
DETEKCIA A KLASIFIKÁCIA OBJEKTOV V PRÍKLADOCH

ZUZANA HALADOVÁ
JÚLIA KUČEROVÁ

ELENA ŠIKUDOVÁ
ZUZANA ČERNEKOVÁ
*Fakulta matematiky, fyziky a informatiky
Univerzita Komenského, Bratislava*



WIKINA



Obsah

1	Snímanie obrazu	3
1.1	Otázky	3
2	Lineárna a nelineárna filtrácia	5
2.1	Príklad: Hľadanie hrán pomocou Sobelovho filtra	5
2.2	Otázky	7
2.3	Úlohy	8
2.3.1	Filtračné jadrá	8
2.3.2	Priemer vs. medián	8
2.3.3	Prvá a druhá derivácia	8
3	Matematická morfológia	11
3.1	Príklad: Morfologická operácia otvorenia	11
3.1.1	Morfologická operácia otvorenia na reálnom ob- raze	13
3.2	Otázky	14
3.3	Úlohy	16
3.3.1	Hit and Miss	16
3.3.2	Granulometria	16
3.3.3	Tophat	16
3.3.4	Kostrá	17

3.3.5	Odstránenie objektov s využitím matematickej morfológie	17
4	Fourierova transformácia a diskretná kosínusová transformácia	19
4.1	Príklad: Filtrovanie šumu vo frekvenvenecnej oblasti	19
4.2	Otázky	20
4.3	Úlohy	22
4.3.1	Fourierove spektrum	22
4.3.2	Posunutie	22
4.3.3	Kruh a pruh	22
4.3.4	Amplitúda a fáza	24
5	Príznačky	25
5.1	Príklad: Príznačky textúry – matica opakovaných výskytov .	25
5.2	Príklad: Lokálne príznačky	25
5.3	Otázky	29
5.4	Úlohy	30
5.4.1	Matica opakovaných výskytov	30
5.4.2	Rozpoznávanie fotografií a malieb	30
5.4.3	Odlíšenie fotografií budov a prírody	31
6	Predspracovanie príznačkov	33
6.1	Príklad: Znižovanie dimenzie – PCA	33
6.2	Otázky	35
6.3	Úlohy	36
6.3.1	PCA-SIFT	36
6.3.2	Normály	36
7	Výber príznačkov	37
7.1	Entropia	37
7.1.1	Príklad: Výpočet entropie	37
7.2	Otázky	39
7.3	Úlohy	39
7.3.1	Výber príznačkov	39
8	Klasifikácia	43
8.1	Naivný Bayesovský klasifikátor	43
8.1.1	Príklad: Klasifikácia pomocou Naivného Bayesovského klasifikátora	44

8.2	Otázky	45
8.3	Úlohy	46
8.3.1	Rozhodovacie stromy	46
8.3.2	Metóda K najbližších susedov	47
8.3.3	Lineárny klasifikátor	48
8.3.4	Metóda K priemerov	49
9	Hodnotenie kvality klasifikácie	51
9.1	Príklad: Vytvorenie matice zámen	51
9.1.1	Príklad: Vyhodnotenie kvality klasifikátora použí- tím matice zámen	52
9.2	Otázky	53
9.3	Úlohy	54
9.3.1	Vyberanie vzorky do testovacej množiny	54
9.3.2	Porovnávanie klasifikátorov	54
9.3.3	ROC krivky	55
10	Svetlo	57
10.1	Otázky	57
11	Ľudský vizuálny systém	59
11.1	Otázky	59
12	Kolorimetria	61
12.1	Príklad: Grassmannov experiment skladania farieb	61
12.2	Otázky	62
12.3	Úlohy	63
12.3.1	Farby	63
12.3.2	CIE diagram	63
13	Farebné modely	65
13.1	Príklad: Prevod medzi farebnými modelmi	65
13.2	Otázky	67
13.3	Úlohy	68
13.3.1	Farebné modely	68
13.3.2	Prevody medzi farebnými modelmi	68
13.3.3	Model RGB	68
13.3.4	Model CMY	69
13.3.5	Detekcia pokožky v modeli HSV	69

13.3.6	Prevod medzi HSV a HSL	70
14	Vizuálne vnímanie a pozornosť	71
14.1	Otázky	71
14.2	Úlohy	72
14.2.1	Detekcia významných oblastí	72



Predslov

Táto cvičebnica vznikla v rámci projektu KEGA 068UK-4/2011 ako súčasť monografie Počítačové videnie, detekcia a rozpoznávanie objektov.

Cvičebnica sleduje jednotlivé kapitoly monografie a slúži ako podklad pre cvičenia k prednáškam a k samostatnému precvičovaniu učiva.

Každá kapitola obsahuje

1. vypracované príklady na ilustráciu preberanej problematiky,
2. jednoduché otázky na zamyslenie k textu,
3. nevypracované úlohy na precvičenie látky.

Vizuálna detekcia a rozpoznávanie objektov patrí v poslednom desaťročí medzi najväčšie výzvy počítačového videnia. Preto predkladaná cvičebnica pokrývajúca moderné trendy v danej oblasti posilní popri teoretickej aj praktickú zložku vysokoškolského vzdelávania, a prispeje tak širšiemu uplatneniu študentov v priemyselnej praxi.

Snímanie obrazu

1.1 Otázky

1. Vysvetlite princíp fungovania Bayerovho filtra a popíšte štandardné rozloženie jednotlivých farebných filtrov.
2. Vysvetlite pojem hĺbka ostrosti pri kamerách so šošovkou, zamyslite sa prečo pojem hĺbka ostrosti nie je relevantný pri štrbinovej kamere.
3. Popíšte aké sú vnútorné parametre kamery.
4. Nakreslite ako vzniká obraz na priemetni pri štrbinovej kamere a pri kamere so šošovkou.
5. Popíšte rozdiel medzi CCD a CMOS senzorom.

Lineárna a nelineárna filtrácia

2.1 Príklad: Hľadanie hrán pomocou Sobelovho filtra

Tento príklad demonštruje použitie Sobelovho filtra (filtračného jadra) pri hľadaní hrán. Majme na vstupe šedoúrovňový obraz I (obrázok 2.1).




Obrázok 2.1: Šedoúrovňový obraz I

Vytvorme si matice G_x , G_y , ktoré budú slúžiť ako filtračné jadrá.


$$G_x = \begin{bmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{bmatrix} \quad (2.1)$$

$$G_y = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} \quad (2.2)$$

Keď postupne filtrujeme obraz I týmito jadrami, vzniknú nám obrazy S_x (obrázok 2.2) a S_y (obrázok 2.3). Tieto obrazy nám hovoria o hranej odozve v smere x a y .



Obrázok 2.2: Obraz S_x , ktorý vznikol filtrovaním obrazu I jadrom G_x . Hodnoty intenzity sú preškálované kvôli lepšiemu kontrastu.




Obrázok 2.3: Obraz S_y , ktorý vznikol filtrovaním obrazu I jadrom G_y . Hodnoty intenzity sú preškálované kvôli lepšiemu kontrastu.


Aby sme dostali obraz S (obrázok 2.4) s hranovými odozvami v oboch smeroch, použijeme vzťah

$$S = \sqrt{S_x^2 + S_y^2}. \quad (2.3)$$

Výsledný hranový (binárny) obraz E (obrázok 2.5) dostaneme tak, že hodnoty bodov z S porovnáme s určeným prahom t , napr. $t = 0,5$.



Obrázok 2.4: Obraz S , ktorý sme získali z obrazov S_x a S_y . Hodnoty intenzity sú preškálované kvôli lepšiemu kontrastu.



Obrázok 2.5: Výsledný hranový obraz E .

2.2 Otázky

1. Napíšte, aký je rozdiel medzi konvolúciou a koreláciou.
2. Popíšte akými spôsobmi riešime problém s aplikovaním masky na okrajoch obrazu.

3. Navrhните druh filtrácie, ktorý bude najvhodnejší na odstránenie šumu typu salt and peper.
4. Popíšte jednotlivé kroky Cannyho detektora hrán.
5. Ako ovplyvní veľkosť jadra pri priemerovaní výsledný obrázky.
6. Zamyslite sa, ako by vyzeral obraz, ktorý vznikne ako absolútny rozdiel dvoch obrazov, ktoré sme vytvorili nasledovne: obraz 1 vznikol z pôvodného obrazu filtrovaním gaussiánom a obraz 2 vznikol z obrazu 1 opätovným aplikovaním Gaussovho filtra.
7. Aké druhy šumu poznáte, čím môžu byť spôsobené a prečo sa ich snažíme odstrániť.
8. Navrhните filtračné jadro 3×3 , ktoré ignoruje hodnotu stredného pixela a nahrádza ho priemernou hodnotou jeho okolia.

