

UNIVERZA V LJUBLJANI
FAKULTETA ZA RAČUNALNIŠTVO IN INFORMATIKO

Domen Pogačnik

**Ocenjevanje estetike fotografij s
pomočjo strojnega učenja**

DIPLOMSKO DELO

UNIVERZITETNI ŠTUDIJSKI PROGRAM PRVE STOPNJE
RAČUNALNIŠTVO IN INFORMATIKA

MENTOR: prof. dr. Franc Solina

Ljubljana 2012

Rezultati diplomskega dela so intelektualna lastnina avtorja in Fakultete za računalništvo in informatiko Univerze v Ljubljani. Za objavlanje ali izkoriščanje rezultatov diplomskega dela je potrebno pisno soglasje avtorja, Fakultete za računalništvo in informatiko ter mentorja.

Besedilo je oblikovano z urejevalnikom besedil \LaTeX .



Št. naloge: 00012/2012

Datum: 15.03.2012

Univerza v Ljubljani, Fakulteta za računalništvo in informatiko izdaja naslednjo nalogo:

Kandidat: **DOMEN POGAČNIK**

Naslov: **OCENJEVANJE ESTETIKE FOTOGRAFIJ S POMOČJO STROJNEGA UČENJA**
EVALUATING PHOTO AESTHETICS USING MACHINE LEARNING

Vrsta naloge: Diplomsko delo univerzitetnega študija prve stopnje

Tematika naloge:

Preučite možnost avtomatičnega ocenjevanja celostne oziroma estetske kvalitete fotografij. Poleg tehničnih lastnosti fotografij, kot so osvetlitev, kontrast in ostrina, poskusite upoštevati tudi kompozicijo fotografij s pomočjo značilnik, ki jih lahko izračunate z metodami računalniškega vida.

Na osnovi zbirke fotografij, ki so jih ocenili človeški eksperti, in s pomočjo metod strojnega učenja naučite sistem avtonomno ovrednotiti estetsko plat fotografij.

Mentor:

prof. dr. Franc Solina

Dekan:

prof. dr. Nikolaj Zimic



IZJAVA O AVTORSTVU DIPLOMSKEGA DELA

Spodaj podpisani Domen Pogačnik, z vpisno številko **63050084**, sem avtor diplomskega dela z naslovom:

Ocenjevanje estetike fotografij s pomočjo strojnega učenja

S svojim podpisom zagotavljam, da:

- sem diplomsko delo izdelal samostojno pod mentorstvom prof. dr. Franca Solina,
- so elektronska oblika diplomskega dela, naslov (slov., angl.), povzetek (slov., angl.) ter ključne besede (slov., angl.) identični s tiskano obliko diplomskega dela
- soglašam z javno objavo elektronske oblike diplomskega dela v zbirki "Dela FRI".

V Ljubljani, dne 10. junij 2012

Podpis avtorja:

Zahvaljujem se mentorju prof. dr. Francu Solini za vse nasvete in pomoč pri izdelavi diplomskega dela.

Zahvaljujem se tudi Robertu Ravniku za vse predloge, s katerimi mi je pomagal pri učinkovitejšem pristopu k reševanju problema ocenjevanja estetike fotografij in zajema učnih podatkov.

Zahvaljujem se tudi Simonu Cigoju za vse nasvete v zvezi s fotografijo.

Kazalo

Povzetek

Abstract

1	Uvod	1
2	Uporabljena tehnologija	5
2.1	OpenCV	6
2.2	SimpleCV	9
2.3	Python	11
2.4	NumPy	13
2.5	SciPy	14
2.6	Matplotlib	14
2.7	Django	15
2.8	Orange	15
3	Lastnosti dobre fotografije	17
3.1	Enostavnost	17
3.2	Kompozicija	18
4	Uporabljene značilke	23
4.1	Barvna shema	24
4.2	Razmerja velikosti fotografije	32
4.3	Kompozicija	33

KAZALO

5	Zajem učnih podatkov	35
6	Rezultati	41
6.1	Klasifikacija fotografij v 3 razrede glede na splošno oceno . . .	43
6.2	Klasifikacija fotografij v 2 razreda glede na splošno oceno . . .	47
6.3	Analiza kompozicije fotografije	47
6.4	Analiza uporabljene barvne palete	50
6.5	Diskusija rezultatov	53
7	Sklepne ugotovitve	61

Povzetek

V diplomskem delu smo identificirali lastnosti fotografij, ki vplivajo na estetsko kvaliteto fotografije, in jih pretvorili v izračunljive značilke. Poudarek smo dali opazovanju subjekta v primerjavi s celotno fotografijo. Subjekt smo identificirali ročno, in sicer s pomočjo izkušenih fotografov. Tekom našega dela smo definirali in implementirali 31 značilk, ki analizirajo barvno shemo, kompozicijo in pa proporce fotografije. V okviru diplomskega dela smo izdelali tudi enostavno spletno aplikacijo za označevanje in ocenjevanje fotografij, ki nam je služila za pridobivanje učnih podatkov. Na podlagi teh značilk in zbranih učnih podatkov, smo s pomočjo strojnega učenja definirali model, ki je sposoben ločevati med estetsko privlačnimi oz. profesionalnimi fotografijami in pa nizko kvalitetnimi hipni posnetki. Ob uporabi klasifikatorja SVM smo dosegli klasifikacijsko natančnost 93 odstotkov. V nadaljevanju smo te značilke analizirali s pomočjo metrike relief^F in nomograma klasifikatorja Naivni Bayes. Na koncu smo predstavili rezultate analize vpliva značilk in podali nekaj smernic pri nadaljnjem razvoju modela.

Evaluating photo aesthetics using machine learning

Abstract

The purpose of this thesis is to identify the characteristics that influence the aesthetic appeal of photographs and to convert these characteristics into calculable features. Primarily, we examined the relation between the foreground object - subject and the photograph as a whole. The subject was manually identified with the assistance of experienced photographers. During our research, we implemented 31 features to analyze various aspects of a photograph, such as the color scheme, composition and proportions. A simple web application for labeling and the aesthetic assessment of photographs, which was developed as a part of our thesis, was used by experienced photographers in order to provide learning samples. On the basis of calculated features and gathered learning data, we used machine learning algorithms to create a model which is able to distinguish high quality/professional from low quality/snapshot photographs. We achieved 93 percent classification accuracy using SVM classifier. The features used by machine learning algorithm were analyzed with reliefF metric and the nomogram data provided by the Naive Bayes classifier. In the final part, we presented and discussed the influence of calculated features and suggested some guidelines for further research on the subject.

Poglavje 1

Uvod

Z uveljavitvijo digitalne fotografije se je količina posnetih fotografij močno povečala. Zaradi nizke cene in enostavnosti digitalnega posnetka se s fotografijo ukvarja vse več ljudi, ki naredijo vedno več posnetkov. V tej poplavi fotografij je ročna analiza fotografij pogosto zelo zamudna in težavna. Pojavlja se potreba po orodjih za upravljanje s fotografijami, ki so sposobna sama izbrati najboljše posnetke iz množice posnetkov v naši zbirki.

Ocenjevanje kvalitete fotografije je zelo subjektivno področje. Kriteriji za ocenjevanje se pogosto razlikujejo med različnimi ocenjevalci, tudi ko gre za profesionalne fotografe. A vendar v večini primerov obstoji konsenz, ali gre za posnetek, kjer je fotograf skrbno izbral motiv in s pomočjo pridobljenega znanja, izkušenj in nenazadnje tudi primerne opreme prišel do kvalitetne fotografije, ali pa je bila slika posneta hipno brez izbranega motiva, kjer avtor posnetka nima ne dovolj znanja in tudi ne opreme za kvaliteten posnetek. Tako podobno kot v delu avtorjev Ke et al. [10] definiramo visoko kvalitetni - profesionalni posnetek in na drugi strani nizko kvalitetni - hipni posnetek.

V preteklosti so se za avtomatično ocenjevanje kvalitete posnetka uporabljale metode, ki so analizirale slike na nizkem nivoju oziroma so upoštevale zelo osnovne attribute slik [5]. Naš pristop je obraten, analize slik smo se lotili od zgoraj navzdol. Cilj, ki smo ga želeli doseči, je razvoj skupine visoko nivojskih značilnk, ki so bližje človeškemu dojetanju kvalitete slik.

Načrtovanje visoko nivojskih značilik je zahtevno opravilo saj tudi profesionalni fotografi za ocenjevanje fotografij uporabljajo precej neoprijemljive termine, kot so dobra kompozicija, barvna shema in osvetlitev. Zadali smo si nalogo, da te koncepte pretvorimo v konkretne značilke, ki so dovolj enostavne in hitro izračunljive. Zavedamo se, da pri ocenjevanju kvalitete slik prihaja do velike variacije pri percepciji kvalitete slik. Tudi zaradi tega smo naš problem omejili samo na razlikovanje med nizko kvalitetnimi (hipni posnetki) in visoko kvalitetnimi (profesionalni) posnetki. Prav gotovo pa naše delo ni namenjeno klasifikaciji umetniških del ali pa razlikovanju med različnimi profesionalnimi fotografijami. Klasifikacija teh del je težavna že za človeške ocenjevalce in pogosto se uporabljajo različni kriteriji pri že prej omenjeni visoko varianci v percepciji kvalitete.

Kljub vsem težavam povezanim z neoprijemljivimi kriteriji za ocenjevanje in varianco pa obstajajo nekatere naravne zakonitosti, ki so bile že potrjene v preteklosti in so tudi prestale preizkus časa. Fotografije izkušenih fotografov se v večini držijo pravil lepe kompozicije, naj si bo to pravilo tretjin, zlato pravilo ali pa katero drugo uveljavljeno pravilo. Na ta način so te fotografije vizualno privlačnejše kot pa fotografije neizkušenih fotografov. Seveda pa obstajajo tudi fotografije izkušenih fotografov, ki ta pravila zavestno kršijo in na ta način ustvarjajo napetost, kar gledalce fotografij le še bolj privlači.

