin{bmatrix} 0 & 1 & 0 & 0 & 1 \\ 0 & 0 & 1 & 1 & 1 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix} = [0 \ 0.535 \ 0.802 \ 0.802 \ 1.604]$$

$$\mathbf{k}_{new} \approx \begin{bmatrix} 0 & 1 & 0 & 0 & 1 \\ 0 & 0 & 1 & 1 & 1 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix} \cdot \begin{bmatrix} 0 \\ 0.289 \\ 0.289 \\ 0.289 \\ 0.867 \end{bmatrix} = \begin{bmatrix} 1.155 \\ 1.443 \\ 0 \\ 0.866 \\ 0 \end{bmatrix}$$

$$\mathbf{a} \approx \mathbf{a}_{new} / \sqrt{0 + 0.535^2 + 0.802^2 + 0.802^2 + 1.604^2} \approx \begin{bmatrix} 0 \\ 0.263 \\ 0.394 \\ 0.394 \\ 0.788 \end{bmatrix}$$

$$\mathbf{k} \approx \mathbf{k}_{new} / \sqrt{1.155^2 + 1.443^2 + 0 + 0.866^2 + 0} \approx \begin{bmatrix} 0.566 \\ 0.707 \\ 0 \\ 0.424 \\ 0 \end{bmatrix}$$

After fifteen rounds:

$$\mathbf{a} \approx \begin{bmatrix} 0 \\ 0.254 \\ 0.368 \\ 0.368 \\ 0.815 \end{bmatrix} \quad \mathbf{k} \approx \begin{bmatrix} 0.521 \\ 0.756 \\ 0 \\ 0.397 \\ 0 \end{bmatrix}$$

Compared to initial weight values 0.447 it can be seen, for instance, that 'E' has a high value ($a_5 = 0.815$) for being a trusted authority which good hubs link to. In addition, 'B' seems to be a good collective page ($k_2 = 0.756$), which links to good authorities.

Remark: \mathbf{a} and \mathbf{k} can also be computed as eigenvectors of the biggest corresponding eigenvalue of $(M^T M)\mathbf{x} = \lambda\mathbf{x}$ and $(MM^T)\mathbf{x} = \lambda\mathbf{x}$, respectively. Using Matlab, $[V_a, D_a] = \text{eig}(M' * M)$ and $[V_k, D_k] = \text{eig}(M * M')$ give

$$\mathbf{a} \approx \begin{bmatrix} 0 \\ 0.254 \\ 0.368 \\ 0.368 \\ 0.815 \end{bmatrix} \quad \mathbf{k} \approx \begin{bmatrix} 0.521 \\ 0.756 \\ 0 \\ 0.397 \\ 0 \end{bmatrix}$$

Datasta Tietoon, syksy 2011, bonuspistetehtävät

Pisteitäviä siltä erää kun ne ovat valmiita:

- P1) pistetehtävä P1
- P2) pistetehtävä P2
- P3) pistetehtävä P3
- P4) pistetehtävä P4
- P5) pistetehtävä P5

Pisteitävien ratkaisuja siltä erää kun ne ovat valmiita:

- P1) solution to bonus exercise P1
- P2) solution to bonus exercise P2
- P3) solution to bonus exercise P3
- P4) solution to bonus exercise P4
- P5) solution to bonus exercise P5

Datasta Tietoon, syksy 2011, tietokonelaskarit 1-5

Tehtäväkierroksien liittyvät tiedostot DT_TX.zip, jossa $X = \{1, 2, 3, 4, 5\}$ on ladattavissa Nopasta. Assarin demoamista syksyn 2010 vanhoihin tehtäviin on nähtävissä myös YouTubessa http://www.youtube.com/results?search_query=T-61.2010&search=tag

Tietokone #1

Lataa ja pura tiedosto DT_T1.zip kurssin alihakemistoon. Käytetään Matlabia. **Omat kuulokkeet mukaan!** Demotyypinen istunto. Tehtävissä 2, 4 ja 5 pientä omaa kokeilua.