2.3 Úlohy

2.3.1 Filtračné jadrá

Napíšte matice reprezentujúce filtračné jadrá metód Sobel, Previtt, Roberts a pomenujte, aký smer hrán detekujú.


2.3.2 Priemer vs. medián

Aplikujte na maticu M nasledujúce filtre veľkosti 3×3 : priemerovací, mediánový, Gaussovský.

$$M = \begin{bmatrix} 255 & 255 & 255 & 255 & 255 \\ 255 & 255 & 255 & 255 & 255 \\ 255 & 255 & 1 & 255 & 255 \\ 255 & 1 & 1 & 1 & 255 \\ 255 & 255 & 1 & 255 & 255 \\ 255 & 255 & 255 & 255 & 255 \\ 255 & 255 & 255 & 255 & 255 \end{bmatrix} \quad (2.4)$$

2.3.3 Prvá a druhá derivácia

Pozrite si nasledujúcu 1D funkciu (obrázok 2.6), predstavte si, že je to jeden riadok obrazu a nakreslite, ako bude vyzerat' prvá a druhá derivácia.




Obrázok 2.6: Graf 1D funkcie.

Matematická morfológia



3.1 Príklad: Morfológická operácia otvorenia

Pre lepšie pochopenie si najskôr ilustrujeme proces morfolologickej operácie otvorenia (opening) na zjednodušenom prípade. Majme binárny obraz 3.1, kde čierna predstavuje objekt a biela pozadie.




Obrázok 3.1: Binárny obraz.

Aplikujme naň morfológickú operáciu erózie so štruktúrnym elementom veľkosti 3×3 . Prechádzame po riadkoch a začneme v prvom bode objektu (na pozícii 2,4). V tomto bode priložíme bod (0,0) štruktúrného elementu a overíme, či všetkým prvkom štruktúrného elementu



Ak prejdeme všetky body objektu, dostaneme výsledný obraz, ktorý vznikol aplikáciou erózie na pôvodný obraz. Naň potom môžeme aplikovať dilatáciu a dostaneme obraz, ktorý vznikol aplikovaním morfolologickej operácie otvorenia na obraz 3.1 (pozri obrázok 3.4).



Obrázok 3.4: Proces otvorenia. Vľavo: Výsledný obraz po aplikovaní erózie na pôvodný obraz (obrázok 3.1). Vpravo: Výsledný obraz po aplikovaní dilatácie na obraz vľavo.


3.1.1 Morfológická operácia otvorenia na reálnom obraze

Na nasledujúcom príklade si ukážeme, ako funguje morfológická operácia Otvorenia na reálnom obraze. Proces si najskôr ilustrujeme na reálnom obraze 3.5.



Obrázok 3.5: Farebný obraz *I*.

V prvom kroku tento obraz prevedieme na šedoúrovňový a následne použijeme prah $t = 120$ (pre 8-bitový obraz s hodnotami 0 – 255) a vytvoríme binárny obraz 3.6.




Obrázok 3.6: Binárny obraz. Vznikol prevedením obrazu I na šedoúrovňový a následným aplikovaním prahu $t = 120$.

Nasledujúce kroky sú operáciami matematickej morfológie. Najprv na binárny obraz aplikujeme eróziu zo štruktúrnym elementom tvaru disku s priemerom 11 bodov, čím nám vznikne obrázok 3.7. Potom na erodovaný obraz aplikujeme dilatáciu s rovnakým štruktúrnym elementom a vznikne nám obraz 3.8. Následné použitie erózie a dilatácie, ktoré sme v tomto ilustračnom príklade využili sa nazýva morfológickým otvorením.


Takýto binárny obraz môžeme použiť ako masku a pomocou nej vytvoriť segmentáciu objektov 3.9 na pôvodnom farebnom obraze 3.5.

3.2 Otázky


1. Zamyslite sa, ako by ste robili dilatáciu na binárnom, šedoúrovňovom a farebnom obraze.



Obrázok 3.7: Obraz 3.6 po použití erózie.



Obrázok 3.8: Obraz 3.7 po použití dilatácie. Teda obraz 3.6 po použití Otvorenia.



Obrázok 3.9: Segmentácia obrazu 3.5 s využitím obrazu 3.8 ako masky.

2. Akú metódu by ste použili na extrakciu kostry zo šedoúrovňového obrazu.

3. Čo je hlavnou nevýhodou metódy Watershed.
4. Aké dva spôsoby aplikácie metódy watershed poznáte.
5. Ktorá z metód Otvorenie, Uzavretie najlepšie odstráni diery v objektoch.
6. Vysvetlite na príklade, ako ovplyvňuje výsledok použitie štruktúrneho elementu rôzneho tvaru a veľkosti.
7. Napíšte z akých operácií sa skladá operácia Bottomhat.
8. Akú operáciu by ste použili na odstránenie malých objektov z binárneho obrazu.
9. Ako je definovaný štruktúrny element pri operácii Hit-or-Miss.
10. Popíšte, akú metódu by ste využili pri získavaní kontúry objektu.

3.3 Úlohy

3.3.1 Hit and Miss

Nakreslite štruktúrne elementy, pomocou ktorých by ste hľadali pravý horný a dolný roh štvorca (bieleho na čiernom pozadí) pomocou operácie Hit-or-Miss.

3.3.2 Granulometria


Naprogramujte si proces granulometrie, teda roztriedenia objektov v obraze podľa ich veľkosti. V prvom kroku načítajte farebný obraz a preved'te ho na šedoúrovňový. Potom použite vhodnú metódu na oddelenie pozadia a popredia (skúste napríklad metódu watershed) a vytvorte binárny obraz. Potom aplikujte granulometriu.

3.3.3 Tophat

Aplikujte operáciu Tophat so štruktúrnym elementom tvaru štvorca so stranou veľkosti 3 pixle (3×3) na binárny obraz 3.1 (V tomto prípade predstavuje čiena objekt a biela pozadie).

3.3.4 Kostra


Vytvorte kostru pre objekty na obraze 3.10.



Obrázok 3.10: Obraz k úlohe Kostra.

3.3.5 Odstránenie objektov s využitím matematickej morfológie

Aký štruktúrally element a akú operáciu by ste použili na odstránenie obdĺžnikov z obrazu 3.11, pričom všetky ostatné objekty by mali zostať nezmenené (v tomto prípade predstavuje biela objekty a čierna pozadie).



Obrázok 3.11: Obraz k úlohe Odstránenie objektov s využitím matematickej morfológie.

Fourierova transformácia a diskrétna kosínusová transformácia

4.1 Príklad: Filtrovanie šumu vo frekvenvenecnej oblasti

Na nasledujúcom príklade si ukážeme, ako sa dá použiť FFT pri filtrovaní šumu v obraze.


Majme na vstupe šedoúrovňový obraz (obrázok 4.1). Transformujme ho pomocou FFT do Fourierovej domény. Pozrime si ako vyzerá jeho amplitúdový obraz na obrázku 4.3. Môžeme si všimnúť že tento obraz je stredovo súmerný. Od stredu obrazu smerom ku krajom obsahuje obraz hodnoty amplitúdy pre najnižšie smerom k najvyšším frekvenciám. Ak je v určitom bode hodnota 1, znamená to, že daná frekvencia (pre x a y podľa riadku a stĺpca) je v obraze prítomná s amplitúdou 1. Ak sa v určitom bode nachádza hodnota 0, znamená to, že daná frekvencia sa v obraze nenachádza. Ak niektoré hodnoty v obraze nastavíme na 0 (pozri obrázok 4.4) a spravíme spätne inverznú FFT, dostaneme obraz, v ktorom sa dané frekvencie vyskytovať nebudú (pozri obrázok 4.5). Ak napríklad nastavíme všetky okrajové hodnoty obrazu na 0, nebude výsledný obraz obsahovať najvyššie frekvencie a teda ostré hrany. Ak v ďalšom kroku odstránime ešte väčší rozsah frekvencií (pozri obrázok 4.6), bude náš výsledný obraz rozmazanejší (pozri obrázok 4.7).



Obrázok 4.1: Šedoúrovňový obraz




Obrázok 4.2: Šedoúrovňový obraz s pridaným gaussovským šumom



Obrázok 4.3: Obraz amplitúdového spektra po aplikovaní fourierovej transformácie na obrázok 4.2

4.2 Otázky


1. Vysvetlite dualitu frekvenčnej a obrazovej domény pri používaní konvolúcie.



Obrázok 4.4: Obráz amplitúdového spektra s maskou.



Obrázok 4.5: Obráz ktorý vznikol aplikovaním inverznej fourierovej transformácie na 4.4



Obrázok 4.6: Obráz amplitúdového spektra s maskou.

2. Ako sa využíva Fourierova transformácia na zrýchlenie výpočtu pri filtrovaní obrazov.



Obrázok 4.7: Obráz ktorý vznikol aplikovaním inverznej fourierovej transformácie na obráz 4.6.

