

Luku 3. Data vektoreina

T-61.2010 Datasta tietoon, syksy 2011

professori Erkki Oja

Tietojenkäsittelytieteen laitos, Aalto-yliopisto

3.11.2011

Data vektoreina


- Datamatriisi
- Piirreirrotus: ääni- ja kuvasignaalit
- Dimensionaalisuuden kirous

$$\mathbf{X} = \begin{matrix} & \underbrace{\hspace{10em}}_{\text{n vektoria (havaintoa)}} & \\ \begin{matrix} x_{11} & x_{12} & x_{13} & \bullet & \bullet & x_{1n} \\ x_{21} & x_{22} & & & & \bullet \\ x_{31} & & \bullet & & & \bullet \\ \bullet & & & \bullet & & \bullet \\ \bullet & & & & \bullet & \bullet \\ \bullet & & & & & \bullet \\ x_{d1} & & & & & x_{dn} \end{matrix} & \underbrace{\hspace{10em}}_{\text{d vektorilementia (dimensio)}} \end{matrix}$$

- Matriisin sarakkeet ovat siis yksittäisiä datavektoreita ja kukin rivi vastaa tiettyä vektorialkiota (*mittaustulosta, piirrettä, attribuuttia, surretta*)

Datamatriisi (2)

- Esimerkiksi datavektori voisi olla äänispektri soittimen äänestä, jolloin vektorialkiot vastaisivat taajuuksia. Koko datamatriisi on tällöin ns. *spektogrammi*



Kuva: Spectrogrammista selviää kunakin ajanhetkenä kunkin taajuuskomponentin voimakkuus.

Datamatriisi (3)

- Spektrogrammissa siis matriisi
 $\mathbf{X} = [\mathbf{x}(1) \quad \mathbf{x}(2) \quad \dots \quad \mathbf{x}(n)]$, jossa $\mathbf{x}(i)$:t ovat peräkkäisissä aikaikkunoissa (esim. 20 ms välein) laskettuja diskreettejä Fourier-muunnoksia (katso kalvo 15)
- Toinen esimerkki spektrogrammista: ihmisen puhe (seuraava kuva)

Datamatriisi (5)

- Kaikkea dataa ei suinkaan voi esittää vektorina mutta tämä kattaa hyvin paljon tapauksia. Vrt. myös relaatiotietokannat joissa tietueet on talletettu binäärivektoreina
- Merkitään seuraavassa d -ulotteista vektoria merkinnällä $\mathbf{x}$ ja sen alkioita $x_1, x_2, \dots, x_d$.
- Oletan että vektorien yhteenlasku $\mathbf{x} + \mathbf{y}$, sisätulo $\mathbf{x}^T \mathbf{y}$ ja normi $\|\mathbf{x}\|$ ovat tunnettuja, samoin matriisilla kertominen $\mathbf{A}\mathbf{x}$, matriisien yhteenlasku $\mathbf{A} + \mathbf{B}$ ja tulo $\mathbf{A}\mathbf{B}$ sekä matriisin ominaisarvot ja -vektorit $\mathbf{A}\mathbf{x} = \lambda\mathbf{x}$.

Datan piirreirrotus ja vektorointi


Analogisen datan digitointi

- Usein data on jo vektorimuodossa: siis järjestetty joukko lukuja (jatkuva-arvoisia, binäärisiä ...).
- Jotta jatkuva (analoginen) data saataisiin tähän muotoon, se täytyy diskretoida (digitoida).
- Analoginen *signaali*, esim. ääni, kuvataan ajan mukana vaihtuvana jatkuvana funktiona $f(t)$

Datan piirreirrotus ja vektorointi (2)

Analogisen datan digitointi

- Sekä aika t että amplitudi f täytyy diskretoida jotta ne voi esittää digitaalisessa muodossa



Kuva: (a) analoginen signaali $f(t)$; (b) ajan suhteen digitoitu lukujono $f_A[n] \in \mathbb{R}$, $n \in \mathbb{Z}$; (c) ajan ja amplitudin suhteen digitoitu $f_D[n] \in \mathbb{Z}$. Äänisignaalisissa tyypillinen digitointi 8 bitillä antaa $2^8 = 256$ tasoa y -akselille välillä $-1 \dots +1$.

