



Univerza v Ljubljani
Fakulteta za *elektrotehniko*

Mere Podobnosti

Stanislav Kovačič




<http://vision.fe.uni-lj.si/>



Merjenje podobnosti

V splošnem se merjenje podobnosti opira na merjenje razdalje
Čim „bližje“ sta si sliki, bolj sta si podobni
Manjša je torej razdalja med slikama, bolj sta si podobni
Večja je razdalja, bolj sta si sliki različni
Enako velja za dele oziroma področja slik, oblik, značilk, ...



Mere podobnosti

Vprašanje:

Imamo dve sliki ali dela slik.


Koliko sta si dve sliki ali dela slik podobni (ali različni oziroma „daleč“)?

Primeri, ko merimo podobnost:

- Primerjanje s predlogo
- Razpoznavanje
- Poravnavanje slik
- Stereo primerjanje
- Sledenje, analiza gibanja
- Iskanje, indeksiranje slik




Poravnavanje slik





Poravnavanje slik

S primerjanjem/poravnavo slik lahko ugotovljamo razlike med slikami!




Sledenje

S primerjanjem zaporednih slik določimo trajektorije - sledimo objektom.



Stereo primerjanje

S stereo primerjanjem ugotovimo razdaljo - „globino“.



Narcissus Encounter - Bri 2007

Narcissus Encounter - Bri 2007



Iz vsebine

- Razdalja, metrika
- Podobnost, norma, razdalja
- Nekaj primerov
- Podobnost množic točk
- Podobnost na podlagi histogramov



Razdalja, metrika

Funkcija razdalje „nad“ U (U je prostor (množica) slik, oblik, videza, ...)
 $d: U \times U \rightarrow \mathbb{R}$

Lastnosti:

- 1.) $d \geq 0$; nenegativnost
- 2.) $d(u,u) = 0$; $d(u,v) = 0 \Leftrightarrow u = v$; enakost
- 3.) $d(u,v) = d(v,u)$; simetričnost

Razdalja torej poljubnemu paru elementov prostora (množice) U priredi nenegativno realno število.

- 4.) $d(u,v) + d(v,w) \geq d(u,w)$ (trikotniško pravilo oz neenakost)

Če velja tudi trikotniško pravilo, potem je d metrika in prostor metričen



Merjenje podobnosti

Na primer, trikotniško pravilo ne velja: **oče, otrok, mati**

$$d(\text{oče, otrok}) + d(\text{otrok, mati}) < d(\text{oče, mati})$$

Razdalja $d(\text{oče, mati})$ je velika, medtem ko sta lahko razdalji

$d(\text{oče, otrok})$ in $d(\text{otrok, mati})$ majhni ☺

Na primer, simetričnost ne velja

sin je podoben očetu

kaj pa: oče je podoben sinu ;)

Opomba:

Včasih se razdalji reče kar podobnost, čeprav je v resnici različnost.



Merjenje podobnosti

Mera podobnosti (Angl. *similarity measure*) je običajno bolj svobodna.

Nima (vedno) vseh, temveč le nekatere lastnosti razdalje/metrike.

- | | |
|-------------------------|------------------------------------|
| $S(u,v) = -d(u,v)$; | negativna |
| $S(u,v) = 1 - d(u,v)$; | za d normiran, $0 \leq d \leq 1$ |
| $S(u,v) \neq S(v,u)$; | ni simetrična |
- trikotniško pravilo ne velja

Lastnosti mere podobnosti narekuje namen uporabe.



Merjenje podobnosti

Želene, ne vedno nujne, lastnosti mere (funkcije) podobnosti:

- metričnost
- zveznost
(majhna sprememba slike, majhna sprememba podobnosti)
- invariantnost
(neobčutljivost na nekatere preslikave,
npr. rotacijo, translacijo, ...)
a včasih je invarianca tudi nezaželena



Lp norma, razdalja

Lp norma, Lp razdalja (razdalja Minkowskega, $p \geq 1$)

$\mathbf{x} = [x_1, x_2, \dots, x_i, \dots, x_n]$ (vektor - element vektorskega prostora)

$\|\mathbf{x}\|_p = (|x_1|^p + |x_2|^p + \dots + |x_i|^p + \dots + |x_n|^p)^{1/p}$ (dolžina vektorja)