3. Vysvetlite čo je to high-pass filter a ako by ste ho použili.
4. Popíšte, ako by ste vytvorili band-pass filter.
5. Nakreslite, ako by vyzeral obráz, v ktorom by bola iba najvyššia možná frekvencia s najvyššou možnou amplitúdou na osi y .
6. Načrtnite, ako by vyzerali nasledujúce filtre vo Fourierovej doméne: Gaussian, Laplacian, Priemerovací filter, Sobel v x -ovom a Sobel v y -ovom smere.

4.3 Úlohy

4.3.1 Fourierove spektrum


Správne prirad'te obrázky 4.8 k obrázkom 4.9 ich Fourierovho spektra (amplitúdové zobrazenie). Zdôvodnite.

4.3.2 Posunutie


Budú sa líšiť amplitúdové obrazy Fourierovho spektra v obrázkoch 4.10? Vysvetli prečo.

4.3.3 Kruh a pruh


Popíšte, ako bude vyzerat' výsledný obraz, ak vo Fourierovom spektre pre obraz kruhu nakreslíme v strede čierny kruh ako na obrázku 4.11 a použijeme inverznú Fourierovu transformáciu.




Obrázok 4.8: Binárne obrázky k úlohe Fourier 1.



Obrázok 4.9: Fourierove spektrá k úlohe Fourier 1.




Obrázok 4.10: Binárne obrázky k úlohe Fourier 2.



Obrázok 4.11: Binárne obrazy k úlohe Fourier 3.

4.3.4 Amplitúda a fáza

Ako sa budú líšiť Fourierové spektrá (Amplitúda a Fáza) pre obrázky 4.12?



Obrázok 4.12: Binárne obrazy k úlohe Fourier 4.


Príznamy

5.1 Príklad: Príznamy textúry – matica opakovaných výskytov


Tento príklad je ukážkou použitia textúrneho príznaku, matice opakovaných výskytov. Majme šedoúrovňový obraz A veľkosti 5×5 pixelov, ktorý sme kvantovali na 5 úrovni šedej (obsahuje hodnoty 0,1,2,3,4). Vypočítajme preňho maticu opakovaných výskytov pre smer vodorovne doprava (0°) a vzdialenosť 1 teda $d_x(0, 1)$. Maticu opakovaných výskytov môžeme počítať napríklad pre 4 smery, vodorovne, zvislo a v smere dvoch diagonál teda: 0° , 90° , 45° , 135° . Na obrazoch 5.1 a 5.2 je znázornený šedoúrovňový obraz A a jeho matica opakovaných výskytov C . Červené okienka a šípky naznačujú ako vznikli jednotlivé hodnoty v matici opakovaných výskytov.

5.2 Príklad: Lokálne príznaky


V nasledujúcom príklade si ukážeme ako sa dajú použiť lokálne príznaky na detekciu inštancií objektov. V našom prípade to bude obal knihy na obrázku 5.4. Keďže objekt, ktorý hľadáme má tvar kvádra a my budeme používať iba jeho prednú stranu (obdĺžnik), vyznačíme si v obraze 4 rohy a ich pozície si zapamätáme.




Obrázok 5.1: Obráz A a jeho matica opakovaných výskytov C.



Obrázok 5.2: Obráz A a jeho matica opakovaných výskytov C.




Obrázok 5.3: Vzorový objekt.




Obrázok 5.4: Testovací obraz.

V druhom kroku extrahujeme pomocou metódy SIFT lokálne príznaky. Najskôr použijeme detektor, ktorým nájdeme zaujímavé body (teda také, v ktorých okolí sa mení intenzita) a tieto následne popíšeme príznakovým vektorom. Detektor metódy SIFT hľadá zaujímavé body pomocou tzv. škálovej pyramídy, ktorá obsahuje pôvodný obraz v rôznych škálach a v rôznych úrovniach rozostrenia (spôsobené filtráciou Gaussovým filtrom). Podľa toho, v ktorej úrovni pyramídy nájdeme zaujímavý bod, zvolíme veľkosť okolia, z ktorého budeme vytvárať popisný vektor - deskriptor. Toto okolie ešte zorientujeme podľa dominantnej orientácie gradientu v okolí. Potom vytvoríme deskriptor zodpovedajúci 16 histogramom orientácií gradientov v okolí, teda obsahujúci 128 hodnôt. Na obrázku 5.5 vidíme zaujímavé body reprezentované šípkami, ktorých smer a veľkosť sú definované gradientom v okolí zaujímavého bodu.

Ak máme obrázky reprezentované pomocou ich deskriptorov, môžeme prejsť do fázy porovnávania. Pre každý deskriptor obrazu 5.4 nájdeme najbližší a druhý najbližší deskriptor vzorového obrazu 5.5. Potom použijeme mieru navrhnutú v pôvodnom SIFT článku - ak je najbližší deskriptor bližší ako 0,8 násobok druhého najbližšieho, považujeme ich za správny pár. Vzájomné párovanie medzi našimi obrazmi vidíme na obrázku 5.6.




Obrázok 5.5: Zaujímavé body detegované metódou SIFT. Smer červených šípkok predstavuje dominantný smer gradientu v okolí daného bodu. Veľkosť okolia je vyjadrená dĺžkou šípkky.



Obrázok 5.6: Spárované deskriptory. Zelené čiary spájajú body na testovacacom obraze s bodmi na vzorovom obraze, ktoré majú najmenšiu vzdialenosť popisných vektorov - deskriptorov.

Teraz môžeme jednoducho použiť prah na počet párov, ktorý určí, či sa na obrázku obal knihy nachádza, alebo nie (ak je počet párov väčší, alebo menší ako prah). Druhou možnosťou je, že použijeme RANSAC prístup na overenie geometrickej transformácie medzi inštanciami objektu na obrazoch. Touto transformáciou je homografia. Výsledkom je

podmnožina outlierov a inlierov z pôvodnej množiny všetkých párov a transformácia medzi obrazmi. Vo finále môžeme použiť súradnice 4 rohov, ktoré sme si zaznamenali v prvom kroku, transformovať ich do testovaného obrazu a vytvoriť masku výskytu knihy v obraze, rovnako ako na obrázku 5.7.



Obrázok 5.7: Maska výskytu vzorového objektu v testovacom obraze 5.4.

5.3 Otázky

1. Prečo je vhodné použiť kvantovanie farebného priestoru pri príznakoch vyjadrujúcich výskyt jednotlivých farieb.
2. Navrhните príznak na odlíšenie farebnej a šedoúrovňovej fotografie (pričom sú obe reprezentované v RGB).
3. Vysvetlite prečo sa robí tzv. normalizácia príznakov.
4. Popíšte čo sú Gaborove filtre a na čo sa používajú.
5. Aký príznak tvaru by sme mohli použiť na odlíšenie štvorca a obdĺžnika.
6. Vysvetlite čo sú reťazcové kódy a popíšte ako by ste ich použili pri identifikácii tvaru objektu, ktorého natočenie sa môže meniť. Popíšte ako by ste ich použili v prípade, že by sa menila aj škála objektu.

7. Aký textúrny príznak by ste použili na odlíšenie obrazov štrku a piesku.
8. Aká je hlavná výhoda použitia binárnych deskriptorov lokálnych príznakov v porovnaní s celočíselnými.
9. Vysvetlite, ako sa dosahuje škálová invariancia pri metóde SIFT.

5.4 Úlohy

5.4.1 Matica opakovaných výskytov

Použite obraz A z príkladu Príznačky textúry- Matica opakovaných výskytov a vypočítajte jeho maticu opakovaných výskytov pre smer zvislo nahor (90°) a vzdialenosť 1 teda $d_y(0, 1)$.

5.4.2 Rozpoznávanie fotografií a malieb

V článku *Distinguishing paintings from photographs* autori identifikovali viacero príznakov, ktoré sú vhodné na rozlišovanie fotografií a malieb. Svojím výskumom zistili, že:

1. Zmena farby medzi pixelmi je výraznejšia v maľbách.
2. Maľby obsahujú hlavne vysoko saturované farby.
3. Odstránením farby z obrazu zachováme väčšinu hrán vo fotografii, ale odstránime väčšinu hrán z maľby. Je to spôsobené tým, že väčšina hrán na fotografiách je spôsobená zmenou intenzity, interakciou svetla a povrchov s rôznou odrazivosťou a textúrou, ale hrany v maľbách sú väčšinou na prechodoch medzi rôznymi farbami ktoré reprezentujú rozličné objekty a oblasti.

Vašou úlohou je matematicky vyjadriť všetky tri príznaky a implementovať ich. Potom si môžete stiahnuť obrázky malieb (napríklad zo stránky niektorej online galérie) a spolu s vašimi fotografiami z nich extrahovať jednotlivé príznaky. Pomocou týchto dát potom môžete natréňovať niektorý z klasifikátorov. Tomuto kroku sa budeme venovať v ďalšej časti cvičebnice.