Sisältö

Konvoluutiosumma, signaalin suodattaminen, spektrogrammi.

- DT_T1_d1.m Tutustuminen Matlab-ohjelmistoon. Skalarit, vektorit ja matriisit sekä niiden indeksointi. Skriptit (makrot) ja funktiot. Esimerkkinä `myCircle.m`.

Funktio. Matlabissa saa apua funktioiden käyttämiseen komentoriviltä `help myCircle`. Annetaan sisään ympyrän säteen arvo `sade1`, jolloin funktio palauttaa arvot ympyrän alalle `ala1` ja halkaisijalle `halkaisija1`. Funktiolla on oma muistiavaruus.

Skripti (makro). Komentoja, jotka ajetaan rivi kerrallaan Matlabin pääympäristössä (“workspace”).

- DT_T1_d2.m Datamatriisi \mathbf{X} . Tilastolliset tunnusluvut: minimi, maksimi, keskiarvo, varianssi. Korrelatiokertoimet ja hajontakuviot. Kirjoitetaan itse Matlab-funktio, joka laskee keskiarvon.
- DT_T1_d3.m Konvoluutiosumma

$$g_k = \sum_{m=-\infty}^{\infty} f_m s_{k-m}, \quad \text{tai toinen notaatio} \quad y[n] = \sum_{k=-\infty}^{\infty} h[k] x[n-k]$$

Lasketaan sama kuin H1/1. Suotimen magnitudivaste (amplitudivaste).

- DT_T1_d4.m Äänisignaalin käsittely. Signaalin aaltomuoto, spektri (Fourier-muunnos) ja spektrogrammi (lyhytaikainen Fourier-muunnos).
- DT_T1_d5.m Äänisignaalin suodattaminen (konvoluutiosuodin) kaistanestosuotimella (ekvalisaattori) häiriön poistamiseksi. Vertaa H1/1, mutta nyt näytteet kymmeniä tuhansia pitkiä.

Suodatus voidaan tehdä aikatasossa signaalijonojen konvoluutiolla tai taajuustasossa Fourier-spektrien kertolasulla:

$$f_k \rightarrow \boxed{s_k} \rightarrow g_k = \sum_m f_m s_{k-m} \quad \leftrightarrow \quad F_n \rightarrow \boxed{S_n} \rightarrow G_n = F_n \cdot S_n$$

tai toisella notaatiolla

$$x[n] \rightarrow \boxed{h[n]} \rightarrow y[n] = \sum_k x[k] h[n-k] \quad \leftrightarrow \quad X[k] \rightarrow \boxed{H[k]} \rightarrow Y[k] = X[k] \cdot H[k]$$

Demossa suodatus on toteutettu valmiiksi, mutta tehtävävä on kasvattaa suodinjonon pituus N tarpeeksi suureksi ja asettaa rajataajuudet (häiriön molemmille puolille) oikealle kohdalle. Analysoi signaalia, etsi siitä häiriö ja vaimenna se.

- DEMO_aani.m Syntetisoidaan harmonisia ääniä.

Tietokone #2

Lataa ja pura tiedosto DT_T2.zip kurssin alihakemistoon. Käytetään Matlabia. Demotyypinen istunto. Tehtävässä 3 joutuu etsimään ja kirjoittamaan muutaman rivin oikeaa koodia. Halutessaan tästä voi jatkaa suoraviivaisesti kurssin harjoitustyön pariin.

Sisältö

Pääkomponenttianalyysi (PCA). Kokeillaan PCA:a kasvokuvadataaan.