Analogisen datan digitointi

- Image Tool 1-1

File Tools Window Help

Pixel Region (Image tool 1)

File Edit Window Help

Pixel info: (X, Y) Intensity

Display range: [0 255]

Pixel info: (112, 61) 133

11	12	12	13	11	10	9	9	9	9	9	9	10	10	10	9	9
9	9	10	10	10	10	11	10	9	9	9	10	11	12	16	18	10
10	11	10	11	11	10	10	10	10	11	10	16	26	59	63	16	10
10	10	9	10	10	10	10	11	16	27	43	62	89	134	147	34	12
10	10	9	9	10	10	11	20	43	109	153	162	165	175	171	110	22
11	10	10	9	11	9	10	37	117	166	184	187	193	180	170	171	166
11	10	9	9	11	10	43	165	186	185	185	189	181	150	115	135	154
37	18	12	11	11	35	159	183	178	174	195	110	90	77	44	29	77
166	78	14	14	15	79	176	186	174	150	102	78	56	35	14	43	10
176	127	22	15	13	89	177	186	179	175	133	104	47	25	36	90	140
151	110	17	13	20	90	171	181	185	189	188	158	95	68	172	138	180
133	80	17	21	43	114	195	177	180	192	188	193	164	154	201	209	204
133	101	65	53	76	142	144	167	173	178	174	172	166	178	190	202	206

Kuva: Matlabin “kameramies” ja yksityiskohta silmän alueelta.
Resoluutio 256×256 , tyyppi `uint8` eli $[0, 255] \in \mathbb{Z}$, jossa
0=musta ja 255=valkea.

Datan piirreirrotus ja vektorointi (4)

Analogisen datan digitointi

- Käytännössä mittalaite tekee sen analogia-digitaali (A/D) -muuntimensa avulla
- Tähän liittyvä teoreettinen kysymys on *näytteistys* (*sampling*): kuinka tiheään näytteitä tulee ottaa, ettei hävitetä tietoa?
- Yksiulotteinen signaali $f(t)$ muutetaan jonoksi $f_m = f(mT)$ missä T on näytteistysväli
- Jos näytteistystaajuus $1/T$ on riittävän suuri verrattuna $f(t)$:n suurimpaan taajuuteen, voidaan itse asiassa koko $f(t)$ palauttaa näytteistään (näytteistyslause, sampling theorem; ks. kurssi T-61.3015 Digitaalinen signaalinkäsittely ja suodatus)
- Demo näytteenotosta <http://www.jhu.edu/~signals/sampling/>

Datan piirreirrotus ja vektorointi

Taajuusspektri

- Mitä tarkoittaa $f(t)$:n taajuus?
- Funktiolla $f(t)$ on *taajuusspektri* joka määritellään *Fourier-muunnoksen* avulla

$$F(\omega) = \int_{-\infty}^{\infty} f(t)e^{-i\omega t} dt$$

missä ω on (kulma)taajuus ja $i = \sqrt{-1}$


- Tämän kompleksifunktion itseisarvo voidaan piirtää käyränä, ja se on ns. amplitudispektri (magnitudispektri)
- Perusteluja: taajuus on jaksollisen funktion ominaisuus (montako kertaa sekunnissa jakso toistuu), ja sinikäyrä $f(t) = \sin(\alpha t + \theta)$ on kaikkein tyypillisin jaksollinen funktio. α on sen (kulma)taajuus, θ on vaihe

Datan piirreirrotus ja vektorointi (2)

Taajuusspektri

- Sinikäyrän Fourier-muunnos on nolla paitsi kulmataajuuden arvoilla $\omega = \pm\alpha$ (miksi?), joten F-muunnos paljastaa sinin taajuuden.
- Jos $f(t)$ on summa monesta sinikäyrästä, niiden kaikkien taajuudet näkyvät piikkeinä *taajuusalueessa* eli kompleksitasossa.

Taajuusspektri



Kuva: Kaksi sinisignaalia ja niiden summa aika- ja taajuustasossa.

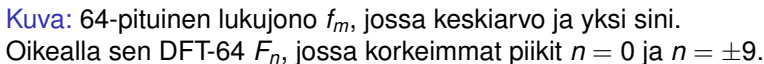
Datan piirreirrotus ja vektorointi (4)

Taajuusspektri

- *Diskreetti Fourier-muunnos* (DFT) määritellään digitoidulle signaalille f_m , $m = 0, \dots, T - 1$:

$$F_n = \sum_{m=0}^{T-1} f_m e^{-2\pi i m n / T}$$

Taajuusspektri



- Demo Fourier-sarjalla approksimoinnista

Datan piirreirrotus ja vektorointi

Taajuussuodatus

- Usein aikasignaalista halutaan poistaa tiettyjä taajuuksia, esim. korkeita taajuuksia jotka vastaavat kohinaa tai verkkovirran taajuus 50 Hz.
- Tässä käytetään hyväksi lineaarisia suotimia, jotka laskennallisesti toteutetaan ns. *konvoluutiona*:

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

missä f_m on suodatettava digitaalinen signaali ja s_j on vastaavasti suodin (äärellinen lukujono).