5.4.3 Odlíšenie fotografií budov a prírody

Navrhните a implementujte príznaky, ktoré by sa dali použiť na rozpoznanie fotografií budov a prírody. Zamyslite sa nad charakteristickými črtami, ktoré obsahujú snímky budov (množstvo hrán, rovnomerné slabosaturované farebné plochy, odlesky od okien...) a snímky prírody (charakteristické saturované farby, bez ostrých hrán, zväčša rozdelené na nebo a krajinu).

Predspracovanie príznakov


6.1 Príklad: Znižovanie dimenzie – PCA

V nasledujúcom príklade si ukážeme, ako funguje redukcia dimenzionality využívajúca PCA, teda Principal Component Analysis.

Predstavme si, že máme popísané naše dáta (10 meraní/ 10 obrazov) 2 druhmi príznakov x a y (pre konkrétne hodnoty x a y pozri tabuľku 6.1). Zobrazenie týchto dát vidíme na obrázku 6.1. Najskôr vypočítame priemer dát pre každý príznak a potom tento priemer odpočítame od všetkých príslušných nameraných hodnôt (pozri stĺpec 3 a 4).

x	y	$x - \bar{x}$	$y - \bar{y}$
2,5	2,4	0,69	0,49
0,5	0,7	-1,31	-1,21
2,2	2,9	0,39	0,99
1,9	2,2	0,09	0,29
3,1	3	1,29	1,09
2,3	2,7	0,49	0,79
2	1,6	0,19	-0,31
1	1,1	-0,81	-0,81
1,5	1,6	-0,31	-0,31
1,1	0,9	-0,71	-1,01

Tabuľka 6.1



Obrázok 6.1: Zobrazenie dát v pôvodnom súradnicovom systéme.

V ďalšom kroku vypočítame kovariančnú maticu z nameraných dát (teda odhad skutočnej kovariančnej matice). Keďže naše dáta sú dvojrozmerné bude veľkosť kovariančnej matice 2×2 :

$$Cov = \begin{pmatrix} 0,616555 & 0,615444 \\ 0,615444 & 0,716555 \end{pmatrix}. \quad (6.1)$$


Keď máme vypočítanú kovariančnú maticu, vypočítame si jej jednotkové vlastné vektory a vlastné čísla. Dostaneme 2 vlastné vektory ($\mathbf{v}_1, \mathbf{v}_2$), ktoré sú navzájom kolmé a prislúchajú im vlastné čísla.

$$(\mathbf{v}_1, \mathbf{v}_2) = \begin{pmatrix} 0,67787 & -0,73517 \\ 0,73517 & 0,67787 \end{pmatrix}, \quad (6.2)$$

$$\lambda = \begin{pmatrix} 0,04908 \\ 1,28402 \end{pmatrix}. \quad (6.3)$$

V ďalšom kroku utriedime vlastné vektory podľa veľkosti ich vlastných čísel od najmenšieho po najväčšie. Potom vyberieme toľko prvých vlastných vektorov, koľko dimenzionálne majú byť naše výsledné dáta (ak

zoberieme pôvodný počet dimenzií, môžeme dáta transformovať do nového priestoru a späť bez straty informácie). Pôvodné dáta transformované do súradnicového systému definovaného dvoma hlavnými komponentami vidíme na obrázku 6.2.



Obrázok 6.2: Zobrazenie dát v súradnicovom systéme definovanom dvoma hlavnými komponentami.

6.2 Otázky

1. Popíšte ako funguje SVD.
2. Vysvetlite, aký je rozdiel medzi PCA a LDA.
3. Ako by ste využili redukciiu dimenzionality pri lokálnych príznakoch.
4. Načo je dobrá redukcia dimenzionality príznakov.
5. Popíšte, ako by ste normalizovali príznak počet vysoko saturovaných pixelov.

6. Premyslite si a popíšte normalizáciu veľkosti obrazov vs. normalizáciu príznakov.

6.3 Úlohy

6.3.1 PCA-SIFT

Implementujte PCA-SIFT, teda metódu, ktorá redukuje 128-hodnotový vektor – deskriptor vytvorený metódou SIFT na 20-hodnotový vektor, reprezentujúci iba hlavné komponenty pôvodného deskriptora. Popíšte, aké sú výhody a nevýhody takéhoto deskriptora a ako sa zmení čas výpočtu a čas porovnávania deskriptorov.

6.3.2 Normály

Predstavte si, že ste pomocou 3D skenera (napríklad technológiou štruktúrovaného svetla) zoskenovali objekt a teraz máte jeho reprezentáciu mračnom bodov. Navrhните, ako by ste použili metódu PCA na získanie normál povrchu v jednotlivých bodoch. Uvažujte mračno bodov, ktoré dobre popisuje daný povrch a obsahuje len málo outlierov.

Pomôcka: použite guľové okolie bodu. Uvedomte si, čo v takomto prípade budú predstavovať prvé dva hlavné komponenty vypočítané z okolia pomocou PCA.

Výber príznačkov

7.1 Entropia

Entropia je veličina pomocou ktorej dokážeme v teórii informácií určiť mieru neurčitosti daného javu. V prípade, že chceme zistiť, koľko informácie je celkovo v náhodnej premennej, vypočítame to spriemerovaním informácie všetkých hodnôt, ktoré môže náhodná premenná nadobudnúť. Informačná (Shannonova) entropia diskkrétnej náhodnej premennej Y , ktorá nadobúda hodnoty $\mathcal{Y} = \{y\}$ s pravdepodobnosťou $P(Y = y) = p(y)$ je daná vzťahom

$$H(Y) = - \sum_{y \in \mathcal{Y}} p(y) \log_2 p(y). \quad (7.1)$$

7.1.1 Príklad: Výpočet entropie

Máme sad listnatých stromov, ktoré však napadla hniloba koreňov. Preto sme si vytvorili tabuľku všetkých stromov v našom sade, kde máme určený druh stromu (jablň, orech, slivka) a informáciu, či bol napadnutý hnilobou koreňov, alebo nie (tabuľka 7.1). Našou úlohou je určiť entropiu, špecifickú podmienenú entropiu a vzájomnú informáciu pre nami zistené informácie. Najprv určíme entropiu $H(X)$ pre informáciu o druhu stromu

	Druh stromu (X)	Hniloba koreňov (Y)
1	jabloň	áno
2	orech	nie
3	slivka	áno
4	jabloň	nie
5	jabloň	nie
6	slivka	áno
7	orech	nie
8	jabloň	áno

Tabuľka 7.1: Informácia o chorobe stromov v sade

$$\begin{aligned}
 H(X) &= - \sum_{x \in \mathcal{X}} p(x) \log_2 p(x) = -\left(\frac{1}{2} \log_2 \frac{1}{2} + \frac{1}{4} \log_2 \frac{1}{4} + \frac{1}{4} \log_2 \frac{1}{4}\right) = \\
 &= -\left(-\frac{1}{2} - \frac{2}{4} - \frac{2}{4}\right) = 1,5
 \end{aligned}$$

Následne si určíme entropiu pre informáciu o tom, či bol strom napadnutý hnilobou koreňov, alebo nie $H(Y)$

$$H(Y) = - \sum_{y \in \mathcal{Y}} p(y) \log_2 p(y) = -\left(\frac{1}{2} \log_2 \frac{1}{2} + \frac{1}{2} \log_2 \frac{1}{2}\right) = -\left(-\frac{1}{2} - \frac{1}{2}\right) = 1$$

Určíme si špecifickú podmienenú entropiu

$$H(Y|X = \text{jabloň}) = -\left(\frac{1}{2} \log_2 \frac{1}{2} + \frac{1}{2} \log_2 \frac{1}{2}\right) = -\left(-\frac{1}{2} - \frac{1}{2}\right) = 1$$

$$H(Y|X = \text{orech}) = -(0 + 1 \log 1) = -(0) = 0$$

$$H(Y|X = \text{slivka}) = -(1 \log 1 + 0) = -(0) = 0$$

Vzájomná informácia

$$I(Y|X) = H(Y) - H(Y|X) = 1 - 0,5 = 0,5$$

Na základe daných výpočtov sme zistili, že hnilobou koreňov máme napadnutú polovicu stromov ($H(Y)$) v našom sade. Z jabloní máme napadnutú polovicu stromov ($H(Y|X = \text{jabloň})$). V prípade orechov vieme, že všetky stromy sú napadnuté hnilobou koreňov ($H(Y|X = \text{orech})$). Zo sliviek ($H(Y|X = \text{slivka})$) nie je napadnutá hnilobou koreňov ani jedna.