Sistem za ocenjevanje kvalitete fotografij je uporaben na veliko področjih. Eno izmed področij so že prej omenjena orodja za upravljanje s fotografijami. Spletni iskalniki, ki iščejo po slikah, bi sistem koristno uporabili za nadzor nad kvaliteto vrnjenih rezultatov. Na tak način bi vrnili najbolj relevantne in predvsem kvalitetne slike. Sistem za avtomatično ocenjevanje kvalitete fotografij bi bil lahko vgrajen tudi v fotoaparate. V preteklosti so v fotoaparate že vgradili programsko opremo za samodejno osvetlitev in ostrenje. V sodobnejših fotoaparatih pa najdemo tudi pomagala, kot je detekcija obrazov in nasmehov. Samodejno ocenjevanje estetike bi bil lahko naslednji korak pri razvoju uporabniku prijaznih fotoaparatorov.

Zgodnejše raziskave ocenjevanja estetike fotografij so za analizo fotografij

uporablja je t.i. nizko nivojske značilke, to so značilke, ki delujejo bolj ali manj neposredno na pikslih fotografije. Kasnejša dela pa so si zadala bolj ambiciozno nalogo, in sicer definirati visoko nivojske značilke, ki bolj ustrezajo abstraktnim konceptom, katere uporabljajo fotografi. Delo avtorjev Ke et al. [10] je te visoko nivojske značilke sestavilo iz nizko nivojskih značilk, kot so šum, zamegljenost, barva, osvetljenost, kontrast in prostorska porazdelitev robov. Nekatera delo so ambicioznejša in poleg teh visoko nivojskih značilk raziskujejo tudi vpliv podobnosti med fotografijami [6, 7]. Pri nekaterih delih so se avtorji [3] odločili raziskati vpliv metapodatkov, ki jih naprava zapiše ob nastanku fotografije. Vendar se je v kasneje v delih Luo and Tang in Sun et al. izkazalo, da ti podatki ne zadostujejo za kvalitetno oceno estetike fotografije. Kasnejša dela so se zato usmerila k analizi kompozicije fotografije [12], kar so nadaljevali tudi avtorji Bhattacharya, Sukthankar in Shah [1] z opazovanjem postavitve osprednjega objekta v okvir slike ali z analizo postavitve horizonta, kadar gre za fotografije pokrajine brez izrazitega osprednjega objekta.

Problem ocenjevanja estetike fotografij smo se odločili reševati s pomočjo metod strojnega učenja. Tehnologijo, ki smo jo uporabili za reševanje danega problema, bomo opisali v poglavju 2. Najprej smo preučili lastnosti vizualno privlačnih fotografij, kjer smo se močno naslonili na delo avtorja M. Freeman, *Fotografov pogled* [8], in pa na predhodno delo avtorjev Ke et al. [10]. Te lastnosti bomo opisali v poglavju 3. Na podlagi teh lastnosti in s pomočjo informacije o subjektu fotografije, ki smo ga podobno kot v delu avtorjev Bhattacharya et al [1] dobili s pomočjo uporabnika, smo definirali značilke, ki opisujejo različne lastnosti fotografij. Opis in implementacijo teh značilk smo opisali v poglavju 4. V nadaljevanju bomo opisali zajem učnih podatkov za strojno učenje. Izdelali smo enostavno spletno aplikacijo s pomočjo katere so nam izkušeni fotografi ocenili različne lastnosti fotografij. V 6. poglavju bomo predstavili tudi rezultate naše metode, sklepne ugotovitve pa so zapisane v 7. poglavju.

Poglavje 2

Uporabljena tehnologija

Pri izboru tehnologije smo največ pozornosti namenili knjižnici za računalniški vid. Po pregledu področja smo se odločili za knjižnico OpenCV na podlagi velikosti uporabniške skupnosti, uglednih imen uporabnikov knjižnice in količine literature, ki je na voljo za knjižnico [4]. Knjižnica OpenCV omogoča programiranje v programskem jeziku C/C++, vendar ponuja tudi vmesnik za programski jezik Python. Programski jezik Python smo izbrali, ker sta nam bila v fazi raziskovanja in prototipiranja sistema pomembna predvsem hitrost in enostavnost razvoja kot pa sama hitrost rešitve. Kasneje smo ugotovili, da vmesnik knjižnice OpenCV za jezik Python ne izkorišča dinamičnosti jezika Python (pri kreiranju podatkovnih struktur), zato smo se odločili za uporabo visoko nivojske knjižnice SimpleCV, ki uporabniku ponuja prijazen dostop do metod knjižnice OpenCV. Odločitev za jezik Python se je pravitako skladala z izborom orodja za strojno učenje Orange. Tudi ta ponuja vmesnik za programiranje v tem jeziku. V okviru diplomskega dela smo izdelali tudi spletno aplikacijo za označevanje in ocenjevanje fotografij za kar smo ponovno uporabili programski jezik Python in pa ogrodje, poimenovano Django.

2.1 OpenCV

Za opravila povezana z računalniškim vidom smo uporabili knjižnico OpenCV (Open Source Computer Vision). Na našo odločitev za OpenCV so vplivali velikost uporabniške skupnosti, ugledna imena uporabnikov knjižnice in količina literature, ki je na voljo za knjižnico [4]. OpenCV je odprtokodna knjižnica z algoritmi, ki se uporabljajo v računalniškem vidu. Knjižnica je izdana pod BSD licenco in je tako na voljo tudi za komercialno uporabo. Razvita je bila v laboratorijih podjetja Intel, trenutno pa nad njo bedi podjetje Willow Garage. Knjižnica podpira vse najbolj uporabljane operacijske sisteme: Windows, Linux, Mac OS kot tudi mobilne operacijske sisteme: Android, Maemo, iOS. Glavni fokus knjižnice je procesiranje slik v realnem času. Kot zanimivost, knjižnica je bila uporabljena v zmagovalnem avtomobilu ekipe iz Stanforda na tekmovanju Darpa Grand Challenge [13].

Knjižnica vsebuje več kot 500 funkcij. Te funkcije pokrivajo področja iz računalniškega vida kot so: prepoznavna in sledenje gibanja, prepoznavna obrazov, prepoznavna kretenj, interakcija človek-računalnik, mobilna robotika, identifikacija objektov, segmentacija, stereovid.

Čeprav je knjižnica implemetirana v jeziku C in C++ so zanjo na voljo vmesniki do jezikov kot so Python, Ruby, Matlab, C#, Java.

Nabor funkcionalnosti:

- upravljanje s podatki slike (alokacija podatkov, dealokacija, kopiranje, konverzija)
- branje slik/videa iz V/I (iz datoteke, kamere)
- upravljanje z matrikami in vektorji (linearna algebra)
- podpora za dinamične strukture (seznam, vrste, množice, drevesa, grafi)
- osnovni algoritmi za procesiranje slik (filtri, detektorji robov, vzorčenje, interpolacija, pretvorba barv, morfološke operacije, histogrami, piramide slik)

OpenCV Overview: > 500 functions
opencv.willowgarage.com

Robot support

The image displays a comprehensive overview of OpenCV's capabilities, organized into several key functional areas:

- General Image Processing Functions:** Includes image enhancement, thresholding, and edge detection.
- Geometric descriptors:** Focuses on shape analysis and feature extraction.
- Image Pyramids:** Illustrates multi-scale image processing techniques.
- Segmentation:** Shows methods for object segmentation and region-based analysis.
- Features:** Covers feature detection and matching algorithms.
- Camera calibration, Stereo, 3D:** Details camera calibration, stereo vision, and 3D reconstruction.
- Transforms:** Includes affine and perspective transformations.
- Utilities and Data Structures:** Lists various utility functions and data structures provided by the library.
- Machine Learning:** Highlights detection and recognition capabilities.
- Tracking:** Shows object tracking and optical flow in 1D.
- Matrix Math:** Emphasizes the library's support for matrix operations.
- Fitting:** Illustrates line and circle fitting algorithms.

Slika 2.1: Prikaz nabora funkcionalnosti knjižnice OpenCV.

- strukturna analiza (povezane komponente, Hough transform, ...)
- kalibracija kamere (stereo korespondenca)
- analiza gibanja (segmentacija, sledenje)
- prepoznavanje objektov
- osnovni GUI (prikaz slik in videa, upravljanje z miško in tipkovnico, drsniki)
- označevanje slik (črt, poligonov, izris teksta)

Primer enostavnega programa z uporabo OpenCV knjižnice:

Spodnji program najprej s piramidnim vzorčenjem pomanjša sliko, jo pretvori v sivinsko obliko, nato pa na zmanjšani sivinski sliki izvede detektor robov Canny. Obe sliki prikažemo na zaslonu.


```
int _tmain(int argc, _TCHAR* argv[])
{
    IplImage* img = cvLoadImage( "MGC.jpg" );
    cvNamedWindow( "Example3-in" );
    cvNamedWindow( "Example3-out" );

    // Show the original image
    cvShowImage("Example3-in", img);

    // Create an image for the output
    IplImage* out = cvCreateImage( cvGetSize(img), IPL_DEPTH_8U, 3 );

    // Perform a Gaussian blur
    cvSmooth( img, out, CV_GAUSSIAN, 11, 11 );

    // Show the processed image
    cvShowImage("Example3-out", out);
}
```