1. DT_T2_d1.m Tehtävä H2/1 Matlabilla. Lisäksi lasketaan ja osoitetaan PCA:n dekorrelointi ja varianssin maksimointi pääkomponentille. Komentoja: `cov`, `eig`.
2. DT_T2_d2.m PCA pienelle datamatriisille. Huomaa, että PCA:n toteuttava koodi on vain muutamia rivejä; koodissa on paljon visualisointiin liittyvää.
3. DT_T2_d3.m "Eigenfaces" - ominaiskasvot. Annetuissa tiedostoissa 92 kasvokuvaaa ja niistä luotu datamatriisi, jolle tehdään PCA. Nyt ominaiskasvot ovat PCA:sta tulevia ominaisvektoreita. Projisoidaan kahden suurimman ominaisvektorin virittämään tasoon kaikki kasvokuvat. Lisäksi voi kohtuu nopeasti visualisoida ominaiskasvot (ominaisvektorit kuvaesityksenä) ja kahteen ulottuvuuteen projisoitujen pisteen kuvaesitykset. Apuna voi käyttää kurssin funktioita `myX2K.m` (datasta kuvaksi) ja `myK2X.m` (kuvasta dataksi).

Tietokone #3

Lataa ja pura tiedosto DT_T3.zip kurssin alihakemistoon. Käytetään Matlabia. Demotyyppinen istunto. Tehtävissä 4 ja 5 voi käyttää haluamaansa luokitusalgoritmia.

Sisältö

Normaalijakama. kNN-luokitin. Luokittelu.

1. DT_T3_d1.m Normaalijakamaan (Gaussisen) tiheysfunktion parametreiden määräminen datan perusteella (suurimman uskottavuuden menetelmän antamilla parametreilla). Komentoja: `normfit`, `normpdf`, `mle`.
2. DT_T3_d2.m kNN eli $k:n$ lähimmän naapurin luokitin. Paperilaskarien H3/3. Käytetään ennallaolevaa opetusaineista luokitellaan uusi piste luokkaan A tai B.
3. DT_T3_d3.m Sama kuin äsknen, mutta nyt $k = 3$.
4. DT_T3_d4.m Tehtävä: *luokittele* ihmisten pituksien avulla näytteitä miehiksi ja naisiksi.
5. DT_T3_d5.m Tehtävä: *luokittele* kuuluisaa Iris-aineistoa, jossa kolmen eri liljalajien 4-ulotteisia mittauksia.
6. DEMO_regressiosovitus.m Lineaarinen sovitus käyttäen Matlabin komentoa `polyfit`.
7. DEMO_luokitteluvirhe.m kNN-luokitin, datan jakaminen opetus- ja testiaineistoon, luokitteluvirheen laskeminen testiaineiston avulla. komentoa `polyfit`.

Tietokone #4

Lataa ja pura tiedosto DT_T4.zip kurssin alihakemistoon. Käytetään Matlabia. Demotyyppinen istunto. Tehtävässä 4 joutuu etsimään ja kirjoittamaan muutaman rivin oikeaa koodia.

Sisältö

Ryhmittely (klusterointi).

1. DT_T4_d1.m Linkki Java-sovelmaan http://home.dei.polimi.it/matteucc/Clustering/tutorial_html/AppletKM.html, jossa demotaan c-means-ryhmittelyalgoritmia (k-means). Demossa voit myös itse klikkailemalla luoda tai siirtää datapisteitä (palot) ja klusterien keskipisteitä (eriväriset neliot).
2. DT_T4_d2.m c-means-ryhmittely tehtävään H4/2. Käytetään Matlabin komentoa `kmeans`.
3. DT_T4_d3.m Hierarkinen ryhmittely tehtävään H4/2. Käytetään Matlabin komentoja `pdist` (etäisyysmatriisi), `linkage` (määritellään ryhmien välisten etäisyysksien laskeminen) ja `dendrogram` (piirtäminen puuksi).
4. DT_T4_d4.m Ryhmitellään T2-kierroksen kasvokuvia automaattisesti. Koodissa kirjoitettuna valmiina runko; muutetaan datasettiä D, ryhmien lukumäärää tai puun katkaisukohtaa `1kmK` ja algoritmia `ryhm.algoritmi`. Tämän jälkeen toteutaan kyseiseen algoritmiin (joko c-means tai hierrakinen ryhmittely jollain etäisyysmitalla) liittyvät komennot, joiden määrä on muutamia rivejä

Tietokone #5

Lataa ja pura tiedosto DT_T5.zip kurssin alihakemistoon sekä lue ohjeistusta Nopasta. Osa tehtävistä tehdään Linux-koneella.