7.2 Otázky

1. Vysvetlite, kde sa používa výber príznakov.
2. Popíšte rozdiel medzi dvomi základnými prístupmi k výberu príznakov.
3. Popíšte princíp dopredného výberu príznakov.
4. Načrtnite algoritmus iteratívneho spätného výberu príznakov.
5. Popíšte kombinovaný výber príznakov.
6. Popíšte, čo vyjadruje Pearsonov korelačný koeficient. Aké hodnoty môže nadobúdať? Uved'te príklady.
7. Popíšte, kedy nastáva nekonzistencia dát a vyjadrite mieru konzistencie.
8. Vysvetlite, čo určujeme pomocou medzitriednej vzdialenosti.
9. Popíšte entropiu a jej matematické vyjadrenie.
10. Napíšte a vysvetlite predpis pre podmienenú entropiu.
11. Vysvetlite, čo udáva vzájomná informácia. Napíšte a vysvetlite jej predpis.
12. Vysvetlite na čo sa využívajú hodnotiace miery.

7.3 Úlohy

7.3.1 Výber príznakov

Majme databázu 20 miest, kde pre každé z nich máme k dispozícii nasledujúce údaje: hustota zaľudnenia, priemerná januárová teplota, priemerná júnová teplota, priemerná vlhkosť vzduchu, úhrn zrážok, znečistenie uhl'ovodíkmi HC, oxidmi dusíka NO_x a oxidom siričitým SO_2 (tabuľka 7.2).

Máme úlohu, kde na základe dát z tabuľky chceme mestá rozdeliť do 3 tried podľa hustoty obyvateľstva

- menej ako 3000 obyvateľov na km^2 (Akron, Dallas, Springfield, Nashville, San Jose, Hartford)

- 3000-5000 obyvateľov na km² (San Diego, Atlanta , Providence, San Francisco, Indianapolis, Miami, Boston, LA, Detroit)
- viac ako 5000 obyvateľov na km² (St. Louis, Washington, Philadelphia, Chicago, New York)

Niektoré z daných dát z tabuľky môžu byť relevantnejšie pre toto rozdelenie a naopak, iné môžu byť menej relevantné. Preto je výhodné pred klasifikáciou zredukovať počet príznakov, ktoré sa budú pri nej používať. Vašou úlohou je preto naprogramovať

- a) dopredný výber príznakov
- b) spätný výber príznakov
- c) kombinovaný výber príznakov

tak, aby sme mali k dispozícii 4 príznaky, teda zredukujete počet príznakov o 3. Následne si vyberte klasifikátor, kde postupne použijete príznaky vybrané rôznymi prístupmi. Výsledky porovnajte, zdôvodnite a určite najvhodnejší prístup k redukcii príznakov.

Mesto	Hustota obyv/km ²	Priemerná teplota január	Priemerná teplota jún	Priemerná vlhkosť vzduchu	Priemerný úhrn zrážok	HC	NO _x	SO ₂
Akron	3320	-3	35	62	36	48	42	59
Atlanta	3225	14	44	58	40	60	37	44
Boston	4680	-4	41	57	45	79	32	62
Dallas	1420	13	43	52	32	1	1	1
Detroit	4915	-3	41	61	32	52	35	102
Hartford	2870	-4	38	51	41	7	3	10
Chicago	6345	-4	39	56	31	220	190	278
Indianapolis	4387	-5	40	58	34	77	56	64
LA	4756	18	34	45	13	150	190	98
Miami	4676	30	45	57	56	59	72	78
Nashville	2672	7	38	49	45	17	14	56
New York	7530	2	40	54	42	264	212	108
Philadelphia	6015	1	39	53	40	315	230	161
Providence	3497	-4	38	52	40	87	47	76
San Diego	3003	22	36	56	12	144	66	72
San Francisco	4301	14	30	64	17	211	171	86
San Jose	2698	18	30	68	12	46	32	3
Springfield	1820	-3	32	54	40	5	1	20
St.Louis	5134	-1	41	56	31	250	225	130
Washington	5287	7	42	50	41	266	342	124

Tabuľka 7.2: Tabuľka dát k úlohe Výber príznakov

Klasifikácia

8.1 Naivný Bayesovský klasifikátor

Naivný Bayesovský klasifikátor vychádza z predpokladu, že efekt, ktorý má hodnota (každého) príznaku na danú triedu, nie je ovplyvnený hodnotami ostatných príznakov. Na výpočet aposterioriórnych pravdepodobností každej triedy použijeme Bayesovo pravidlo

$$P(\omega_i|\mathbf{x}) = \frac{P(\mathbf{x}|\omega_i)P(\omega_i)}{P(\mathbf{x})}. \quad (8.1)$$

Naivný Bayesovský klasifikátor slúži na priradenie objektu $\mathbf{x}$ do čo najpravdepodobnejšej triedy ω_i podľa jeho príznakov, ak pre každé $j \neq i$ platí

$$\frac{P(\mathbf{x}|\omega_i)P(\omega_i)}{P(\mathbf{x})} \geq \frac{P(\mathbf{x}|\omega_j)P(\omega_j)}{P(\mathbf{x})}. \quad (8.2)$$

Hodnota $P(\mathbf{x}) = \sum_{j=1}^K P(\mathbf{x}|\omega_j)P(\omega_j)$ sa vyskytuje na oboch stranách nerovnice, preto vzorka $\mathbf{x}$ patrí do triedy ω_{i^*} , ktorej rozhodovacia funkcia

$$d_i(\mathbf{x}) = P(\mathbf{x}|\omega_i)P(\omega_i) \quad (8.3)$$

dosiahne najvyššiu hodnotu

$$i^* = \arg\max_i d_i(\mathbf{x}). \quad (8.4)$$

8.1.1 Príklad: Klasifikácia pomocou Naivného Bayesovského klasifikátora

Majme autá, kde ich príznakmi sú farba, typ, pôvod a fakt, či bolo, alebo nebolo ukradnuté:

poradové číslo	farba	typ	pôvod	ukradnuté?
1	červená	športové	domáce	áno
2	červená	športové	domáce	nie
3	červená	športové	domáce	áno
4	žltá	športové	domáce	nie
5	žltá	športové	import	áno
6	žltá	SUV	import	nie
7	žltá	SUV	import	áno
8	žltá	SUV	domáce	nie
9	červená	SUV	import	nie
10	červená	športové	domáce	áno

Našou úlohou je určiť, či nám môžu ukradnúť červené domáce SUV (x). Keďže nemáme žiaden prípad takéhoto auta v našej databáze, potrebujeme si daný prípad vypočítať.

Najprv potrebujeme určiť pravdepodobnosti $P(x_k|\omega_i)$ podľa vzťahu

$$P(x_k|\omega_i) = \frac{N^{i,k}}{N^i}, \quad (8.5)$$

kde $N^{i,k}$ predstavuje počet objektov patriacich do triedy ω_i s príznakom x_k a N^i predstavuje počet všetkých objektov v triede i .

áno červená $N^1 = 5$ $N^{1,1} = 3$	nie červená $N^2 = 5$ $N^{2,1} = 2$
áno SUV $N^1 = 5$ $N^{1,2} = 1$	nie SUV $N^2 = 5$ $N^{2,2} = 3$
áno domáce $N^1 = 5$ $N^{1,3} = 2$	nie domáce $N^2 = 5$ $N^{2,3} = 3$

V prípade $P(\text{červená}|\text{áno})$ máme 5 prvkov, kde $\omega_j = \text{áno}$ a kde 3 z tých prípadov sú $a_i = \text{červená}$. Preto pre $P(\text{červená}|\text{áno})$, $N^1 = 5$ a $N^{1,1} = 3$.

Následne môžeme určiť všetky pravdepodobnosti

$$P(\text{červené}|\text{áno}) = \frac{3}{5} = 0,6 \quad P(\text{červené}|\text{nie}) = \frac{2}{5} = 0,4$$

$$P(\text{SUV}|\text{áno}) = \frac{1}{5} = 0,2 \quad P(\text{SUV}|\text{nie}) = \frac{3}{5} = 0,6$$

$$P(\text{domáce}|\text{áno}) = \frac{2}{5} = 0,4 \quad P(\text{domáce}|\text{nie}) = \frac{3}{5} = 0,6$$

Máme $P(\text{áno}) = 0,5$ a $P(\text{nie}) = 0,5$. Dosadením do vzorca (8.3) dostávame pre $\omega = \text{áno}$

$$d_1(\mathbf{x}) = P(\text{áno}) * P(\text{červená}|\text{áno}) * P(\text{SUV}|\text{áno}) * P(\text{domáce}|\text{áno}) = 0,5 * 0,6 * 0,2 * 0,4 = 0,024$$

a pre $\omega = \text{nie}$

$$d_2(\mathbf{x}) = P(\text{nie}) * P(\text{červená}|\text{nie}) * P(\text{SUV}|\text{nie}) * P(\text{domáce}|\text{nie}) = 0,5 * 0,4 * 0,6 * 0,6 = 0,072$$

Keďže $0,024 < 0,072$, a teda $d_1 < d_2$ náš prípad môžeme klasifikovať ako nie, teda auto nám pravdepodobne neukradnú.