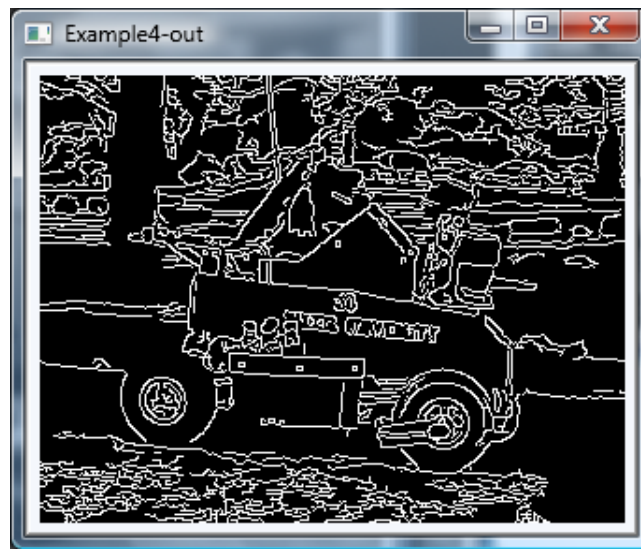
Slika 2.2: Originalna slika (levo) in slika nad katero smo izvedli gaussovo glajenje (desno). Nad desno sliko smo nato izvedli detektor robov Canny. Slika je del vodiča, ki se nahaja na spletnih straneh Drexel University [11].

```
    cvWaitKey(0);
    cvReleaseImage( &img );
    cvReleaseImage( &out );
    cvDestroyWindow( "Example3-in" );
    cvDestroyWindow( "Example3-out" );
    return 0;
}
```

vir: <http://das1.mem.drexel.edu/~noahKuntz/openCVTut1.html>

2.2 SimpleCV

Ugotovili smo, da vmesnik knjižnice OpenCV za jezik Python ne izkorišča dinamičnosti jezika Python, npr. pri kreiranju podatkovnih struktur, in se zato odločili za uporabo visoko nivojske knjižnice za jezik Python imenovane SimpleCV. Knjižnica v osnovi ponuja uporabniku prijazen dostop do metod,



Slika 2.3: Rezultat detektorja robov Canny. Slika je del vodiča, ki se nahaja na spletnih straneh Drexel University [11].


ki jih ponuja knjižnica OpenCV, to pa še nadgradi z implementacijo nekaterih pogostejših opravil na področju računalniškega vida. Glavno vodilo razvijalcev te knjižnice oz. ogrodja je prav enostavnost uporabe. Prav zaradi te želje po enostavnem in učinkovitem ogrodju so razvijalci poleg OpenCV knjižnice integrirali tudi uporabne Python knjižnice kot so PIL, Numpy, Scipy, ...

Funkcionalnost SimpleCV ogrodja:

- detekcija značilnk
- detekcija robov, blobov
- filtriranje in sortiranje značilnk po lokaciji, barvi, kvaliteti in velikosti manipulacija slik in pretvorba med formati
- zajem videa iz spletnih kamer, Kinect-a, Firewire vmesnika, IP kamer in mobilnih telefonov

Primer enostavnega programa:

Program zajame sliko iz spletne kamere in s pomočjo Haarovih značilnk, podanih v xml deskriptorju, poišče obraze na podani sliki.



Slika 2.4: Rezultat algoritma, ki izvede prepoznavo obrazov.

```
from SimpleCV import *  
  
img = Image('lenna1.png')  
faces = img.findHaarFeatures('haarcascade_frontalface_alt.xml')  
if faces:  
    for face in faces:  
        face.draw()  
img.show()
```

2.3 Python

Za potrebe izračuna značilk fotografij, obdelave podatkov ter izdelave spletne aplikacije smo potrebovali programski jezik, ki je enostaven in omogoča hiter razvoj. Pomembno vlogo pri izbiri sta imeli tudi knjižnica za računalniški vid SimpleCV in pa orodje za strojno učenje Orange, saj oba ponujata vmesnik za programski jezik Python.

Python je splošno namenski visoko nivojski jezik s filozofijo, ki teži k enos-

tavnosti uporabe, uveljavljanju dobrih praks kodiranja in dobre berljivosti kode. Prav tako teži k enostavni sintaksi in se drži DRY principa, ki je pogoj za učinkovit jezik.

Python podpira več programskih paradig kot so objektno orientirano, imperativno in v manjšem obsegu funkcionalno paradigmo. Je dinamično tipiziran jezik s samodejnim upravljanjem s pomnilnikom. Python je najpogosteje uporabljen kot skriptni jezik, podobno kot jeziki PHP, Ruby in Perl. Vendar Python omogoča še veliko več. Z uporabo knjižnic lahko program napisanem v Python programskem jeziku prevedemo in zapakiramo v izvršljivo datoteko. Prav tako za Python obstajajo knjižnice, ki nam omogočajo gradnjo grafičnih uporabniških vmesnikov za namizne aplikacije.

Python interpreterji so na voljo za vse najpogostejše uporabljene operacijske sisteme. Referenčna implementacija Python interpreterja je izdana pod odprtokodno licenco. Vzdržuje ga neprofitna organizacija Python Software Foundation. Obstajajo pa tudi alternativne implementacije, kot so IronPython in Jython, ki teče v javanskem navideznem stroju.

Python se večinoma uporablja kot skriptni jezik za spletne aplikacije. Preko vmesnika WSGI je možna povezava z spletnim strežnikom Apache. Spletna aplikacijska ogrodja kot so Django, Pylons, TurboGears, itd. nam omogočajo hiter razvoj kompleksnih spletnih aplikacij.

Python interpreter je standardna komponenta popularnih Linux distribucij kot so Ubuntu, Red Hat, Fedora, Gentoo, itd. V teh primerih služi kot jezik v katerem so napisani inštalacijski programi, orodja za upravljanje s paketi in ostala administracijska orodja. Prav tako je bil Python interpreter večkrat uspešno integriran v različne programske pakete kot skriptni jezik. Sem spadajo Blender, Maya, GIMP, itd. Python je tudi eden prvih jezikov, uporabljenih v Google App Engine okolju.

Zaradi modularne arhitekture, enostavne sintakse in orodij za procesiranje teksta je Python zelo dobro sprejet v akademskem svetu. Pogosto se uporablja za procesiranje naravnega jezika in strojno učenje.

Primer enostavnega programa v Python programskem jeziku:

Program si zabeleži trenutni lokalni čas, nato pa izpiše katero aktivnost trenutno opravljamo.

```
from time import localtime

activities = {8: 'Sleeping',
             9: 'Commuting',
             17: 'Working',
             18: 'Commuting',
             20: 'Eating',
             22: 'Resting' }

time_now = localtime()
hour = time_now.tm_hour

for activity_time in sorted(activities.keys()):
    if hour < activity_time:
        print activities[activity_time]
        break
else:
    print 'Unknown, AFK or sleeping!'
```

2.4 NumPy

NumPy je eden izmed ključnih knjižnic za znanstveno obdelovanje podatkov v Python programskem jeziku. Glavna funkcionalnost paketa so predvsem uporabne funkcije iz področja linearne algebre. Poskrbi tudi za upravljanje podatkovnih struktur povezane s temi algoritmi. Knjižnica se uporablja tudi v paketu SimpleCV. Na voljo je pod odprtokodno BSD licenco.

2.5 SciPy

SciPy je še ena v zbirki ključnih knjižnic, ki se uporablja v matematiki, znanosti in tehniških vedah. Uporabljena je tudi v paketu SimpleCV. Knjižnica gradi svojo funkcionalnost na že prej omenjeni NumPy knjižnici.

Nabor funkcionalnosti pokriva področja:

- statistike
- optimizacije
- numerične integracije
- linearne algebre
- Fourierjeve transformacije
- procesiranja signalov
- procesiranja slik


Knjižnica je na voljo pod odprtokodno licenco.

2.6 Matplotlib

Pri izračunu značilik fotografij smo si večkrat pomagali z vizualizacijo različnih količin, za kar smo uporabili knjižnico Matplotlib. Knjižnica se zgleduje po ukazu `plot` v programskem paketu Matlab in omogoča izris različnih tipov grafov in diagramov na enostaven način. Knjižnica deluje na večini bolj popularnih operacijskih sistemih.

Primer uporabe:

```
x = randn(10000)
hist(x, 100)
```



Slika 2.5: Primer vizualizacije podatkov s pomočjo knjižnice Matplotlib.

2.7 Django

Za pridobivanje učnih podatkov smo izdelali spletno aplikacijo za označevanje in ocenjevanje fotografij. Za ta namen smo izbrali spletno programsko ogrodje za programski jezik Python imenovan Django, ki je namenjeno hitremu razvoju spletnih aplikacij. Podpira razvoj aplikacij po vzorcu MVC (Model, View, Controller). V sami osnovi nudi pretvornik ORM (object-relationship mapper), ki nam omogoča abstrakcijo podatkovne baze na način, da s podatki upravljamo s uporabo podatkovnih modelov v programskem jeziku Python. Omogoča pa nam tudi delo z obrazci, ponuja sistem za avtentikacijo ter ostale pogosto uporabljane komponente.

2.8 Orange

Za izvedbo strojnega učenja in analizo značilk smo izbrali programski paket Orange [14]. Programski paket Orange je odprtokodno orodje, ki implementira algoritme za strojno učenje ter tudi analizo in vizualizacijo podatkov. Razvito je bilo v laboratoriju za Umetno Inteligenco (sedaj Bioinformatiko) na fakulteti za računalništvo in informatiko Univerze v Ljubljani.

Možna načina uporabe paketa sta naslednja:

1. s pomočjo grafičnega vmesnika: uporabljamo gradnike, ki jih nam ponuja orodje Orange Canvas
2. s Python programskim jezikom: uporabljamo Orange knjižnico za Python

Poglavje 3

Lastnosti dobre fotografije

3.1 Enostavnost

Kvalitetni posnetki težijo k čim večji enostavnosti, zato je pri teh fotografijah mogoče nemudoma identificirati subjekt slike (interesni center fotografije). Gledalec si naredi prvi vtis o sliki na podlagi subjekta, šele potem raziskuje ostala področja slike in se nenazadnje tudi vrne na subjekt. V nasprotju s kvalitetnimi posnetki pa hipni posnetki nemalokrat vnašajo v sliko nepomembne in predvsem moteče elemente, ki gledalca zmedejo in tako otežujejo razpoznavo subjekta. Zaradi tega so te fotografije vizualno manj privlačne.