Sisältö

Kattavat joukot. Keskukset ja auktoriteetit.

1. T5/1 Kattavat joukot.
2. T5/2 Kirjoita omia kuitteja ja testataan kattavien joukkojen etsintää omasta datasta.
3. T5/3 0/1-datamatriisi tekstdokumenteista ja niissä esiintyvistä sanoista.
4. DT_T5_d4.m Tämän voi ajaa joko Octavesta tai Matlabista. Katso luentokalvojen luvun 9 algoritmia ”keskukset ja auktoriteetit” hyvien WWW-sivujen löytämiseksi.

Datasta Tietoon, syksy 2011, Matlab-komentoja

Muista myös Matlabin GNU-kloonin Octave, jonka voi ladata ilmaiseksi Windows-, Mac- ja Linux-ympäristöihin, <http://www.octave.org>. Voit ladata sen lisäpaketin kera <http://octave.sourceforge.net>.

Huomaathan myös tietokonelaskareiden läpikäynnin YouTubessa: http://www.youtube.com/results?search_query=T-61.2010\&search=tag.

- `help <function>, doc <function>`,
- `min, max, mean, median, std, var`, tunnuslukuja: minimi, maksimi, keskiarvo, mediaani, keskihajonta, varianssi
- `plot`, tyypillisii piirtokomento lukujonolle (käyrä): yhdistetään pisteet suorilla viivoilla toisiinsa
- `title, xlabel, ylabel, legend`, piirtämiseen liittyviä komentoja: kuvan otsikko, akselien nimiä, käyrille nimet
- `conv`, konvoluutiosumma
- `fft`, diskreetti Fourier-muunnos (DFT)
- `freqz`, suotimen taajuusvaste
- `soundsc`, lukujonon soittaminen äänenä
- `eig`, ominaisarvot ja -vektorit
- `normpdf, exppdf`, gaussisen / eksponenttisen tiheysfunktion arvojen laskeminen
- `polyfit`, datan sovittaminen polynomikäyrällä
- `kmeans`, c-means-ryhmittely
- `pdist, linkage, dendrogram`, hierarkinen ryhmittely
- SOM Toolbox <http://www.cis.hut.fi/projects/somtoolbox/>

Datasta Tietoon, syksy 2011, kaavakokoelma

Kurssin esitietoina ensimmäisen vuoden matematiikka sekä todennäköisyyslaskennan perusteet. Alla joitakin laskuoperaatioita, joita tarvitaan kurssin harjoituksissa. Kommentit ja korjaukset tervetulleita: jukka.parviainen@aalto.fi.

- summamerkintä \sum (“iso sigma”)

Esimerkki geometrinen sarjan summa ja osasumma.

$$\sum_{i=0}^{\infty} a^i = a^0 + a^1 + a^2 + \dots = \frac{1}{1-a}, \quad |a| < 1$$

$$\sum_{i=0}^N a^i = a^0 + a^1 + a^2 + \dots + a^N = \frac{1-a^{N+1}}{1-a}, \quad |a| < 1$$

- tulomerkintä \prod (“iso pii”). Katso H2/3.

Esimerkki: lasketaan ns. uskottavuusfunktio n :lle datapisteelle käyttäen (1-ulotteisesta) gaussisesta tiheysfunktioista $p(x|\mu, \sigma)$

$$\begin{aligned} \prod_{i=1}^n p(x(i)|\mu, \sigma) &= p(x(1)|\mu, \sigma) \cdot p(x(2)|\mu, \sigma) \cdot \dots \cdot p(x(n)|\mu, \sigma) \\ &= \frac{1}{\sqrt{2\pi}\sigma} \cdot e^{-\frac{(x(1)-\mu)^2}{2\sigma^2}} \cdot \frac{1}{\sqrt{2\pi}\sigma} \cdot e^{-\frac{(x(2)-\mu)^2}{2\sigma^2}} \cdot \dots \cdot \frac{1}{\sqrt{2\pi}\sigma} \cdot e^{-\frac{(x(n)-\mu)^2}{2\sigma^2}} \\ &= \left(\frac{1}{\sqrt{2\pi}\sigma}\right)^n \cdot e^{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x(i)-\mu)^2} \end{aligned}$$