8.2 Otázky


1. Z akého predpokladu vychádza naivný Bayesovský klasifikátor.
2. Popíšte od čoho závisí tvar rozhodovacej hranice v Bayesovskom klasifikátore. Uveďte príklady.
3. Vysvetlite princíp techniky najbližších susedov.
4. Popíšte čo spôsobuje pri technike najbližších susedov zvyšovanie parametra K .
5. Vysvetlite, čo znázorňujú uzly a listy v rozhodovacích stromoch.
6. Popíšte algoritmus tvorby rozhodovacieho stromu.
7. Popíšte rozdeľujúce kritériá pri rozhodovacích stromoch.
8. Vysvetlite, na čo slúži orezávanie stromov.

9. Popíšte princíp lineárnej diskriminačnej funkcie.
10. Vysvetlite určovanie váh pri klasifikácii pomocou lineárnej diskriminačnej funkcie.
11. Popíšte dva hlavné spôsoby klasifikácie do K tried pomocou diskriminačnej funkcie.
12. Popíšte hlavný rozdiel medzi diskriminačnou analýzou a metódou podporných vektorov.
13. Vysvetlite pojem Lagrangeove multiplikátory.
14. Popíšte rozdiel medzi SVM s voľným okrajom a nelineárnym SVM. Vysvetlite, kedy sa využívajú a prečo.
15. Popíšte, aké typy často využívaných aktivačných funkcií existujú pre NS.
16. Vysvetlite pojem skrytá vrstva v NS.
17. Popíšte rozdiel medzi riadenými a neriadenými technikami klasifikácie.
18. Vysvetlite princíp techniky K priemerov.
19. Popíšte aglomeratívne zhlukovanie.
20. Popíšte rozdiel medzi SOM a ANN.
21. Od čoho závisí hustota máp pri SOM.
22. Vysvetlite nedostatky SOM.

8.3 Úlohy

8.3.1 Rozhodovacie stromy

Majme štúdiu, kde bola na základe výskumu veľkého množstva pacientov ukázaná korelácia medzi vekom pacienta, jeho krvným tlakom a rizikom mŕtvice (obrázok 8.1). Na obrázku je znázornená tabuľka, ktorá predstavuje toto priemerné riziko podľa veku a tlaku krvi pacienta. Navrhnite rozhodovací strom pre riziko mŕtvice nasledovne



Obrázok 8.1: Tabuľka znázorňujúca stúpajúce riziko ochorenia v závislosti na veku a krvnom tlaku pacienta

a) 7 tried (farebne rozlíšené)

b) 3 triedy:


- nízke (5 % – 10 %)
- stredné (20 % – 40 %)
- vysoké riziko (50 % – 60 %)

8.3.2 Metóda K najbližších susedov


Na obrázku 8.2 a) – c) sú znázornené dáta, ktoré sú rozdelené do kategórií. Toto rozdelenie je znázornené rôznymi farbami. Pre každý z nových bodov (čierna farba) navrhните

- metriku pre určovanie vzdialenosti,
- počet susedov.

Popíšte rozdiel klasifikácie v príklade b) pri použití euklidovskej a manhattanskej metriky. Zdôvodnite. Popíšte, ako by sa zmenila výsledná klasifikácia pri použití iných metrík a počtov susedov. Zdôvodnite.



Obrázok 8.2: Obrázok k úlohe K najbližších susedov.



Obrázok 8.3: Dáta rozdelené rozdeľujúcou nadrovinou použitím lineárneho klasifikátora.

8.3.3 Lineárny klasifikátor

Na obrázku 8.3 sú znázornené dáta a ich rozdeľujúca nadrovina, ktorá bola určená pomocou lineárneho klasifikátora. Aký problém nastane pri klasifikácii testovacích dát? Zdôvodnite, prečo vznikol daný problém a navrhnite jeho riešenie.

8.3.4 Metóda K priemerov

Majme dáta, kde máme pre každé pozorovanie ($M_1, \dots, M_5$) určené dve hodnoty X a Y :

	X	Y
M_1	1	1
M_2	2	1
M_3	4	3
M_4	5	4
M_5	6	2

Rozdeľte dané dáta do

- $K = 2$ skupín. Ako vstupné centroidy majme vzorky M_1 a M_2 .
- $K = 3$ skupín. Ako vstupné centroidy majme vzorky M_1 , M_2 a M_3 .

Každý krok zakresľujte do grafu.

Hodnotenie kvality klasifikácie

9.1 Príklad: Vytvorenie matice zámen

Matica zámen slúži na vyhodnocovanie kvality klasifikátorov. Dáva informáciu o súvislosti výsledkov klasifikácie dát s informáciou o ich správnom zaradení do tried.

Skutočnosť \ Rozhodnutie	Negatívne	Pozitívne
Negatívne	a	b
Pozitívne	c	d

Tabuľka 9.1: Matica zámen

V tabuľke 9.1 je znázornená matica zámen pre 2 klasifikačné triedy, kde

- a** je počet správnych zaradení prvkov ako negatívnych,
- b** je počet nesprávnych zaradení prvkov ako pozitívnych,
- c** je počet nesprávnych zaradení prvkov ako negatívnych,
- d** je počet správnych zaradení prvkov ako pozitívnych.

Z danej matice môžeme získať informáciu o celkovej správnosti klasifikácie ako podiel správne zaradených prvkov a všetkých prvkov

$$AC = \frac{a + d}{a + b + c + d}. \quad (9.1)$$

	HT áno	HT nie
celé dáta: 456	146 (32 %)	310 (68 %)
trénovacie: 292 (64 %)	93 (32 %)	199 (68 %)
testovacie: 164 (36 %)	49 (30 %)	115 (70 %)

Tabuľka 9.2: Rozdelenie vstupných dát na testovacie a trénovacie

Skutočnosť \Systém	HT áno	HT nie	HT ?
HT áno	56	34	3
HT nie	6	192	1

Tabuľka 9.3: Matica zámen pre rozhodovací strom na trénovacích dátach

Skutočnosť \Systém	HT áno	HT nie
HT áno	93	0
HT nie	0	199

Tabuľka 9.4: Matica zámen pre neurónovú sieť na trénovacích dátach

9.1.1 Príklad: Vyhodnotenie kvality klasifikátora použitím matice zámen

Našou úlohou je na základe príznakov určiť, či pacient má, alebo nemá hypertenziu (HT, vysoký krvný tlak). K dispozícii máme údaje o 456 pacientoch, kde pri každom pacientovi máme určený jeho vek, výšku, váhu a hladinu cukru. Na základe daných príznakov chceme zistiť hrozbu hypertenzie.

Najprv je potrebné rozdeliť dáta na trénovacie a testovacie. V ideálnom prípade bude rozdelenie pacientov s hypertenziou a bez nej čo najpodobnejšie pri testovacích, aj trénovacích dátach. V tabuľke 9.2 je znázornené rozdelenie našich dát.

Na klasifikáciu daných dát sme použili dva klasifikátory: rozhodovací strom a neurónové siete. V tabuľkách 9.3 a 9.4 sú zobrazené matice zámen pre trénovacie dáta pri oboch klasifikátoroch.

V tabuľkách 9.5 a 9.6 sú zobrazené matice zámen pre testovacie dáta pri oboch klasifikátoroch.

Skutočnosť \Systém	HT áno	HT nie	HT ?
HT áno	20	27	2
HT nie	10	105	0

Tabuľka 9.5: Matica zámen pre rozhodovací strom na testovacích dátach

Skutočnosť \Systém	HT áno	HT nie
HT áno	39	10
HT nie	8	107

Tabuľka 9.6: Matica zámen pre neurónovú sieť na testovacích dátach

	trénovacie dáta	testovacie dáta
rozhodovací strom	85 %	76 %
neurónová sieť	100 %	89 %

Tabuľka 9.7: Výsledná úspešnosť porovnávaných klasifikátorov

Pri vyhodnocovaní klasifikátorov vychádzame z matice zámen, z ktorej môžeme určiť správnosť klasifikácie dosiahnutej na trénovacích aj testovacích dátach. Ako z prevedených testov vyplýva (tabuľka 9.7), neurónová sieť lepšie výsledky v porovnaní s rozhodovacím stromom pre testovacie a rovnako aj trénovacie dáta.