Dobre fotografije lahko dosežejo enostavnost na več načinov. Najlažji način je, kjer je to mogoče, da si izberemo enostavno ozadje, kot je naprimer nebo, pesek itd., saj je le-to komplementarno subjektu. Na ta način s pomočjo barvnega kontrasta dosežemo, da subjekt v sliki izstopa. Podoben efekt dosežemo tudi v primeru razlike med osvetlitvijo subjekta v primerjavi z ozadjem. Največkrat uporabna tehnika pa je enostavno postaviti ozadje izven fokusa, ki ima za rezultat zamegljeno ozadje, kar gledalcu omogoči, da se lažje osredotoči na subjekt fotografije. Primer zamegljenega ozadja lahko opazimo na sliki 3.1.




Slika 3.1: Primer fotografije z zamegljenim ozadjem, ki omogoča, da se gledalec lahko osredotoči na subjekt fotografije.

3.2 Kompozicija

Pri določanju kompozicije se vse vrti okoli subjekta fotografije. Najprej se moramo vprašati, ali je interakcija z ostalimi predmeti v okolici pomembna za vsebino fotografije. Ta odločitev vpliva na kasnejšo izbiro ostalih elementov poleg subjekta. Pri fotografiji smo glede postavljanja samih elementov nekoliko bolj omejeni kot pri ostalih umetniških delih. A vendar lahko vplivamo na postavitev elementov že pri samem fotografiranju, in sicer z manipulacijo vidnega polja in s spreminjanjem perspektive fotografije. Tako postavljeni elementi, ki upoštevajo osnovne lastnosti organizacije, tvorijo harmonično celoto ali enotnost.

Pri določanju postavitve elementov je pomembno, po kakšni poti želimo, da potuje gledalčev pogled. Pri tem si lahko pomagamo z uporabo različnih črt in oblik. Prav tako je pomembna tudi njihova orientacija, saj gledalcu pomagajo pri pravilnem dojetju fotografije (kot si je zamislil fotograf). Elementi v sliki so ponavadi različnih oblik in velikosti, zato se pojavi vprašanje ravnotežja med njimi. Manjši objekti z močnim kontrastom imajo večji vpliv kot večji monotoni elementi. Ti elementi predstavljajo sile in človeško oko si jih želi uravnovesiti na način, da doseže harmonijo, stanje, ki je vizualno prijetno. Elementi se lahko tudi ponavljajo in na takšen način ustvarjajo



Slika 3.2: Pravokotnika v zlatem razmerju.

vzorci ali pa fotografiji dajejo občutek ritma. Prazen prostor med elementi imenujemo negativni prostor. Le-ta očem omogoči, da se spočijejo in se prav tako šteje za pomembno lastnost kompozicije.

Izmed bolj objektivno definiranih lastnosti pa je prav gotovo geometrija fotografije, ki si jo bomo bolj podrobno ogledali v nadaljevanju. Kljub temu da opisane lastnosti omogočajo kvalitetno kompozicijo, lahko zavestno kršenje teh lastnosti prav tako vodi do izjemnih del.

Pri določanju geometrije kompozicije umetniškega dela obstaja več pristopov oziroma izkustvenih pravil. Najbolj znano pravilo je prav gotovo zlati rez, ki temelji na zlatem razmerju. Dve količini sta v zlatem razmerju (φ), kadar je razmerje vsote obeh količin in večje izmed količin enak razmerju večje in manjše količine (enačba 3.1). Vrednost zlatega razmerja je približno 1.62. Grafično ponazoritev tega pravila lahko vidimo na sliki 3.2.

$$\frac{a+b}{a} = \frac{a}{b} = \varphi \quad (3.1)$$

Poenostavitev zlatega reza je pravilo tretjin, ki ga bomo opisali v nadaljevanju.

3.2.1 Pravilo tretjin

Pravilo tretjin je izkustveno pravilo ali smernica, ki se pogosto uporablja v slikarstvu, fotografiji in oblikovanju. Ukvarja z umestitvijo za fotografijo



Slika 3.3: Fotografiji z istim motivom vendar z drugačnim obrezom. Leva fotografija ne upošteva pravila tretjin. Desna slika, ki to pravilo upošteva, je privlačnejša.

pomembnih elementov. Najpomembnejši element fotografije ali subjekt naj se ne bi nahajal v centru fotografije razen v primeru da je zaželjena simetričnost fotografije. Pravilo razdeli sliko na 9 enakih delov z dvema enakomerno porazdeljenima horizontalnima črtama in z dvema prav tako enakomerno porazdeljenima vertikalnima črtama. Pravilo pravi, da bi morali pomembni elementi ležati ob teh črtah ali na njihovih presečiščih.

3.2.2 Liho pravilo

Človeški možgani so nagnjeni k združevanju elementov v pare. Tako v primeru da se v fotografiji nahaja sodo število elementov, možgani nimajo težjega dela z iskanjem parov in simetrije. Zato takšne fotografije pogosto izpadejo kot puste. Liho pravilo nam zato pravi, da če je le mogoče, v sliko vstavimo liho število elementov. V primeru, da imamo en predmet, ki nam predstavlja subjekt, mu dodamo še dva podporna objekta namesto enega samega. Pogost primer uporabe tega pravila je kompozicija treh elementov, ki med seboj tvorijo obliko trikotnika ali pa črte. Pravilo izgubi na svojem pomenu, ko je število elementov preveliko.

3.2.3 Pravilo prostora

Pravilo pravi, da v primeru, ko želimo poustvariti iluzijo gibanja ali pa ponazoriti vsebinsko praznino, pustimo prazen prostor v smeri kamor gleda oseba ali predmet na sliki. V primeru da fotografiramo tekača, nam prazen prostor pred njim daje občutek gibanja v to smer.

3.2.4 Simetrija

Kadar govorimo o organizmih, dojemamo simetrijo kot prikaz zdravja posameznega organizma. Zelo očiten primer simetrije opazimo pri človeškem obrazu, bilateralno simetrijo, ki razdeli sliko v dve zrcalno enaki polovici. Simetričnost je v tem primeru vizualno privlačnejša. Posledično ima simetrija podoben vpliv na dojetanje ostalih objektov. Manj opazen vpliv ima simetrija na dojetanje enostavnosti umetniškega dela, ki v gledalcu zbuja občutke varnosti, urejenosti in domačnosti. Kljub človeški psihološki naravnosti k simetriji pa težnja k prekomerni simetriji izpade dolgočasno in nezanimivo. Ljudje si želimo raziskovanja novih možnosti, ki jih v prekomerno simetričnih delih pri-manjkuje. Pravi izziv za umetnika je poiskati pravo razmerje med simetrijo in asimetrijo.

3.2.5 Perspektiva

Perspektiva gledalca lahko pomembno vpliva na njegovo dojetanje slike. Če fotografiramo objekt odzgoraj, navidezno zmanjšamo njegovo velikost, nasprotno pa fotografiranje odspodaj navidezno poveča predmet in mu daje veličino. V primeru, da je fotografija nastala iz višine samega objekta, doživljamo tak objekt kot nam enakovreden.

3.2.6 Horizont

Pri fotografijah krajine in morja, ki nimajo izrazitega subjekta, pridobi na veljavi pozicija ločnice med zemljo (ali morjem) in nebom. Ločnica ali hor-

izont naj ne bi delil fotografije na dva enako velika dela, ampak naj bi s svojimi proporcijami dal poudarek nebu ali pa zemlji.

Poglavje 4

Uporabljene značilke

Kot že v delih pred nami [12, 1], smo dali velik poudarek na opazovanju osrednjega objekta ali subjekta fotografije v relaciji s celotno fotografijo. Subjekt fotografije smo določili ročno s pomočjo izkušenih fotografov. Zaradi enostavnosti za ocenjevalce in lažji izračun značilk smo subjekt označili s pravokotnim markerjem. Z definicijo pozicije in velikosti subjekta smo lahko definirali značilke, ki opisujejo različne kvalitete samega subjekta, kot tudi primerjavo kvalitet subjekta s celotno fotografijo. Od 31 definiranih in implementiranih značilk je kar 23 značilk odvisnih od definicije subjekta.

Implementirane značilke lahko na grobo razdelimo v 3 kategorije, in sicer na značilke, ki opisujejo: 1. barvno paleto fotografije, 2. proporce fotografije in 3. kompozicijo fotografije.

V okviru analize barvne palete smo si ogledali:

- število barvnih odtenkov,
- povprečen odtenek,
- število dominantnih barv,
- povprečno dominantno barvo,
- povprečno nasičenost barve,
- povprečno osvetlitev,

- povprečno intenziteto pikslov,
- kontrast med subjektom in celotno sliko.

Vse zgoraj naštet lastnosti fotografij, razen seveda zadnje postavke, smo izračunali tako na subjektu fotografije kot na celotni sliki. Prav tako pa smo izračunali razmerje oz. razliko med obema količinama.

Naslednja kategorija lastnosti, ki smo jo opazovali so bili proporci fotografije. V okviru analize proporcev smo preučili razmerje velikosti stranic fotografije in tudi velikost subjekta v primerjavi s celotno sliko.

Nazadnje smo preučili kompozicijo fotografije. V okviru analize kompozicije smo si ogledali, kako postavitve subjekta fotografije sledi pravilu tretjin in za koliko je subjekt oddaljen od stranic fotografij. Nazadnje smo naredili še analizo prostorske porazdelitve robov, s čimer smo ugotavljali, kje v fotografiji je največ dogajanja.