- konvoluutiosumma (H1/1 ja tietokoneharjoituksen T1)

Laskuoperaatio kahdelle lukujonolle f_n ja h_n tuottaa jonon g_n

$$\begin{aligned} g_n &= \sum_{k=-\infty}^{\infty} h_k f_{n-k} \\ &= \dots + h_{-1} f_{n+1} + h_0 f_n + h_1 f_{n-1} + \dots \end{aligned}$$

- Diskreettiaikainen Fourier-muunnos (H1/2)

$$F(\omega) = \sum_{m=-\infty}^{\infty} f_m e^{-i\omega m}$$

Tässä f_m alkuperäinen lukujono ja $F(\omega)$ (diskreettiaikainen) Fourier-muunnos, jossa normaalisti $-\pi/2 \leq \omega \leq \pi/2$. Olemassa vastaava käänneismuunnos jossa $F(\omega)$:sta f_m .

- Diskreetti Fourier-muunnos (DFT)

$$F_n = \sum_{m=0}^{N-1} f_m e^{-i2\pi mn/N}$$

Tässä f_m alkuperäinen lukujono ja F_n diskreetti Fourier-muunnos, jossa $n, m = 0, \dots, N-1$. Yhteys edelliseen $F_n = F(2\pi n\omega/N)$.

- Taylorin polynomi (H1/3)

$$f(x) = \sum_{n=0}^{\infty} \frac{f^{(n)}(a)}{n!} (x-a)^n$$

Funktiota voidaan approksimoida siitä kehitetyllä Taylorin polynomilla.

- logaritmit (H1/4, H2/4, H2/5)

Tyypillisesti luonnollinen (e), 2- tai 10-kantainen logaritmi. Yleisiä laskusääntöjä:

$$\log_m(A \cdot B) = \log_m A + \log_m B$$

$$\log_m(A/B) = \log_m A - \log_m B$$

$$\log_m A^C = C \log_m A$$

$$\log_m D = \log_n D / \log_n m$$

Esimerkki.

$$\log_{10} 2 \approx 0.301, 2^{10} \approx 10^3 \text{ (k)}, 2^{20} \approx 10^6 \text{ (M)}, 2^{30} \approx 10^9 \text{ (G)}.$$

Esimerkki.

$$\begin{aligned} 4^n &= 100000 \\ \log_4 4^n &= \log_4 100000 \\ \underbrace{n \log_4 4}_{} &= \log_{10} 100000 / \underbrace{\log_{10} 4}_{2^2} \\ n &= 5/(2 \log_{10} 2) \approx 5/0.602 \approx 8.3 \end{aligned}$$

Esimerkki.

$$\begin{aligned} 10^x &= 2^{2006} \\ \log_{10} 10^x &= \log_{10} 2^{2006} \\ x \log_{10} 10 &= 2006 \log_{10} 2 \\ x &\approx 2006 \cdot 0.301 \approx 630.8 \\ 10^{630.8} &= 10^{0.8} \cdot 10^{630} \approx 6.3 \cdot 10^{630} \end{aligned}$$

- matriisien kertolasku (H2/1)

Esimerkki.

Olkoon A matriisi kooltaan (3×2) (kolme saraketta, kaksi riviä) ja B (2×1) . Muistetaan, että kertolaskussa "dimensioiden pitää täsmätä". Tulossa AB dimensiotarkastelu: $(3 \times 2)(2 \times 1) \rightarrow (3 \times 1)$.

$$\text{Olkoon } A = \begin{bmatrix} 3 & 4 \\ 2 & 5 \\ 6 & 1 \end{bmatrix} \text{ ja } B = \begin{bmatrix} 8 \\ 9 \end{bmatrix}$$