9.2 Otázky

1. Vysvetlite, čo znamená preučenie klasifikátora.
2. Vymenujte množiny dát, aké používame pri určovaní kvality klasifikátora.
3. Vysvetlite metódu vzájomnej validácie.
4. Vysvetlite rozdiel medzi K-násobnou vzájomnou validáciou a vzájomnou validáciou s vynechaním jednej vzorky.
5. Vysvetlite pojem chybová funkcia klasifikátora.

6. Popíšte maticu zámen a jej vytváranie pre viac klasifikačných tried.
7. Vysvetlite pojem ROC krivka a jej vytvorenie.
8. Popíšte, ako bude vypadat' ROC krivka ideálneho klasifikátora (ktorý bezchybne oddeľuje dve triedy).
9. Popíšte, ako bude vypadat' ROC krivka náhodného klasifikátora (ktorý má chybu 50 %).
10. Vysvetlite, čo znamenajú jednotlivé časti matice zámen pre dve klasifikačné triedy a ako medzi sebou súvisia.
11. Popíšte McNemarov test.

9.3 Úlohy

9.3.1 Vyberanie vzorky do testovacej množiny

Vysvetlite, čo nastane v prípade, že sa pri rozdelení dát dostanú do trénovacej množiny dáta jedného typu a do testovacej dáta druhého. Navrhните riešenie tohto problému.

9.3.2 Porovnávanie klasifikátorov

Majme štyri klasifikátory A, B, C a D. Každý z klasifikátorov má zadané hodnoty (FP, TP) nasledovne

A(0; 1)	B (0,65; 0,65)
C(0,1; 0,4)	D(0,8; 0,9)

- Určite, ktorý z klasifikátorov je najlepší.
- Určite, ktorý z klasifikátorov využíva stratégiu, kde náhodne určuje triedu pre daný prvok.

9.3.3 ROC krivky

Majme klasifikátor s použitím prahu, ktorým sme dostali nasledujúci výsledok

prah	TP	FP
15	0,2	0,2
20	0,2	0,3
33	0,3	0,3
46	0,4	0,4
68	0,5	0,4
75	0,6	0,5
91	0,7	0,5
112	0,8	0,6
130	0,8	0,7
180	0,9	0,8

Načrtnite ROC krivku klasifikátora.

Svetlo

10.1 Otázky

1. Aké typy žiarenia sú neviditeľné pre ľudské oko.
2. Vysvetlite rozdiel medzi radiometrickými a fotometrickými veličinami.
3. Vysvetlite, čo rozumieme pod pojmom spektrum.
4. Vysvetlite pojem tepelné žiarenie telesa.
5. V akom rozsahu vlnových dĺžok sa nachádza viditeľná časť spektra?
6. Do ktorej oblasti vlnových dĺžok spadá žiarenie čierneho telesa pri nízkych teplotách? Je toto žiarenie registrovateľné ľudským okom?
7. Definujte pojem absolútne čierne teleso.
8. Ako je definovaná veličina žiarivý tok?
9. Popíšte podľa akých zákonov optiky sa riadi svetlo.
10. Na vysvetlenie ktorých optických javov postačuje vlnový model svetla?
11. Aké základné vlastnosti charakterizujú elektromagnetické vlnenie.

12. Vysvetlite, čo je fotón.
13. Vysvetlite, akými veličinami popisujeme svetlo.
14. Na základe ktorých predpokladov formuloval Planck zákon vyžarovania pre absolútne čierne teleso?
15. Popíšte Planckovu krivku.

L'udský vizuálny systém

11.1 Otázky

1. Vysvetlite princíp vnímania svetla a farieb ľudským okom.
2. Koľko percent všetkých informácií zo svojho okolia vníma človek pomocou zraku.
3. Aké receptorové bunky sa nachádzajú na sietnici oka.
4. Popíšte z akých častí sa skladá ľudské oko a na čo slúžia.
5. Ako sa nazýva oblasť oka, kde sa nachádza väčšina čapíkov.
6. Vysvetlite, aký typ čapíkov je najmenej (L, M, S) zastúpený v ľudskom oku.
7. Vysvetlite pojem žltá škvrna a čím sa vyznačuje.
8. Vysvetlite v ktorej časti ľudského vizuálneho systému sa dejú oponentné procesy.
9. Popíšte, aké kanály vystupujú v oponentných procesoch.
10. Popíšte, aké skupiny gangliových buniek rozoznávame.
11. Vysvetlite trichromatickú teóriu.

12. Vysvetlite, čo je slepá škvrna.
13. Vysvetlite, čo sú receptorové polia a v akej súvislosti ich používame.
14. Vymenujte a popíšte poruchy farbocitu.

Kolorimetria

12.1 Príklad: Grassmannov experiment skladania farieb

Určite farebné súradnice farby, ktorá vznikne zmiešaním troch farieb v systéme CIE-xy, ktoré sú reprezentované ako vektory

$$c_1 = [0, 2; 0, 4; 10]^T, c_2 = [0, 1; 0, 5; 10]^T, c_3 = [0, 3; 0, 2; 10]^T$$

Aplikovaním prvého Grassmannovho zákona dostávame farbu určenú vektorom $c_4 = [x_4, y_4, Y_4]^T$, ktorá vznikla zložením farieb c_1 a c_2 nasledovne

$$T_1 = \frac{Y_1}{y_1} = \frac{10}{0,4} = 25,$$
$$T_2 = \frac{Y_2}{y_2} = \frac{10}{0,5} = 20$$

a teda

$$x_4 = \frac{x_1 T_1 + x_2 T_2}{T_1 + T_2} = \frac{0,2 \cdot 25 + 0,1 \cdot 20}{25 + 20} = 0,44$$
$$y_4 = \frac{y_1 T_1 + y_2 T_2}{T_1 + T_2} = \frac{0,4 \cdot 25 + 0,5 \cdot 20}{25 + 20} = 0,15$$
$$Y_4 = Y_1 + Y_2 = 10 + 10 = 20,$$

z toho

$$c_4 = [0,44;0,15;20]^T.$$

Teraz je potrebné zmiešať farby c_3 a c_4 . Výsledná farba c_5 je určená vektorom $c_5 = [x_5, y_5, Y_5]^T$, pričom

$$\begin{aligned}T_3 &= \frac{Y_3}{y_3} = \frac{10}{0,2} = 50, \\T_4 &= \frac{Y_4}{y_4} = \frac{20}{0,15} = 133,3 \\x_5 &= \frac{x_3 T_3 + x_4 T_4}{T_3 + T_4} = \frac{0,3 \cdot 50 + 0,44 \cdot 133,3}{50 + 133,3} = 0,40 \\y_5 &= \frac{y_3 T_3 + y_4 T_4}{T_3 + T_4} = \frac{0,2 \cdot 50 + 0,15 \cdot 133,3}{50 + 133,3} = 0,16 \\Y_5 &= Y_3 + Y_4 = 10 + 20 = 30.\end{aligned}$$

Výsledná farba, ktorá vznikne zmiešaním farieb c_1 , c_2 a c_3 a je daná v priestore CIE-xy súradnicami

$$c_5 = [0,40;0,16;30]^T.$$

12.2 Otázky

1. Aké typy skladania farieb poznáme, uveďte hlavné rozdiely medzi nimi.
2. Aké sú prvé matematicky definované priestory farieb.
3. Čo sa nachádza na Plankovej krivke v CIE diagrame.
4. Popíšte na čo slúži referenčný biely bod.
5. Vysvetlite, čo je pákové pravidlo.
6. Ako určíme doplnkové (komplementárne) farby v CIE diagrame.
7. Uveďte niektoré doplnkové (komplementárne) farby.
8. Uveďte príklady purpurových farieb.
9. Definujte sýtosť farby.
10. Ako určíme čistotu farby v CIE diagrame.

11. Vysvetlite, čo predstavuje gamut farieb.
12. Vysvetlite, čo predstavujú McAdamove elipsy.
13. Vysvetlite pojem metamér.

12.3 Úlohy

12.3.1 Farby

Majme tri primárne farby: červená, zelená, modrá.

- Určite tri sekundárne farby, ktoré vzniknú ich vzájomnou kombináciou.

12.3.2 CIE diagram

Určite doplnkové farby v CIE diagrame k farbám A1, A2 a A3.

	x	y
A1	0,3	0,2
A2	0,25	0,4
A3	0,4	0,4

Dané farby zobrazte v RGB. Na výpočty použite hodnoty v tabuľke.

	x	y
R	0,6400	0,3300
G	0,2100	0,7100
B	0,1500	0,0600
D65	0,3127	0,3290

Farebné modely

13.1 Príklad: Prevod medzi farebnými modelmi

V nasledujúcom príklade si ilustrujeme konverziu medzi farebnými modelmi a zobrazíme farebné zložky pre daný obrázok. Televízne normy používajú farebný model Y'CbCr namiesto RGB, ktorý je bežne používaný v monitoroch počítačov.