L₂ norma - Evklidska norma - Evklidski prostor

$\|\mathbf{x}\|_2 = (|x_1|^2 + |x_2|^2 + \dots + |x_i|^2 + \dots + |x_n|^2)^{1/2}$

L₁ norma

$\|\mathbf{x}\|_1 = (|x_1| + |x_2| + \dots + |x_i| + \dots + |x_n|)$

L_∞ norma

$\|\mathbf{x}\|_∞ = \sup(|x_1|, |x_2|, \dots, |x_i|, \dots, |x_n|)$



Korelacijske mere podobnosti

I₁(i,j) – slika 1, npr predloga

I₂(i,j) – slika 2

Vsota absolutnih razlik: $SAD(x, y) = \sum_{i,j} |I_1(i, j) - I_2(i + x, j + y)|$

Vsota absolutnih razlik: $SSD(x, y) = \sum_{i,j} (I_1(i, j) - I_2(i + x, j + y))^2$

Normirana križna korelacija: $NCC(x, y) = \frac{\sum_{i,j} I_1(i, j) \cdot I_2(i + x, j + y)}{\sqrt{\sum_{i,j} I_1(i, j)^2 \sum_{i,j} I_2(i + x, j + y)^2}}$

Normirana križna korelacija (s srednjo vrednostjo nič):

$$ZNCC(x, y) = \frac{\sum_{i,j} (I_1(i, j) - \bar{I}_1) \cdot (I_2(i + x, j + y) - \bar{I}_2(x, y))}{\sqrt{\sum_{i,j} (I_1(i, j) - \bar{I}_1)^2 \sum_{i,j} (I_2(i + x, j + y) - \bar{I}_2(x, y))^2}}$$



Lp razdalja

$\mathbf{d} = \mathbf{y} - \mathbf{x}$: (razlika vektorjev, $\|\mathbf{d}\|$ - dolžina vektorja razlike)

$\|\mathbf{x} - \mathbf{y}\|_p = (|x_1 - y_1|^p + |x_2 - y_2|^p + \dots + |x_i - y_i|^p + \dots + |x_n - y_n|^p)^{1/p}$

L₂ razdalja - Evklidska razdalja

$\|\mathbf{x} - \mathbf{y}\|_2 = (|x_1 - y_1|^2 + |x_2 - y_2|^2 + \dots + |x_i - y_i|^2 + \dots + |x_n - y_n|^2)^{1/2}$

L₁ razdalja - Manhattan razdalja


$\|\mathbf{x} - \mathbf{y}\|_1 = (|x_1 - y_1| + |x_2 - y_2| + \dots + |x_i - y_i| + \dots + |x_n - y_n|)$


L_∞ razdalja - „šahovniška“ razdalja

$\|\mathbf{x} - \mathbf{y}\|_∞ = \sup(|x_1 - y_1|, |x_2 - y_2|, \dots, |x_i - y_i|, \dots, |x_n - y_n|)$





Primerjanje s predlogo

- Naloga: poišči  v sliki
- Vprašanje: kakšno mero podobnosti izbrati? je to bistveno vprašanje?

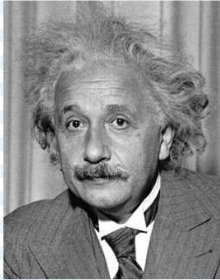


Slide: Hoiem

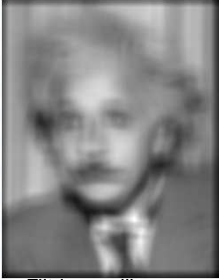
 **Primerjanje s predlogo**

Naloga: poišči  v sliki

$$S(m,n) = \sum_{k,l} g(k,l) f(m+k,n+l)$$



Slika f




Filtrirana slika


f = slika
g = predloga

S(m,n) deluje?
Pravzaprav ne

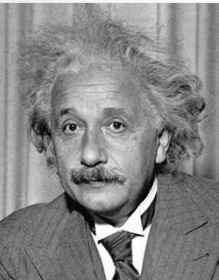
Težava:
v splošnem močan
odziv na svetla področja