Datan piirreirrotus ja vektorointi (2)

Taajuussuodatus

- On helppo todistaa että konvoluution Fourier-muunnokselle pätee


$$G_n = F_n \cdot S_n$$

eli taajuustasossa spektrit kerrotaan keskenään

- Jos siis halutaan estää / korostaa tiettyjä taajuuksia, valitaan suodinjono s_k siten että sen F-muunnoksessa S_n nämä taajuudet ovat heikkoja / vahvoja.
- Esimerkki suodatuksesta aika- ja taajuustasossa. Tässä tehdään alipäästösuodatus (keskiarvoistaminen) aikatasossa $g_k = \sum_m f_m s_{k-m}$ vasemmassa sarakkeessa tai vastaavasti taajuustasossa $G_n = F_n \cdot S_n$. Vertaa ekvalisaattorin toimintaan kotistereissa tai musiikkisoittimessa.

Datan piirreirrotus ja vektorointi (3)

Taajuussuodatus



Kuva: Signaalin suodatus. Vasemmalla aikataason digitaaliset lukujonot (signaalit): sisääntulo f_k , suodinjono s_k ja suodatuksen lopputulos g_k . Oikealla vastaavat Fourier-muunnetut spektrit $f_k \leftrightarrow F_n$. Korkeataajuinen komponentti vaimenee suodatuksessa.

Datan piirreirrotus ja vektorointi (4)

Taajuussuodatus

- Suodattimen suunnittelu käytännössä on oma taiteenlajinsa, ks. T-61.3015 Digitaalisen signaalinkäsittelyn ja suodatuksen kurssi.
- Joko aika-alueen digitaalinen signaali f_m tai taajuusalueen digitaalinen signaali $|F_n|$ (amplitudispektri, mahdollisesti täydennettynä vaiheella) voivat sellaisenaan olla vektoreita joita jatkossa analysoidaan. Esimerkkinä puheen spektrogrammi.
- Kuville on olemassa 2-ulotteinen DFT jota voi vastaavalla tavalla käyttää kuvien suodatukseen; vrt. digikameroiden kuvankäsittelyoptiot.

Datan piirreirrotus ja vektorointi (5)


Taajuussuodatus

- Spektriä voi myös kokonaisuudessaan tai osina käyttää tehokkaana piirrevektorina kuville. Se paljastaa esim. kuvassa olevien viivojen yleisimmät suunnat. Enemmän kurssissa T-61.5100 Digitaalinen kuvankäsittely.

Muita tyypillisiä piirteitä eri datatyypeille

Histogrammi

- Hyvin yleinen ja tehokas piirretyyppi on *histogrammi*, jossa suureen arvot “lokeroidaan”



Kuva: Normaalijakautuneita satunnaislukuja $N = 1000$ kpl.
Sama data, mutta pylväiden lukumäärä 4, 10, 60 ja 300.

Muita tyypillisiä piirteitä eri datatyypeille (2)

Histogrammi

Histogrammissa pylvään korkeus kertoo, kuinka monta arvoa osui lokeroon.

- DFT on esimerkki tästä eli taajuushistogrammi: paljonko signaalissa tai kuvassa on tiettyä taajuutta
- Kuvan värihistogrammi kertoo, montako pikseliä kuvassa on kutakin väriä (dimensio 16.7 miljoonaa tiivistämättömänä, kun kolmevärimäinen 8-bittinen esitys)
- Tekstidokumentin sanahistogrammi kertoo montako kertaa kukin sana esiintyy dokumentissa (dimensio 50.000 - 100.000 tiivistämättömänä)


Muita tyypillisiä piirteitä eri datatyypeille

Kuva ja ääni

- Hyvä piirteiden lähde ovat standardit, etenkin JPEG (joint photographic experts group) ja MPEG (moving pictures expert group); esim. MPEG-1 Audio Layer 3 eli MP3 äänelle ja musiikille

Muita tyypillisiä piirteitä eri datatyypeille (2)

Kuva ja ääni



Muita tyypillisiä piirteitä eri datatyypeille (3)

Kuva ja ääni

Kuva: Alkuperäinen kuva, josta kolme eri JPEG-tallennusta.
Yksityiskohtakuvien tavukoot 42 kT, 12 kT, 6 kT.