Niiden matriisitulo $C = AB$, on

$$C = \begin{bmatrix} 3 & 4 \\ 2 & 5 \\ 6 & 1 \end{bmatrix} \cdot \begin{bmatrix} 8 \\ 9 \end{bmatrix} = \begin{bmatrix} 3 \cdot 8 + 4 \cdot 9 \\ 2 \cdot 8 + 5 \cdot 9 \\ 6 \cdot 8 + 1 \cdot 9 \end{bmatrix} = \begin{bmatrix} 60 \\ 61 \\ 57 \end{bmatrix}.$$

- determinantti (H2/2)

Esimerkki.

$$\text{Olkoon } C = \begin{bmatrix} a & b \\ c & d \end{bmatrix}, \text{ jolloin } \det(C):$$

$$\det(C) = \begin{vmatrix} a & b \\ c & d \end{vmatrix} = ad - bc$$

- matriisin käänneismuunnos, yleisesti

$$\mathbf{C}^{-1} = \frac{1}{\det(\mathbf{C})} \text{adj}(\mathbf{C})$$

jossa adjungoidussa matriisissa osadeterminantien A_{ij} kerroin $(-1)^{i+j}$

$$\text{adj}(\mathbf{C}) = \begin{bmatrix} A_{11} & -A_{12} & A_{13} & \dots \\ -A_{21} & A_{22} & \dots & \dots \\ \vdots & \vdots & \ddots & \vdots \end{bmatrix}^T$$

Esimerkki 2-ulotteiselle \mathbf{C}

$$\begin{aligned} \mathbf{C} &= \begin{bmatrix} c_{11} & c_{12} \\ c_{21} & c_{22} \end{bmatrix} = \begin{bmatrix} 2 & 4 \\ 4 & 6 \end{bmatrix} \\ \mathbf{C}^{-1} &= \frac{1}{\det(\mathbf{C})} \text{adj}(\mathbf{C}) = \frac{1}{c_{11}c_{22} - c_{12}c_{21}} \begin{bmatrix} c_{22} & -c_{21} \\ -c_{12} & c_{11} \end{bmatrix}^T \\ &= \frac{1}{4} \begin{bmatrix} -6 & 4 \\ 4 & -2 \end{bmatrix} \end{aligned}$$

- toisen asteen polynomien ratkaisukaava (H2/1)

$$ax^2 + bx + c = 0 \rightarrow x_i = \frac{-b \pm \sqrt{b^2 - 4ac}}{2a}, \quad i = \{1, 2\}$$

- ominaisarvot ja -vektorit (H2/1)

Neliömatriisin C ominaisarvot lasketaan yhtälöstä $Cu = \lambda u \Rightarrow (C - \lambda I)u = 0$. Yhtälöryhmän ratkaisu on yhdenpitävä determinантin kanssa, mistä saadaan polynomiaalinen karakteristinen yhtälö $\det(C - \lambda I) = 0 \Rightarrow p_n \lambda^n + p_{n-1} \lambda^{n-1} + \dots + p_0 = 0 \Rightarrow \lambda_1, \dots, \lambda_n$.

Esimerkki.

$$\text{Olkoon } C = \begin{bmatrix} 14 & 16 \\ 16 & 20 \end{bmatrix}, \text{ jolloin } \det(C - \lambda I):$$

$$\begin{aligned} \det(C) &= \begin{vmatrix} 14 - \lambda & 16 \\ 16 & 20 - \lambda \end{vmatrix} = 0 \\ (14 - \lambda)(20 - \lambda) - 256 &= \lambda^2 - 34\lambda + 24 = 0 \end{aligned}$$

josta ominaisarvot $\lambda_1 \approx 33.28$ ja $\lambda_2 \approx 0.72$.

Ominaisvektorit saadaan yhtälöstä $\begin{vmatrix} 14 & 16 \\ 16 & 20 \end{vmatrix} u = 33.28u$ ja yhtälöryhmästä $\begin{cases} 14u_1 + 16u_2 = 33.28u_1 \\ 16u_2 + 20u_1 = 33.28u_2 \end{cases}$ josta ominaisvektorit $e_1 = |0.64 \quad 0.77|^T$ ja $e_2 = |0.77 \quad -0.64|^T$. Huomaa, että nämä ovat pituudeltaan 1.