4.1 Barvna shema

4.1.1 Predstavitev barv

Ko analiziramo barve uporabljene v fotografiji je potrebno najprej razumeti kako so barve sploh predstavljene. Zato predstavimo koncept barvnega prostora, ki opisujejo, kako so te barve sploh zapisane. Najpogostejša je uporaba barvnega prostora RGB (red, green, blue), ki je sestavljen iz treh barvnih komponent: rdeče, zelene, modre. Ostali pogosto uporabljeni prostori so še CMYK in HSV. V nadaljevanju bomo opisali barvna prostora RGB in HSV, ki smo ju uporabili v našem diplomskem delu.

4.1.2 Barvni prostor RGB

Je aditivni barvni prostor, v katerem z mešanjem treh komponent poustvarimo široko paleto barv. Uporablja se pogosto pri vzorčenju, zapisu in prikazu slik na različnih elektronskih napravah, kot na primer računalniških

zaslonih (CRT, LCD), TV zaslonih (LCD, plazma), in pa tudi v fotoaparatih in video kamerah.

Za nastanek barve v prostoru RGB potrebujemo 3 barvne odtenke ali komponente. Z mešanjem oz. prilagajanjem intenzitete posamezne komponente lahko poustvarimo širok nabor barv. Če je intenziteta vseh treh komponent 0, to pomeni črno barvo (ni svetlobe). Vse ostale barve dobimo z mešanjem teh treh komponent. Treba je poudariti, da je barvni prostor RGB odvisen od naprave, ki reproducira dano vrednost RGB. V obratnem primeru, če so vse komponente prisotne v polni intenziteti, dobimo belo barvo.

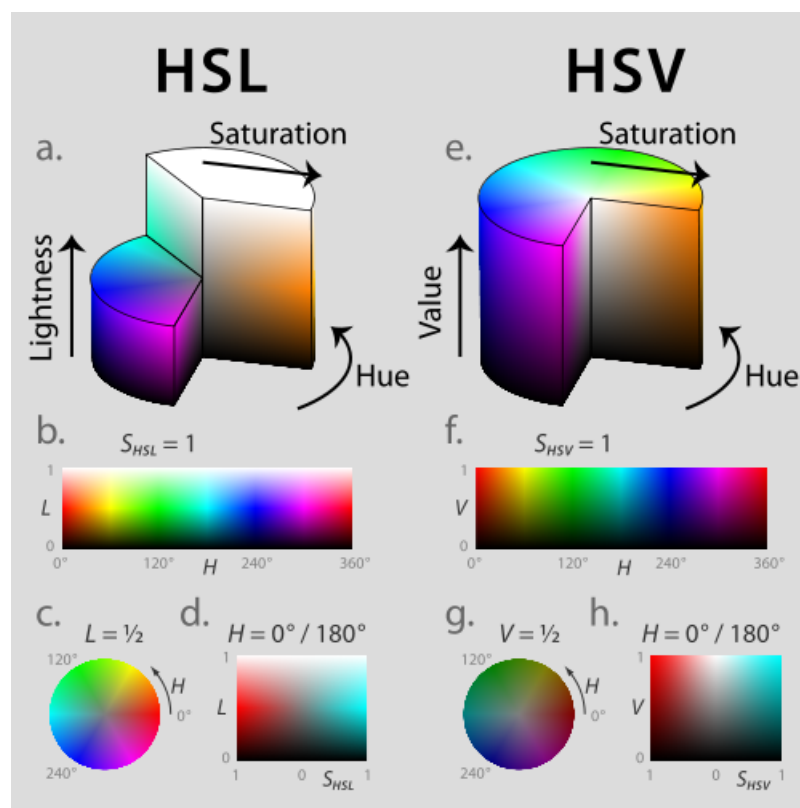
Barva v prostoru RGB je predstavljena kot trojček (r,g,b), sestavljen iz komponent, ki predstavljajo intenzitete posamezne komponente RGB. Vsaka komponenta lahko vsebuje vse vrednosti od 0 pa do maksimalne določene vrednosti. Tu razlikujemo 3 različne formate:

- realno število od 0 do 1 (zapis s plavajočo vejico)
- zapis z procenti od 0 do 100 %
- 0 do 255 (8 bitno nepredznačeno število)
- 0 do 65,535 (16 bitno nepredznačeno število)

4.1.3 Barvni prostor HSV

Barvni prostor HSV in njemu podobni HSL sta primera cilindrične reprezentacije točk v prostoru RGB. Njun namen je predstaviti bolj intuitiven barvni prostor za aplikacije, ki se ukvarjajo z računalniško grafiko, analizo slik in računalniškem vidom.

HSV je sestavljen iz treh komponent: hue (odtenek), saturation (nasičenost), value (osvetlitev). Pogosto se za prostor HSV uporablja tudi sinonim HSB, kjer zadnja črka pomeni brightness (osvetlitev - op. p. isti prevod kot zgoraj za value). Prostoru HSV podoben pa je barvni prostor HSL. Od prostora HSV se razlikuje po zadnji komponenti - lightness (prevedeno kot svetlost). Razlika med osvetlitvijo (brightness) in svetlostjo (lightness) je, da




Slika 4.1: Predstavitev barvnega prostora HSV (in HSL).

je osvetlitev čiste barve enaka osvetlitvi bele barve, medtem ko je svetlost čiste barve enaka svetlosti sive barve.

V cilindru vrtenje okrog centralne navpične osi predstavlja spremembo odtenka barve (hue), razdalja od centralne vertikalne osi predstavlja spremembo v nasičenosti barve (saturation), premikanje po dolžini te osi pa pomeni spremembo osvetljenosti. Na tem mestu moramo poudariti, da je prostor HSV samo preslikava barvnega prostora RGB, ki je odvisen od naprave, zato se lahko odtenki barv razlikujejo med posameznimi napravami.

Poleg barvnega odtenka pri našem dojetanju barve igra pomembno vlogo nasičenost barve. Nasičenost barve je eden od izrazov, ki se uporabljajo za opisovanje intenzitete določene barve. Ostali izrazi vključujejo barvitost, kroma, čistost barve in inteziteto. Te izrazi se pogosto v literaturi uporabljajo izmenično, vendar se njihove definicije razlikujejo. Če želimo razumeti



Slika 4.2: Nasičenost barve - originalna slika na levi in njena kopija z 50% več barvne nasičenosti.

pojem nasičenost barve, moramo najprej definirati koncept barvitosti slike. Barvitost predstavlja razliko med barvo in sivino. Pojem nasičenosti barve je tesno povezan z barvitostjo, ponazarja namreč barvitost barve, ki je relativna glede na svojo osvetljenosti.

V knjižnici SimpleCV je nasičenost barve predstavljena kot vrednost od 0 do 255.

Osvetljenost kot zadnja komponenta v prostoru HSV, predstavlja količino svetlobe, ki jo oddaja ali odbija objekt. Manjša je osvetljenost, bolj dojemamo barvo kot črno, kar lahko vidimo na sliki 4.3. V knjižnici SimpleCV je nasičenost barve predstavljena kot vrednost od 0 do 255.


4.1.4 Število barvnih odtenkov

Kljub temu da profesionalne fotografije izgledajo žive, pogosto uporabljajo malo število barvnih odtenkov [10].


Za izračun števila barvnih odtenkov smo sliko najprej pretvorili v že prej opisani barvni prostor HSV. Izračunali smo histogram odtenkov barv s 30 stolpci, pri čemer smo upoštevali samo odtenke, katerih njihova nasičenost z barvo presega 20 % hkrati pa tudi njihova osvetljenost presega 15 %. Za rezultat smo upoštevali samo stolpce, ki vsebujejo več kot 0,5 % vseh pikslov v fotografiji. Število barvnih odtenkov smo izračunali tako za celotno sliko kot tudi ločeno samo za subjekt fotografije. Izračunali smo tudi razmerje med številom odtenkov v celotni sliki in subjektom.



Slika 4.3: Vpliv pojemanja osvetlitve na dojetanje barve.



Slika 4.4: Fotografije, ki se med seboj razlikujejo po njihovi barvitosti za katere smo izračunali število barvnih odtenkov.



Slika 4.5: Histogrami barvnih odtenkov za pripadajoče fotografije na sliki 4.4 . Število barvnih odtenkov (od leve proti desni): 5, 22 in 9 odtenkov.

4.1.5 Povprečen odtenek

Za izračun povprečnega odtenka vzamemo že prej izračunan histogram HSV odtenkov s 30 stolpci (4.1.4). S pomočjo enačbe 4.1 izračunamo povprečen odtenek barve, ki jo predstavlja distribucija podana s histogramom. Povprečen odtenek izračunamo tako na celotni sliki kot na subjektu. Izračunamo pa tudi razliko povprečnih odtenkov med subjektom in celotno fotografijo.

$$\mu = \frac{1}{N} \sum_{k=1}^N x_k P(x_k) \quad (4.1)$$

4.1.6 Število dominantnih barv

Identifikacije dominantnih barv smo se lotili z uporabo metode implementirane v knjižnici SimpleCV, ki bazira na programski kodi avtorja Elija Billaerja [2]. Metoda najprej izračuna histogram barvnih odtenkov, nato pa pri dani distribuciji poišče vse vrhove, ki predstavljajo dominantne barve v fotografiji. Metoda, za razliko od naivnega pristopa pri identifikaciji vrhov s pomočjo prvega odvoda, analizira vrednost krivulje levo in desno od potencialnega vrha, da izloči vse morebitne lažne vrhove. Število dominantnih barv izračunamo tako za subjekt kot celotno fotografijo. Izračunamo pa tudi razmerje med številom barv, uporabljenih v subjektu in celotni fotografiji.

4.1.7 Povprečna dominantna barva

S pomočjo metode za detekcijo dominantnih barv, opisane v 4.1.6 dobimo histogram dominantnih barv. Nato pa s pomočjo enačbe 4.1 izračunamo povprečno dominantno barvo.