- Ne on kehitetty äänen, kuvien ja videon pakkaamiseen, mutta pakattua muotoa voi käyttää myös piirteinä automaattisessa analyysissä

Muita tyypillisiä piirteitä eri datatyypeille


Teksti vektorina

- Edellä mainittiin jo sanahistogrammit
- Jos yksittäisten dokumenttien sanahistogrammit ovat datamatriisin **X** sarakkeina, sitä kutsutaan termi-dokumentti-matriisiksi.
- Kuvan
esimerkissä termi-dokumenttimatriisi, jossa kukin rivi vastaa yhtä dokumenttia ja kukin sarake vastaa yhtä sanaa. Sanojen lukumäärät ≥ 1 on korvattu mustalla pisteellä. Sarakkeet on järjestetty sanojen esiintymisjärjestykseen. Ensimmäisessä dokumentissa yli 200 sanaa, toisessa myös noin 200 sanaa, joista noin 150 uusia verrattuna ensimmäiseen, jne. Lähde: 56 harjoitustyötä DT-kurssilla 2005. HUOM! Dataan on

Muita tyypillisiä piirteitä eri datatyypeille (2)

Teksti vektorina

tahallisesti lisätty yksi “lähes” kopioidokumentti. Mikä dokumentti?



Kuva: Termi-dokumentti-matriisi, jossa kukin rivi ($D = 56$) vastaa yhtä dokumenttia ja kukin sarake ($N = 5098$) vastaa yhtä sanaa.

Muita tyypillisiä piirteitä eri datatyypeille (3)

Teksti vektorina

- Käytännössä matriisia useimmiten muokataan seuraavasti:
1. Tavallisimmat sanat (ja, siis, ...) poistetaan; 2. sanoja (termejä) painotetaan niiden tärkeyden mukaan, usein käyttäen ns. *käänteistä dokumenttitaajuutta*

$$w(sana) = \log\left(\frac{L}{df(sana)}\right)$$

missä $w(sana)$ on painokerroin, $df(sana)$ on sanan *dokumenttifrekvenssi* (kuinka monessa kokoelman dokumentissa tuo sana esiintyy), ja L on kokelman dokumenttien lukumäärä

- Nyt kunkin dokumentin sanahistogrammissa arvot kerrotaan painoilla w .

Muita tyypillisiä piirteitä eri datatyypeille (4)

Teksti vektorina

- Siten esim. sana “ja” joka luultavasti esiintyy jokaisessa dokumentissa (suomenkielisessä kokoelmassa) saa histogrammiarvon 0.
- Hankalampi tapaus ovat synonyymit ja sanojen taivutusmuodot. Näitä pohditaan kurssissa T-61.5020 Statistical Natural Language Processing (Luonnollisen kielen tilastollinen mallinnus)
- Samaa vektorointimuotoa voi käyttää mille tahansa *merkkijonoille*; esim. geneettisessä koodissa on 4 kirjainta A,C,G,T jotka ovat lyhenteitä tietyille nukleotideille. “Sana” voi olla esim. 3 merkin pituinen osajono: AAA, AAC, TTT joita on vain $4^3 = 64$ erilaista ja siten “termi-dokumenttimatriisin” sarakkeet 64-dimensioisia.

Muita tyypillisiä piirteitä eri datatyypeille (5)

Teksti vektorina

- Samantapainen idea yleistyy *puille* ja niitäkin yleisemmille tietorakenteille.



Dimensionaalisuuden kirous

Otoksen koko suhteessa avaruuden dimensioon

- Ajatellaan histogrammia moniulotteisessa avaruudessa. Katsotaan oheista
1-ulotteista histogrammia, jossa 10 lokeroa. Jos halutaan tasossa (2-ulotteinen avaruus) 10 lokeroa / dimensio, tulee jo $10 \times 10 = 100$ lokeroa (pientä suorakaidetta). Riittääkö data täyttämään ne?