- pisteen \mathbf{x} projektio suoralle \mathbf{w}

Esimerkki. Olkoon $\mathbf{x} = [3 \ 2]^T$ ja se projisoidaan kohtisuoraan suoraa $\mathbf{w} = [0.6 \ 0.8]^T$ vasten. Projektio piste

$$y = \mathbf{w}^T \mathbf{x} = [0.6 \ 0.8] \cdot [3 \ 2]^T = 0.6 \cdot 3 + 0.8 \cdot 2 = 3.4$$

Pisteen y sijainti alkuperäisessä koordinaatistossa $\hat{\mathbf{x}} = \mathbf{w}y = [2.04 \ 2.72]^T$.

- pisteiden $\mathbf{X} = [\mathbf{x}(1) \ \mathbf{x}(2) \ \dots \ \mathbf{x}(n)]$ projektio ortogonaaliselle hypersololle \mathbf{W} (kts. PCA-esimerkit H2 ja tietokonelaskarit T2)

$$\begin{aligned} \mathbf{Y} &= \mathbf{W}^T \mathbf{X} \\ \hat{\mathbf{X}} &= \mathbf{W} \mathbf{Y} \end{aligned}$$

- osittaisderivoointi, gradientti (H2/2, H2/3, H2/4, H2/5, H3)

$$\begin{aligned} \frac{\partial}{\partial x} (4x^2 + 3xy + 2y^2) &= 8x + 3y \\ \frac{\partial}{\partial y} (4x^2 + 3xy + 2y^2) &= 3x + 4y \end{aligned}$$

- ääriarvokohdat: etsitään (osittais)derivaatan nollakohta

- euklidinen etäisyys (Euclidian distance)

$$d(\mathbf{x}, \mathbf{y}) = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_d - y_d)^2}$$

- etäisyysmatriisi D näytteiden $\mathbf{x}(1), \dots, \mathbf{x}(n)$ välillä

$$D = \begin{bmatrix} d(\mathbf{x}(1), \mathbf{x}(1)) & d(\mathbf{x}(1), \mathbf{x}(2)) & \dots & d(\mathbf{x}(1), \mathbf{x}(n)) \\ d(\mathbf{x}(2), \mathbf{x}(1)) & d(\mathbf{x}(2), \mathbf{x}(2)) & \dots & d(\mathbf{x}(2), \mathbf{x}(n)) \\ \vdots & \vdots & \ddots & \vdots \\ d(\mathbf{x}(N), \mathbf{x}(1)) & d(\mathbf{x}(N), \mathbf{x}(2)) & \dots & d(\mathbf{x}(N), \mathbf{x}(n)) \end{bmatrix}$$

josta nähdään, että matriisi on symmetrinen ja lävistäjällä nollia (jos etäisyysmittana $d(\cdot)$ esimerkiksi euklidinen etäisyys). Vertaa esim. kaupunkien väliset etäisydet karttakirjassa.

- kuinka monella tavalla voidaan permutoida n muuttujaa? $n!$ (kertoma).

Esimerkiksi $\{'A', 'B', 'C'\} \rightarrow \{'ABC', 'ACB', 'BAC', 'BCA', 'CAB', 'CBA'\}$ eli $3! = 1 \cdot 2 \cdot 3 = 6$

- kuinka monta erilaista $k:n$ kokoista joukkoa saadaan n :stä muuttujasta? $\binom{n}{k} = \frac{n!}{(n-k)!k!}$ (binomikerroin).

Esimerkiksi $\{'A', 'B', 'C'\} \rightarrow \{'', 'A', 'B', 'C', 'AB', 'AC', 'BC', 'ABC'\}$ eli esimerkiksi $\binom{3}{1} = 3$.