4.1.8 Povprečna nasičenost barve (saturacija)

Izračunamo histogram HSV nasičenosti barve s 30 stolpci. Po enačbi 4.1 izračunamo povprečno nasičenost. Nasičenost izračunamo tako nad subjektom kot celotno sliko, na koncu pa izračunamo še njuno razliko.

4.1.9 Povprečna osvetlitev

Izračunamo histogram HSV osvetlitve s 30 stolpci. Po enačbi 4.1 izračunamo povprečno osvetlitev. Osvetlitev izračunamo nad subjektom in celotno fotografijo, na koncu pa izračunamo še njuno razliko.

4.1.10 Povprečna intenziteta pikslov

Fotografijo najprej pretvorimo v sivinsko obliko. Nato izračunamo sivinski histogram s 30 stolpci. Po enačbi 4.1 izračunamo povprečno intenziteto pikslov. Intenziteto izračunamo nad subjektom in celotno sliko, na koncu pa izračunamo še njuno razliko.

4.1.11 Kontrast med subjektom in celotno sliko

Kontrast fotografije ni enotno definiran pojem, vendar pa običajno predstavlja razliko med odtenkom barve in osvetljenostjo objekta v relaciji z ostalimi objekti. V našem primeru smo ga definirali kot zmnožek med razliko povprečnih odtenkov subjekta in celote ter razliko med povprečno osvetlitvijo prav tako med subjektom in celoto 4.2. Pri obeh, razliki med povprečnima odtenkom kot tudi razliki med povprečnima osvetlitvama, smo vzeli absolutno vrednost.

$$|H1 - H2| * |B1 - B2| \tag{4.2}$$

4.2 Razmerja velikosti fotografije

4.2.1 Razmerje med stranicami fotografije

Profesionalne fotografije imajo pogosto neobičajna razmerja stranic, saj izkušeni fotografi pogosto naknadno spreminjajo okvir fotografije glede na izbran motiv [9]. Zato nam ta enostavna značilka posredno nekaj pove o kvaliteti posnetka. Izračunamo tako razmerje med stranicami celotne fotografije kot

tudi razmerja stranic subjekta in razliko razmerij med celotno sliko in subjektom.

4.2.2 Razmerje med velikostjo subjekta in celotne slike

Kot smo omenili v poglavju 3, je za kvaliteten posnetek je potreben izrazit motiv, kar obsega tudi njegovo relativno velikost glede na celotno fotografijo.

4.3 Kompozicija

Kot smo opisali v podpoglavju 3.2, kompozicija igra ključno vlogo pri estetski privlačnosti fotografije. Analizirali smo, koliko fotografija sledi izkustvenemu pravilu tretjin opisanem v razdelku 3.2.1.

4.3.1 Oddaljenost središča subjekta od t.i. napetostnih točk (stress points) pri pravilu tretjin

Najprej izračunamo 4 napetostne točke, to so točke, ki ležijo na presečišču horizontalnih in vertikalnih črt in predstavljajo mrežo definirano po pravilu tretjin. Nato pa izračunamo evklidsko razdaljo središča subjekta do najbližje napetostne točke. To razdaljo še normaliziramo glede na dolžino diagonale celotne fotografije.

4.3.2 Oddaljenost stranic subjekta od robov okvirja fotografije

V fotografiji običajno ni zaželeno, da bi se motiv nahajal blizu robov okvirja posnetka. Izračunamo oddaljenost subjekta od vseh štirih robov.

4.3.3 Prostorska porazdelitev robov slike (oddaljenost robov od središča fotografije)

Kot smo že omenili ni zaželeno, da se motiv ali pomembnejši elementi nahajajo blizu robov slike. V tem primeru smo problem obrnili in ga definirali kot oddaljenost robov od središča slike. Najprej s pomočjo Canny detektorja robov dobimo sliko z označenimi robovi. Nato pa za vsak piksel v sliki, ki predstavlja rob, izračunamo evklidsko razdaljo do središča slike. Izračunane razdalje seštejemo in normaliziramo tako, da delimo s številom vseh pikslov v fotografiji. Zabeležimo tudi vsoto pikslov, ki so označena kot rob, in jo normaliziramo s številom vseh pikslov v fotografiji.

Poglavje 5

Zajem učnih podatkov

Za pridobitev učnih podatkov smo za pomoč zaprosili izkušene fotografe. Zajema učnih podatkov smo se lotili z izdelavo enostavne spletne aplikacije, in sicer s pomočjo spletnega ogrodja Django, javascript knjižnice jQuery in podatkovne zbirke MySQL. Aplikacija je fotografu omogočila, da je na enostaven način označil subjekt fotografije, če je ta seveda obstajal, tako da je potegnil pravokotni marker čez fotografijo. Nato je podal še ocene fotografije, in sicer glede na v naprej definirane parametre (slika 5.1).

V želji po globljem razumevanju problema smo se odločili, da poleg splošne ocene fotografije povprašamo še po bolj podrobnih parametrih, ki definirajo estetiko fotografije. Prav tako pa smo s povpraševanjem po podrobnih parametrih želeli doseči večjo objektivnost pri ocenjevanju slik. V želji po čim bolj konsistentnih rezultatih smo močno omejili nabor možnih ocen - na samo tri možne vrednosti: slaba, povprečna, dobra.

Parametri in njihov nabor ocen, po katerih smo spraševali, so bili poleg splošne ocene še:

- kompozicija (slaba, povprečna, dobra)
- barvna paleta (slaba, povprečna, dobra)
- osvetlitev (slaba, povprečna, dobra)
- ostrina fotografije (slaba, povprečna, dobra)

**Kompozicija:**

slaba povprečna dobra

Barvna paleta:

slaba povprečna dobra

Osvetlitev:

slaba povprečna dobra

Ostrina slike:

slaba povprečna dobra

Splošna ocena slike:

slaba povprečna dobra

Razločljivost motiva:

slaba / ni motiva povprečna dobra

Motiv

x koord.: y koord.: dolžina: širina: [Reset](#)

Slika 5.1: Zaslonski posnetek spletne aplikacije za označevanje in ocenjevanje fotografij.

- razločljivost motiva (slaba/ni motiva, povprečna, dobra)

Pri zajemu učnih podatkov smo seveda želeli ustvariti čim večjo zbirko označenih in ocenjenih fotografij glede na naše zmožnosti. Pravtako pa smo zaradi kredibilnosti težili k cilju, da ima vsaka fotografija vsaj 3 ocene. Ker je ocenjevanje fotografij, še posebej pa označevanje subjekta, časovno potratno opravilo, bi bila ocena celotne zbirke fotografij prevelik zalogaj za enega samega uporabnika. Zato nismo vztrajali na zahtevi, da fotograf označi vse slike v zbirki, ampak smo se zadovoljili s pogojem, da ima vsaka fotografije 3 ocene različnih ocenjevalcev.

Za ocenjevanje smo uporabili fotografije iz spletnega portala Flickr. Izbrali smo fotografije, ki so bile pravkar naložene na portal ("recently uploaded"). Tem smo zaradi slabe kvalitete dodali slike iz kategorije "pick of the day". Z ročno selekcijo smo nato izločili med seboj preveč podobne fotografije in pa abstraktne fotografije. To smo storili zaradi enostavnosti in želje, da bi naš sistem uporabili v realnem svetu, in sicer za pomoč uporabnikom, ki fotografiranja niso večji. Ker smo želeli dobiti uravnoteženo učno zbirko, smo se po opozorilu fotografov o slabi kvaliteti teh fotografij odločili, da vključimo tudi fotografije 'picks of the day', ki so bistveno boljše kvalitete.

Vrstni red fotografij, ki so jih ocenjevali fotografi, je bil naključen. Na ta način smo preprečili monotonost, saj bi ocenjevanje v vrstnem redu (glede na to, kdaj smo fotografije dodali) lahko privedlo do tega, da bi fotografi ocenjevali več slik istega tipa zapored. Ta monotonost bi imela za posledico manjšo pozornost in tako tudi manj objektivne rezultate. Prav tako je bila prisotna nevarnost daljšega zaporedja fotografij nizke oziroma visoke kvalitete kar bi lahko imelo za posledico prilagoditev kriterijev ocenjevalca navzdol ali pa navzgor, to pa bi pripeljalo do nekonsistentnih rezultatov. Pozorni smo bili tudi na potencialno utrujenost fotografov zaradi dolgotrajnega ocenjevanja. Zato smo omogočili, da lahko fotograf prekine z ocenjevanjem in fotografije oceni v več sejah.

V zavedanju, da se zelene lastnosti fotografije razlikujejo glede na tip in namen, smo fotografije naknadno ročno razvrstili v posamezne kategorije. Te

tip fotografije	št. slik	povprečna ocena
živali	14	2.33
arhitektura	12	2.11
črno & bela	13	2.51
vozila	8	1.73
mestna panorama	7	2.82
close up	33	1.95
rože	11	2.49
notranjost	23	1.89
pokrajina & narava	47	2.47
ljudje & prireditve	32	1.81
portreti	36	2.39
šport	17	1.69
podvodo	10	1.54
urbano	11	1.95


Tabela 5.1: Tipi fotografij in število fotografij posameznega tipa.

podatke smo kasneje uporabili za strojno učenje. Vseh kategorij je bilo 14 in jih skupaj s številom slik v posamezno kategoriji lahko vidite v spodnji tabeli.