Slide: Hoiem


 **Primerjanje s predlogo**

Naloga: Poišči oko  v sliki

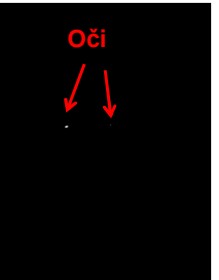
$$S(m,n) = \sum_{k,l} (g(k,l) - f(m+k,n+l))^2$$



Vhodna slika





1- sqrt(SSD)



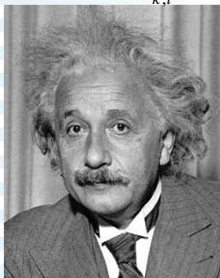
Oči
Upagovljena slika

Slide: Hoiem


 **Primerjanje s predlogo**

Naloga: poišči  v sliki

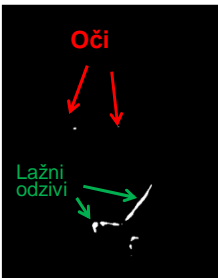
$$S(m,n) = \sum_{k,l} (f(k+m,l+n) - \bar{f}) g(k,l)$$



Vhodna slika





Filtrirana slika



Oči
Lažni odzivi
Upagovljena f.slika

Slide: Hoiem

 **Primerjanje s predlogo**

Naloga: poišči oči  v sliki

$$S[m,n] = \frac{\sum_{k,l} (g[k,l] - \bar{g})(f[m-k,n-l] - \bar{f}_{m,n})}{\left(\sum_{k,l} (g[k,l] - \bar{g})^2 \sum_{k,l} (f[m-k,n-l] - \bar{f}_{m,n})^2 \right)^{0.5}}$$


Matlab: `normxcorr2(template, im)`

Slide: Hoiem



Primerjanje s predlogo


Dobra lastnost ZNCC:
Neodvisna od spremembe svetlosti in kontrasta



Vhodna slika



Filtrirana slika




Upagovljena

Slide: Hoiem



Hausdorff-ova razdalja



$h(A,B)$: za vsako točko iz A poiščemo najbližjo točko v B
Izmed vseh razdalj izberemo največjo.

$h(B,A)$: za vsako točko iz B poiščemo najbližjo točko v A
Izmed vseh razdalj izberemo največjo.

Izmed $h(A,B)$ in $h(B,A)$ izberemo večjo.

Primer uporabe:

Eno sliko transformiramo dokler ni največja razdalja med točkami minimalna.
Tedaj sta sliki (množici točk) poravnani.



Hausdorff-ova razdalja

$H(A,B)$ je razdalja med dvema neenako močnima množicama točk.
 H je največja razdalja točke do najbližje točke v drugi množici.

$h(A,B) = \sup_{a \in A} \inf_{b \in B} d(a,b)$: d je na primer Evklidska razdalja

$h(B,A) = \sup_{b \in B} \inf_{a \in A} d(b,a)$

$$H(A,B) = \max\{h(A,B), h(B,A)\}$$




Jaccard-ov indeks (razdalja)

$J(A,B)$ indeks ali koeficient
je razmerje med presekom dveh množic in unijo teh množic.
Na primer dveh področij, ki se delno prekrivata.

$$J(A,B) = \frac{|A \cap B|}{|A \cup B|}$$

J ni „prava“ metrika, ali pač?.




Kaj pa

$$J_d(A,B) = 1 - J(A,B) = \frac{|A \cup B| - |A \cap B|}{|A \cup B|}$$




Razdalja med histogrami

Slike primerjamo posredno
- primerjamo njihove *opise* (histograme)



Testna slika



Znani objekti



Vprašanje: kako primerjati histograme ?


Slide credit: Bastian Leibe



Evklidska razdalja

(L₂ norma)

$$d(H1, H2) = \sum_{i=1..N} (h_1(i) - h_2(i))^2$$



Poudarja razlike posameznih celic
Precej občutljiva na šum
Vse celice imajo enako težo



Mere podobnosti med histogrami

Obstaja veliko možnosti za primerjanje histogramov, nekatere:

- Evklidska razdalja:

$$d(H1, H2) = \sum_{i=1..N} (h_1(i) - h_2(i))^2$$

- Hi kvadrat (standardni test preizkušanja enakosti porazdelitev)

$$\chi^2 = \frac{1}{2} \sum_{i=1..N} \frac{(h_1(i) - h_2(i))^2}{h_1(i) + h_2(i)}$$

- Presek histogramov (za normirana histograma):


$$IS = 1 - \sum_{i=1..N} \min(h_1(i), h_2(i))$$



Razdalja hi kvadrat

Hi kvadrat

$$\chi^2 = \frac{1}{2} \sum_{i=1..N} \frac{(h_1(i) - h_2(i))^2}{h_1(i) + h_2(i)}$$



Statistični test enakosti porazdelitev
Možno upoštevati tudi stopnjo statistične značilnosti
Celice niso enako utežene.