Toinen esimerkki, kuinka monella tapaa voidaan valita 7 numeroa 39:stä

$$\binom{39}{7} = \frac{39!}{32! \cdot 7!} = \frac{39 \cdot 38 \cdot 37 \cdot 36 \cdot 35 \cdot 34 \cdot 33 \cdot 32!}{32! \cdot 7 \cdot 6 \cdot 5 \cdot 4 \cdot 3 \cdot 2} \approx 15000000$$

- normaalijakauman tiheysfunktio

$$p(x) = \frac{1}{\sqrt{2\pi}\sigma} \cdot e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

jossa keskihajonta σ ja keskiarvo μ . Varianssi σ^2 .

- normaalijakauman d -ulotteinen tiheysfunktio

$$p(\mathbf{x}) = K \cdot \exp \left(-\frac{1}{2} (\mathbf{x} - \mathbf{m})^T \mathbf{C}^{-1} (\mathbf{x} - \mathbf{m}) \right)$$

jossa skaalaustermi

$$K = \frac{1}{(2\pi)^{d/2} \det(\mathbf{C})^{1/2}}$$

ja \mathbf{C} (toisinaan myös merkinnällä Σ) on kovarianssimatriisi sekä $\mathbf{m} = (\mu_1 \mu_2 \dots \mu_d)^T$ keskiarvovektori (huippukohta). Kovarianssimatriisi \mathbf{C} on symmetrinen neliömatriisi kokoa ($d \times d$).

$$\begin{aligned}\mathbf{C} &= \begin{bmatrix} \mathbf{E}[(x_1 - \mu_1)^2] & \mathbf{E}[(x_1 - \mu_1)(x_2 - \mu_2)] & \dots & \mathbf{E}[(x_1 - \mu_1)(x_d - \mu_d)] \\ \mathbf{E}[(x_2 - \mu_2)(x_1 - \mu_1)] & \mathbf{E}[(x_2 - \mu_2)^2] & \dots & \mathbf{E}[(x_2 - \mu_2)(x_d - \mu_d)] \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{E}[(x_d - \mu_d)(x_1 - \mu_1)] & \mathbf{E}[(x_d - \mu_d)(x_2 - \mu_2)] & \dots & \mathbf{E}[(x_d - \mu_d)^2] \end{bmatrix} \\ &= \begin{bmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1d} \\ \sigma_{21} & \sigma_{22} & \dots & \sigma_{2d} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{d1} & \sigma_{d2} & \dots & \sigma_{dd} \end{bmatrix}\end{aligned}$$

jossa siis $\sigma_{ij} = \sigma_{ji}$ ja σ_{ii} ovat yksittäisten muuttujien variansseja σ_i^2 .

Jos kaikki ristitermit $\sigma_{ij} = 0$, niin muuttujat ovat lineaarisesti riippumattomia toisistaan. Jos kaikki ristitermit $\sigma_{ij} = 0$ ja vielä kaikki σ_{ii} vakioita, niin tiheysfunktio on symmetrinen akseleiden suhteen ("hyperpallomainen"). Katso kuvat luentokalvojen luvusta 5.

Käytännössä datasetin \mathbf{X} (dimensio d , n kpl näytteitä, koko $(d \times n)$) kovarianssimatriisi \mathbf{C} (koko $d \times d$) lasketaan

$$\mathbf{C} = \frac{1}{n-1} \mathbf{XX}^T$$

- eksponentiaalinen jakauma

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

- tasainen jakauma (välillä $[a, b]$)

$$p(x) = 1/(b-a), \text{ kun } x \in [a, b], 0 \text{ muuten}$$

- odotusarvo $E\{\cdot\}$; (painotettu) keskiarvo

$$E\{X\} = \int xp(x) dx = \mu$$

$$E\{X\} = \sum_i x_i p_i = \mu$$

- varianssi $\text{Var}\{\cdot\}$, kun $\mu = E\{X\}$ on keskiarvo; otosvarianssi

$$\text{Var}\{X\} = E\{(X - \mu)^2\} = E\{X^2\} - (E\{X\})^2 = \sigma^2$$

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2$$

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \mu)^2$$