Dimensionaalisuuden kirous (2)

Otoksen koko suhteessa avaruuden dimensioon



Kuva: Datahistogrammi (a) 1D; (b) 2D

- d -ulotteisessa avaruudessa 10^d ; esim. jos $d = 79$, niin 10^{79} , joka on maailmankaikkeuden atomien arvioitu lukumäärä. Näin jo 79-ulotteisessa vektoriavaruudessa, jossa on 10 lokeroa kullakin koordinaattiakselilla, tulisi vain 1 atomi kuhunkin lokeroon

Dimensionaalisuuden kirous (3)

Otoksen koko suhteessa avaruuden dimensioon

- *Mikä tahansa vektorijoukko korkeaulotteisessa avaruudessa on tavattoman harva*
- Tämä on *dimensionaalisuuden kirous*: tarvitaan valtavasti dataa minkäänlaisen mallin muodostamiseksi korkeaulotteiselle datalle

Dimensionaalisuuden kirous

Korkeaulotteisten vektoriavaruuksien omituisuuksia

- Ajatellaan neliötä, kuutiota, hyperkuutiota jonka sivun pituus on 1 ja dimensio d . Ajatellaan datajoukkoa (datamatriisin $\mathbf{X}$ sarakkeet) joka on jakautunut tasaisesti hyperkuutioon. (Kussakin kahdessa osajoukossa joilla on sama tilavuus on keskimäärin sama määrä vektoreita). Kun d on suuri, törmätään joihinkin yllättäviin ilmiöihin.

- 1. Melkein koko hyperkuutio tarvitaan kattamaan pienikin osuus vektoreista.

Mikä on sellaisen pienemmän hyperkuution sivun pituus, joka sisältää osuuden p kaikista vektoreista? (Esim. kymmenesosan, $p = 0.1$). Merkitään sivun pituutta $s(p)$

Neliö: $s(0.1) = \sqrt{0.1} \approx 0.32$, $s(p) = \sqrt{p}$

Kuutio: $s(0.1) = (0.1)^{1/3} \approx 0.46$ $s(p) = p^{1/3}$

Dimensionaalisuuden kirous (2)




Korkeaulotteisten vektoriavaruuksien omituisuuksia

10-ulotteinen: $s(0.1) = (0.1)^{1/10} \approx 0.80$

d -ulotteinen hyperkuutio: $s(p) = p^{1/d}$

Mille tahansa osuudelle p pätee $s(p) \rightarrow 1$ kun $d \rightarrow \infty$.

Lähes koko hyperkuutio tarvitaan kattamaan pienikin osuus datasta.



Kuva: Sisäpisteiden suhteellinen määrä pienenee dimension kasvaessa.

Dimensionaalisuuden kirous (3)

Korkeaulotteisten vektoriavaruuksien omituisuuksia

- 2. Pisteet ovat kaukana toisistaan: melkein jokainen vektori (datapiste) on lähempänä kuution reunaa kuin toista pistettä.

Hyperkuution keskipisteen etäisyys reunasta on 0.5. Se on maksimietäisyys; yleensä pisteiden etäisyys reunasta on pienempi.

Olkoon datapisteitä n kpl ja avaruuden dimensio d .

Voidaan osoittaa että pisteiden keskimääräinen etäisyys on

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

Nähdään että olipa n mikä tahansa, $D(d, n) \rightarrow 0.5$ kun $d \rightarrow \infty$.

Dimensionaalisuuden kirous (4)

Korkeaulotteisten vektoriavaruuksien omituisuuksia

- 3. Jos tehdään tasavälinen histogrammi, niin melkein kaikki lokerot ovat hyperkuution pinnalla.
Olkoon lokeroiden lukumäärä dimensiota kohti b , kaikkiaan silloin lokeroita b^d . Niistä osuus $(\frac{b-2}{b})^d$ on kuution sisäosassa. Mutta tämä menee nollaan kun $d \rightarrow \infty$.
- Kaikki yhdessä osoittavat että korkeaulotteinen hyperkuutio ei vastaa käsitystämme kuutiosta, vaan on pikemminkin “piikikäs”.
- Opetus: data-analyysissä olisi tärkeää saada dimensio jotenkin pudotettua mahdollisimman pieneksi, että vältetään yllä olevat ilmiöt.

Yhteenveto

- Tässä luvussa esitettiin datamatriisi $\mathbf{X}$ yhtenä tapana esittää havaintoja.
- Datamatriisista voidaan irrottaa piirteitä, jotka kuvaavat tehokkaammin dataa. Piirteitä voidaan käyttää paremmin esimerkiksi luokittelussa tai ryhmittelyssä.
- Laskenta tulee monella tapaa ongelmalliseksi, jos mitattavien suureiden määrä eli datamatriisin dimensio kasvaa suureksi. Seuraavassa luvussa esitellään yksi tapa pudottaa tehokkaasti datan dimensiota.