Najprv si vytvoríme obrázok, na ktorom budeme demonštrovať konverziu. Daný obrázok bude pozostávať z farebnej šachovnice, ktorej farby budú zodpovedať rozloženiu zobrazenému na obrázku 13.1. Toto zobrazenie dosiahneme pomocou vytvorenia obrázka v RGB farebnom mo-

čierna	červená	modrá
zelená	žltá	fialová
tyrkisová	biela	biela

Obrázok 13.1: Rozloženie farieb

deli pre dané zložky nasledovne


$$\begin{aligned}
 R &= \begin{bmatrix} 0 & 255 & 0 \\ 0 & 255 & 255 \\ 0 & 255 & 255 \end{bmatrix}, \\
 G &= \begin{bmatrix} 0 & 0 & 0 \\ 255 & 255 & 0 \\ 255 & 255 & 255 \end{bmatrix}, \\
 B &= \begin{bmatrix} 0 & 0 & 255 \\ 0 & 0 & 255 \\ 255 & 255 & 255 \end{bmatrix}. \quad (13.1)
 \end{aligned}$$

Našou úlohou je prekonvertovať vytvorený obrázok z farebného modelu RGB do Y'CbCr a zobrazit' dané zložky osobitne. Na prevod medzi modelmi použijeme rovnice


$$\begin{bmatrix} Y \\ Cb \\ Cr \end{bmatrix} = \begin{bmatrix} 16 \\ 128 \\ 128 \end{bmatrix} + \begin{bmatrix} 0,257 & 0,504 & 0,098 \\ -0,148 & -0,291 & 0,439 \\ 0,439 & -0,368 & -0,071 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix}, \quad (13.2)$$

$$\begin{bmatrix} R \\ G \\ B \end{bmatrix} = \begin{bmatrix} 1,000 & 0,000 & 1,140 \\ 1,000 & -0,395 & -0,581 \\ 1,000 & 2,032 & 0,000 \end{bmatrix} \begin{bmatrix} Y - 16 \\ Cb - 128 \\ Cr - 128 \end{bmatrix}. \quad (13.3)$$

Na obrázku 13.2 vidíme obraz v RGB modeli a jednotlivé zložky R, G a B samostatne.



Obrázok 13.2: Obraz v (a) RGB farebnom modeli, (b) R zložka, (c) G zložka, (d) B zložka.



Obrázok 13.3: Výsledné hodnoty po prevode z RGB do Y'CbCr (a) Y zložka, (b) Cb zložka, (c) Cr zložka

Následne prevedieme daný obraz do Y'CbCr podľa vzťahu (13.2). Výsledné hodnoty sú

$$\begin{aligned}
 Y &= \begin{bmatrix} 0,0627 & 0,3195 & 0,1607 \\ 0,5669 & 0,8237 & 0,4174 \\ 0,6648 & 0,9216 & 0,9216 \end{bmatrix}, \\
 Cb &= \begin{bmatrix} 0,5020 & 0,3537 & 0,9412 \\ 0,2110 & 0,0627 & 0,7930 \\ 0,6502 & 0,5020 & 0,5020 \end{bmatrix}, \\
 Cr &= \begin{bmatrix} 0,5020 & 0,9412 & 0,4305 \\ 0,1342 & 0,5734 & 0,8697 \\ 0,0627 & 0,5020 & 0,5020 \end{bmatrix}. \quad (13.4)
 \end{aligned}$$

Jednotlivé zložky Y', Cb a Cr samostatne sú na obrázku 13.3. Z tohto obrázka je zjavné využitie pre zobrazenie televízneho signálu. V prípade Y'CbCr modelu stačí zobraziť Y zložku, vďaka ktorej používateľ získa plnohodnotnú šedotónovú informáciu v porovnaní s inými zložkami z Y'CbCr, rovnako ako z RGB modelu.

13.2 Otázky

1. Aké typy farebných modelov poznáme.
2. Popíšte rozdiel medzi modelmi RGB a RGBA.
3. Vysvetlite, čo predstavujú jednotlivé zložky v modeli L*a*b*.

4. Popíšte s akým častým problémom sa stretávame pri práci s farbami v modeli HSV.
5. Vysvetlite, kde v RGB modeli sa nachádzajú farby zodpovedajúce odtieňom šedej.
6. Vysvetlite, aký je hlavný rozdiel medzi HW orientovanými a používateľsky orientovanými modelmi.
7. Vysvetlite, kde sa využívajú modely triedy Y.
8. Vysvetlite, prečo boli farebné modely RGB, CMY, YIQ a HSL vytvorené. Určite, kde a prečo sa dané modely využívajú.

13.3 Úlohy

13.3.1 Farebné modely

Určite hodnoty pre šedú farbu v modeloch CMY, YIQ a HSV, ktorej vyjadrenie v RGB modeli je (pre 8-bitový obrázok s hodnotami 0 – 255)

- (10; 10; 10)
- (90; 90; 90)
- (250; 250; 250)

13.3.2 Prevody medzi farebnými modelmi

Majme daný pixel v RGB s hodnotami (150; 10; 200) pre 8-bitový obrázok s hodnotami 0 – 255. Určite farbu daného pixela v modeloch CMY, HSI, YCbCr.

13.3.3 Model RGB

V RGB kocke zobrazte farby obrázka 13.4 nasledovne (pre 8-bitový obrázok s hodnotami 0 – 255)

- Zobrazte všetky farby nachádzajúce sa v obrázku.
- Zobrazte len farby, ktorých hodnoty zodpovedajú predpisu $R+G+B = 100$.



Obrázok 13.4: Vstupný obrázok k úlohe Model RGB

- Zobrazte len farby, ktorých hodnoty zodpovedajú predpisu $R+G+B = 180$.

Pozorujte a popíšte kde a prečo sa zobrazené farby nachádzajú.

13.3.4 Model CMY

Preveďte nasledujúce farby z modelu CMY do modelu CMYK. Popíšte a vysvetlite rozdiel.

- (244, 244, 244)
- (125, 89, 111)
- (43, 28, 198)

13.3.5 Detekcia pokožky v modeli HSV

Majme farbu pokožky definovanú v HSV nasledovne

$$\begin{aligned} 0 < H < 50 \\ 0,23 < S < 0,68 \end{aligned}$$

Nájdite na danom obrázku 13.5 oblasti, ktoré sú podľa horeuvedených ohraničení pokožkou.



Obrázok 13.5: Obrázok k úlohe Detekcia pokožky


13.3.6 Prevod medzi HSV a HSL

Preved'te červenú farbu (0, 1, 1) z modelu HSV do modelu HSL. Vysvetlite ako a prečo sa farba zmenila.

Vizuálne vnímanie a pozornosť

14.1 Otázky

1. Vysvetlite pojem vizuálna pozornosť.
2. Vymenujte aspoň 5 spôsobov využitia detekcie významných oblastí v praxi.
3. Popíšte rôzne prístupy sledovania očí a rozdiely medzi nimi.
4. Popíšte výhody a nevýhody sledovania pohybu očí.
5. Popíšte princíp tvorby máp zachytávajúcich významné oblasti v obraze.
6. Vysvetlite výhody tvorby modelov na detekciu významných oblastí v porovnaní so sledovaním očí.
7. Popíšte rozdiel medzi prístupmi zdola-nahor a zhora-nadol pri detekcii významných oblastí.
8. Vysvetlite nedostatky modelov, ktoré využívajú len nízkoúrovňové príznaky.
9. Popíšte základnú architektúru modelu založeného na Ittiho prístupe.



Obrázok 14.1: Vstupné snímky pre detekciu významných oblastí s použitím nízkoúrovňových príznakov.

14.2 Úlohy

14.2.1 Detekcia významných oblastí

Majme obrazy, ktoré zachytávajú západ slnka (obr. 14.1). Navrhňte nízkoúrovňové príznaky, ktoré by ste použili pri detekcii významných oblastí v daných obrazoch. K dispozícii máte prídavnú informáciu podľa ktorej viete, že najvýznamnejší objekt je západ slnka. Svoje predpoklady si overte naprogramovaním jednoduchého systému, kde vytvoríte mapu významných oblastí nasledovným spôsobom

- Vytvorte mapy pre príznaky, ktoré ste si vybrali.
- Mapy príznakov sčítajte a výsledok normalizujte.

Tiráž

Názov: Detekcia a klasifikácia objektov v príkladoch

©Autorský kolektív:

RNDr. Zuzana Haladová

RNDr. Júlia Kučerová

RNDr. Elena Šikudová, PhD.

RNDr. Zuzana Černeková, PhD.

Obálka: Spyridon Giochalias

Vydavateľstvo: Wikina, Livornská 445, 109 00 Praha 10
1. vydanie

Náklad: 100

Nepredajné

Vydané s podporou grantu KEGA 068UK-4/2011

ISBN: 978-80-87925-08-9