V naši zbirki fotografij se nahaja 274 fotografij, ki so ocenjene s pomočjo 14 izkušenih fotografov. Od tega ima 258 fotografij vsaj 3 ocene. Povprečna ocena fotografije je bila 2.14. Število ocenjenih fotografij po ocenjevalcu in njihovo povprečno oceno lahko vidite v tabeli 5.2. Zaradi varovanja podatkov smo njihova imena nadomestili z zaporedno številko ocenjevalca. Kot zanimivost prilagamo tudi nekaj primerov najboljših (slika 5.2) kot tudi najslabših fotografij (slika 5.3).

ocenjevalec	št.ocenjenih slik	povprečna ocena
oc1	275	2.10
oc2	14	2.07
oc3	5	1.60
oc4	107	2.04
oc5	40	2.30
oc6	9	1.67
oc7	22	2.09
oc8	38	1.89
oc9	71	2.32
oc10	96	2.27
oc11	81	1.79
oc12	40	1.88
oc13	174	2.39
oc14	9	1.67

Tabela 5.2: Število ocenjenih slik, ki jih je ocenil posamezno ocenjevalec skupaj s povprečno skupno oceno. Ocenjevalci so za skupno oceno izbirali med možnostmi: slabo (1), povprečno (2), dobro (3).



Slika 5.2: Nekaj fotografij iz naše zbirke, ki so dobile najboljše ocene.



Slika 5.3: Nekaj fotografij iz naše zbirke, ki so dobile najslabše ocene.

Poglavje 6

Rezultati

Z ocenjenimi in označenimi fotografijami, opisanimi v prejšnjem poglavju, in z izračunanimi značilkami, opisanim v poglavju 4, smo bili pripravljene na izvedbo strojnega učenja in kasnejšo analizo uporabljenih značilk, pri katerem smo uporabili programsko orodje Orange. Za glavni del naše analize smo fotografije klasificirali glede na njihovo splošno oceno, po kateri smo že spraševali fotografe.

Za učno množico smo vzeli samo fotografije, ki so zadoščale našim pogojem za kredibilno oceno fotografije. Ti pogoji so bili: 1. obstajajo vsaj 3 ocene iste fotografije, 2. nobena ocena se od ostalih ne razlikuje za več kot en nivo ter 3. večina ocen je v soglasju. Učna množica, ki je zadoščala tem pogojem, je vsebovala 192 primerov. Njihovo porazdelitev lahko vidite na sliki 6.2.

Za strojno učenje smo uporabili metode Naivni Bayes, klasifikacijsko drevo in pa SVM. Metodo Naivni Bayes smo izbrali kot primer enostavnega algoritma za strojno učenje. Poleg enostavnosti pa s pomočjo nomograma, ki nam je na voljo ob uporabi te metode, lahko ocenimo kvaliteto izračunanih značilk. Kot drugo metodo smo izbrali klasifikacijsko drevo predvsem zaradi enostavnosti interpretacije rezultatov. Kot zadnjo metodo smo vzeli SVM klasifikator, ki je služil za primerjavo prejšnjih dveh algoritmov z metodo, ki v večini primerov daje najboljše rezultate. V rezultatih lahko opazite še

klasifikator Majority, ki vse primere klasificira v večinski razred, in služi za primerjavo kot spodnja meja za klasifikacijsko natančnost.

Pri metodi Naivni Bayes smo uporabili privzete nastavitve, ki jih nam ponudi programsko orodje Orange. Za predhodno verjetnost (prior) smo uporabili relativno frekvenco, velikost okna LOESS je bil 0.5 s številom vzorčnih točk nastavljenih na 100. Pri klasifikacijskem drevesu je bil kriterij za izbor atributov "information gain", izbrali smo opcijo za iskanje optimalnega reza (search for optimal split). Minimalno število primerov v listih smo nastavili na 2 in izvedli rezanje drevesa s privzeto nastavljenim m-estimate. Za klasifikator SVM smo uporabili jedro RBF, kjer smo sami knjižnici dopustili, da poišče optimalne vrednosti parametrov 'Cost in 'Complexity bound' za model.

Klasifikacijske metode smo testirali s petkratnim prečnim preverjanjem. Kot rezultate prilagamo klasifikacijsko točnost in pa površino pod ROC krivuljo (AUC).

Kot smo že omenili v poglavju 5, smo fotografijam naknadno ročno določili tip fotografije (tabela: 5.1). Zaradi pomisleka o izgubi splošnosti smo naredili analizo tako z upoštevanjem tipa fotografije kot tudi brez uporabe tega atributa. V nadaljevanju bomo najprej predstavili rezultate klasifikacije fotografij glede na splošno oceno. Fotografije smo najprej klasificirali v 3 razrede, nato pa smo jih z istimi atributi klasificirali še v 2 razreda. V primeru klasifikacije v 3 razrede najprej prilagamo rezultate klasifikacije z uporabo vseh atributov. Izmed teh atributov smo kasneje izbrali 15 najboljših, ki smo jih ponovno uporabili za klasifikacijo. Te rezultate navajamo v nadaljevanju. Kasneje pa tem atributom pridružimo še prej omenjen tip fotografije in ponovno opravimo klasifikacijo. V nadaljevanju pa predstavimo tudi rezultate klasifikacije v 2 razreda, in sicer glede na splošno oceno. Klasifikacijo smo opravili s pomočjo 16 najboljših atributov, ki smo jih predhodno izbrali in jih predstavljamo v nadaljevanju. Tem atributom kasneje pridružimo še tip fotografije in ponovimo klasifikacijo. Na koncu pa predstavimo še rezultate klasifikacije fotografij v tri razrede, glede na kompozicijo in uporabljeno

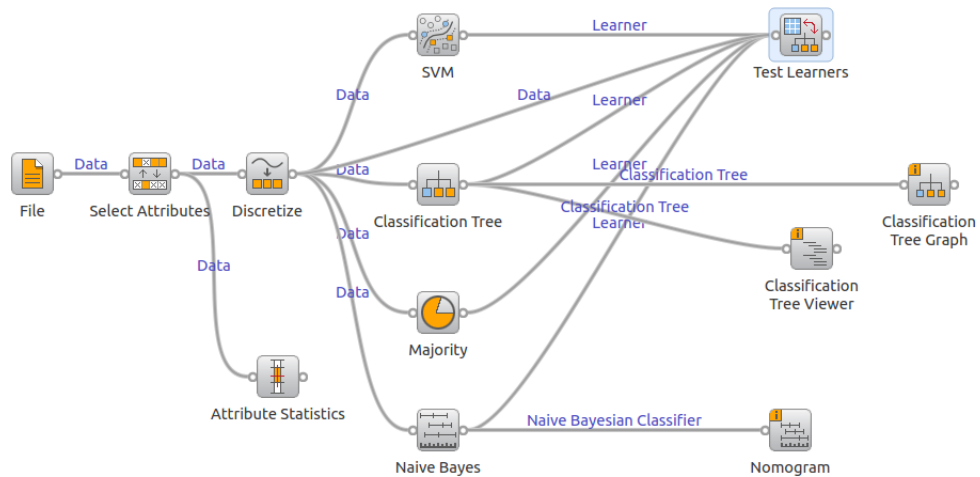
	CA	AUC
Naive Bayes	0.4792	0.6429
Majority	0.4065	0.5000
Classification Tree	0.4694	0.5826
SVM	0.5051	0.6034

Tabela 6.1: Klasifikacija fotografij glede na splošno oceno brez upoštevanja tipa fotografije. Kratica CA ponazarja klasifikacijsko natančnost, AUC pa površino pod ROC krivuljo.


barvno shemo fotografije.

6.1 Klasifikacija fotografij v 3 razrede glede na splošno oceno

Za strojno učenje, čigar rezultati so predstavljeni v tabeli 6.1, smo uporabili attribute, predstavljene v tabeli 6.2. Z analizo atributov smo iz začetnega nabora 31 značilnk izbrali 15 značilnk, ki najbolj pripomorejo k klasifikacijski natančnosti. Te značilke smo izbrali s pomočjo metrike ReliefF. V začetku smo izbrali vse značilke s pozitivno vrednostjo prej omenjene metrike. Nato pa smo z izločanjem slabših značilnk glede na vrednost metrike reliefF poizkušali pridobiti najmanjši nabor značilnk, s katerim dobimo kar največjo klasifikacijsko natančnost pri klasifikatorju SVM. Izbrali smo 15 značilnk z najboljšo vrednostjo metrike reliefF (prvih 15 značilnk v tabeli 6.2.) in ponovno opravili strojno učenje (tabela 6.3). Po definiciji najboljših značilnk smo tem značilkam pridružili še tip fotografije in ponovno opravili strojno učenje (tabela 6.4).



Slika 6.1: Shema v programskem orodju Orange za analizo podatkov in strojno učenje.



Slika 6.2: Graf porazdelitve učnih primerov glede na splošno oceno. Možne ocene so: 1 (slaba), 2 (povprečna), 3 (dobra).

#	značilka	reliefF	inf. prispevek	gain ratio
1	peaks_count_whole (4.1.6)	0.041	0.066	0.035
2	hues_whole_avg (4.1.5)	0.032	0.041	0.020
3	edges_pixel_count (4.3.3)	0.028	0.014	0.007
4	offset_left (4.3.2)	0.026	0.089	0.044
5	hues_subj_avg (4.1.5)	0.024	0.034	0.017
6	edges_dist_sum (4.3.3)	0.023	0.025	0.013
7	saturation_avg_diff (4.1.8)	0.014	0.042	0.022
8	offset_bottom (4.3.2)	0.013	0.060	0.030
9	saturation_subj_avg (4.1.8)	0.012	0.032	0.016
10	subj_relative_size (4.2.2)	0.010	0.059	0.029
11	brightness_subj_avg (4.1.9)	0.010	0.025	0.012
12	hues_count_ratio (4.1.4)	0.007	0.059	0.034
13	intensity_avg_diff (4.1.10)	0.007	0.104	0.052
14	brightness_whole_avg (4.1.9)	0.006	0.032	0.016
15	contrast_subj_whole (4.1.11)	0.005	0.056	0.028
16	aspect_ratio_subj (4.2.1)	0.003	0.034	0.017
17	peaks_count_ratio (4.1.6)	0.003	0.056	0.032
18	brightness_avg_diff (4.1.9)	0.003	0.071	0.036
19	offset_top (4.3.2)	0.002	0.071	0.035
20	intensity_whole_avg (4.1.10)	0.001	0.017	0.008
21	saturation_whole_avg (4.1.8)	0.001	0.051	0.025
22	hues_count_whole (4.1.4)	0.000	0.054	0.027
23	peaks_count_subject (4.1.6)	0.000	0.085	0.043
24	hues_count_subject (4.1.4)	-0.000	0.035	0.018
25	aspect_ratio_diff (4.2.1)	-0.001	0.011	0.007
26	aspect_ratio (4.2.1)	-0.001	0.023	0.012
27	min_distance_stress_point (4.3.1)	-0.001	0.069	0.037
28	hues_avg_diff (4.1.5)	-0.004	0.067	0.034
29	intensity_subj_avg (4.1.10)	-0.004	0.015	0.008
30	peaks_avg_diff (4.1.7)	-0.006	0.072	0.036
31	offset_right (4.3.2)	-0.012	0.077	0.038


Tabela 6.2: Atributi, razvrščeni po metriki reliefF. V oklepaju je zapisana številka razdelka, kjer je bila ta značilka predstavljena.