Slide credit: Bastian Leibe



Kullback-Leiblerjeva razdalja

Definicija

$$KL(Q, V) = \sum_i q_i \log \frac{q_i}{v_i}$$



Podlaga v teoriji informacij:

Pričakovano število dodatnih bitov za kodiranje vzorcev iz porazdelitve Q, če uporabimo kod na podlagi porazdelitve V, v primerjavi, če bi kodirali s Q.

Ni simetrična (ni metrika)

Simetrična verzija: *Jeffreyjeva divergenca*

$$JD(Q, V) = KL(Q, V) + KL(V, Q)$$

Slide credit: Bastian Leibe



Druge možnosti

Primerjamo srednji vrednosti

Primerjamo srednji vrednosti in varianci

Medsebojna informacija



Hellingerjeva razdalja


Definicija

- Koefficient Bhattacharyya

$$BC(Q, V) = \sum_i \sqrt{q_i v_i}$$

- Hellingerjeva razdalja

$$d_{\text{Hell}}(Q, V) = \sqrt{1 - BC(Q, V)}$$




Pojasnilo

- Statistično ozadje
 - BC meri statistično separabilnost dveh porazdelitev
- Je metrika (velja tudi trikotniška neenakost)



Povprečna barva

Izračunamo povprečje vseh barv v sliki




$$\mu = \frac{1}{N} \sum_{i=1}^N \mathbf{x}_i$$

$$\mathbf{x}_i = (r_i, g_i, b_i)^T$$

- Razdalja, na primer:

Problem: $d = \mu_1 - \mu_2$

Izgubimo informacijo o razpršenosti barve okoli povprečne vrednosti!






Gaussov model barve

Predpostavimo Gaussovo porazdelitev barve

- Gauss: Srednja vrednost in varianca



$$\mu = \frac{1}{N} \sum_{i=1}^N x_i$$

$$\Sigma = \frac{1}{N-1} \sum_{i=1}^N (x_i - \mu)(x_i - \mu)^T$$

- Lahko računamo za vsak kanal posebej in se izračun variance poenostavi:

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



→ (μ_1, σ_1) **Matlab:** (μ_2, σ_2) ←
`mu = mean(x) ;`
`C = cov(x) ;`



- Ampak porazdelitev največkrat ni Gaussoval



Večmodalne mere podobnosti

Medsebojna informacija (koliko ena slika pove o drugi sliki):

$$S_{MI} = H(A) + H(B) - H(A, B)$$

$$H(\cdot) = -\sum p(\cdot) \cdot \log(p(\cdot))$$

Normirana medsebojna informacija:

$$S_{NMI} = \frac{H(A) + H(B)}{H(A, B)}$$

Primeri:

svetlostna slika vs IR slika
 CT slika vs MRI slika



Mahalanobis-ova razdalja

$$d_M^2(x, y) = (x-y)^T S^{-1} (x-y)$$

x, y : naključna vektorja

$x = [x_1, x_2, \dots, x_i, \dots, x_N]$

$y = [y_1, y_2, \dots, y_i, \dots, y_N]$



S : kovariančna matrika

Če je kovariančna matrika diagonalna, je Mahalanobisova razdalja enaka uteženi Evklidski razdalji, in variance komponent so uteži.

$$d_M^2(x, y) = \sum_i \frac{(x_i - y_i)^2}{\sigma_i^2}$$



Modalnost



Gre za primerjanje slik, ki nastanejo po različnih postopkih, a upodabljajo isto tkivo. Korelacijski pristopi v tem primeru odpovedo.



Modalnost



Gre za primerjanje slik, ki nastanejo
po različnih postopkih, a upodabljajo isto sceno.