	CA	AUC
Naive Bayes	0.4586	0.6184
Majority	0.4065	0.5000
Classification Tree	0.3650	0.4716
SVM	0.5416	0.6302

Tabela 6.3: Klasifikacija fotografij glede na splošno oceno z uporabo 15 najboljših značilnk brez uporabe tipa fotografije. Kratica CA ponazarja klasifikacijsko natančnost, AUC pa površino pod ROC krivuljo.

	CA	AUC
Naive Bayes	0.5729	0.7640
Majority	0.4065	0.5000
Classification Tree	0.4997	0.7105
SVM	0.6196	0.7961

Tabela 6.4: Klasifikacija fotografij glede na splošno oceno z uporabo 15 najboljših značilnk, ki smo jim dodali še tip fotografije. Kratica CA ponazarja klasifikacijsko natančnost, AUC pa površino pod ROC krivuljo.



Slika 6.3: Distribucija učnih primerov glede na splošno oceno, kjer smo izločili primere s povprečno oceno. Možne ocene so: 1 (slaba), 2 (povprečna), 3 (dobra).

6.2 Klasifikacija fotografij v 2 razreda glede na splošno oceno

Pri klasifikaciji fotografij v 2 razreda smo vzeli isti nabor značilk kot že poprej. Z analizo atributov smo iz začetnega nabora 31 značilk izbrali 16 značilk, ki najbolj pripomorejo k klasifikacijski natančnosti. Te značilke smo ponovno izbirali s pomočjo metrike ReliefF. Izbrali smo značilke s pozitivno vrednostjo prej omenjene metrike, nato pa smo z izločanjem slabših značilk glede na vrednost metrike reliefF poizkušali pridobiti najmanjši nabor značilk s katerim dobimo kar največjo klasifikacijsko natančnost pri klasifikatorju SVM. Izbrali smo 16 značilk z najboljšo vrednostjo metrike reliefF (tabela 6.5), ki smo jih uporabili za strojno učenje (tabela 6.6). Po definiciji najboljših značilk smo tem značilkam pridružili še tip fotografije in ponovno opravili strojno učenje (tabela 6.7).

6.3 Analiza kompozicije fotografije

Poleg splošne ocene smo od ocenjevalcev pridobili tudi oceno kompozicije fotografije. Pri pridobivanju učnih primerov za oceno kompozicije smo uporabili iste kriterije kot že pri splošni oceni. Uporabljene značilke predstavljajo podmnožico značilk uporabljenih pri klasifikaciji glede na splošno oceno. Iz

#	značilka	reliefF	inf. prispevek	gain ratio
1	hues_subj_avg (4.1.5)	0.035	0.015	0.007
2	peaks_count_whole (4.1.6)	0.034	0.036	0.018
3	peaks_count_subject (4.1.6)	0.033	0.012	0.006
4	brightness_subj_avg (4.1.9)	0.031	0.034	0.017
5	saturation_whole_avg (4.1.8)	0.027	0.047	0.023
6	peaks_count_ratio (4.1.6)	0.025	0.028	0.018
7	subj_relative_size (4.2.2)	0.025	0.070	0.036
8	offset_top (4.3.2)	0.024	0.077	0.039
9	hues_whole_avg (4.1.5)	0.023	0.009	0.005
10	brightness_whole_avg (4.1.9)	0.019	0.052	0.026
11	saturation_subj_avg (4.1.8)	0.018	0.003	0.001
12	intensity_subj_avg (4.1.10)	0.017	0.015	0.008
13	hues_avg_diff (4.1.5)	0.011	0.039	0.020
14	brightness_avg_diff (4.1.9)	0.010	0.091	0.049
15	intensity_avg_diff (4.1.10)	0.009	0.059	0.031
16	intensity_whole_avg (4.1.10)	0.009	0.016	0.008
17	peaks_avg_diff (4.1.7)	0.009	0.048	0.025
18	contrast_subj_whole (4.1.11)	0.005	0.032	0.016
19	saturation_avg_diff (4.1.8)	0.003	0.040	0.021
20	hues_count_whole (4.1.4)	0.001	0.032	0.016
21	edges_pixel_count (4.3.3)	-0.002	0.009	0.005
22	aspect_ratio_subj (4.2.1)	-0.004	0.033	0.017
23	offset_left (4.3.2)	-0.004	0.097	0.049
24	aspect_ratio (4.2.1)	-0.004	0.027	0.014
25	edges_dist_sum (4.3.3)	-0.007	0.012	0.006
26	min_distance_stress_point (4.3.1)	-0.007	0.044	0.025
27	hues_count_ratio (4.1.4)	-0.010	0.057	0.035
28	aspect_ratio_diff (4.2.1)	-0.011	0.054	0.028
29	offset_bottom (4.3.2)	-0.015	0.059	0.030
30	offset_right (4.3.2)	-0.016	0.076	0.039
31	hues_count_subject (4.1.4)	-0.017	0.008	0.004

Tabela 6.5: Atributi, razvrščeni glede na metriko reliefF, ki so bili uporabljeni za klasifikacijo v 2 razreda glede na splošno oceno. Rezultati klasifikacije so predstavljeni v tabeli 6.6. V oklepaju je zapisana številka razdelka, kjer je bila ta značilka predstavljena.

	CA	AUC
Naive Bayes	0.6824	0.7078
Majority	0.5099	0.5000
Classification Tree	0.7557	0.7690
SVM	0.9340	0.9068

Tabela 6.6: Klasifikacija fotografij v 2 razreda (slaba, dobra) glede na splošno oceno z uporabo 16 najboljših značilnk brez uporabe tipa fotografije. Kratica CA ponazarja klasifikacijsko natančnost, AUC pa površino pod ROC krivuljo.

	CA	AUC
Naive Bayes	0.8409	0.9197
Majority	0.5099	0.5000
Classification Tree	0.8342	0.8707
SVM	0.9406	0.9912

Tabela 6.7: Klasifikacija fotografij v 2 razreda (slaba, dobra) glede na splošno oceno z uporabo 16 najboljših značilnk in uporabo tipa fotografije. Kratica CA ponazarja klasifikacijsko natančnost, AUC pa površino pod ROC krivuljo.


#	značilka	inf. prispevek	gain ratio	reliefF
1	offset_right (4.3.2)	0.026	0.111	0.055
2	subj_relative_size (4.2.2)	0.015	0.114	0.057
3	aspect_ratio (4.2.1)	0.013	0.012	0.006
4	offset_bottom (4.3.2)	0.011	0.095	0.048
5	offset_top (4.3.2)	0.007	0.143	0.071
6	aspect_ratio_subj (4.2.1)	0.006	0.051	0.026
7	min_distance_stress_point (4.3.1)	0.004	0.142	0.076
8	offset_left (4.3.2)	0.002	0.145	0.073
9	aspect_ratio_diff (4.2.1)	0.001	0.047	0.027
10	edges_pixel_count (4.3.3)	0.001	0.028	0.014
11	edges_dist_sum (4.3.3)	-0.002	0.030	0.015

Tabela 6.8: Značilke, razvrščene po metriki reliefF, ki opisujejo kompozicijo fotografije.

nabora te podmnožice značilk, ki opisujejo kompozicijo podmnožice (tabela 6.8), smo nadalje izbrali 5 najboljših značilk glede na metriko reliefF in z njihovo pomočjo izvedli strojno učenje. Ti rezultati so predstavljeni v tabeli 6.9.

6.4 Analiza uporabljene barvne palete


Prav tako smo od ocenjevalcev pridobili oceno uporabljene barvne palete na fotografiji. Pogoji za pridobitev učne množice so bili enaki pogojim pri klasifikaciji glede na splošno oceno. Značilke, ki opisujejo barvno paletu fotografije, so navedene v tabeli 6.10. Iz te množice značilk smo izbrali 4 najboljše značilke glede na metriko reliefF in z njihovo pomočjo opravili strojno učenje. Ti rezultati so predstavljeni v tabeli 6.11.



Slika 6.4: Distribucija ocene kompozicije učnih podatkov. Možne ocene so: 1 (slaba), 2 (povprečna), 3 (dobra).

	CA	AUC
Naive Bayes	0.5153	0.6856
Majority	0.5151	0.5000
Classification Tree	0.5351	0.6523
SVM	0.5554	0.6933

Tabela 6.9: Klasifikacija fotografij glede na oceno kompozicije z uporabo 5 najboljših značilk. Kratica CA ponazarja klasifikacijsko natančnost, AUC pa površino pod ROC krivuljo.



Slika 6.5: Distribucija učnih podatkov glede na oceno barvne palete. Možne ocene so: 1 (slaba), 2 (povprečna), 3 (dobra).

#	značilka	reliefF	inf. prispevek	gain ratio
1	peaks_count_ratio (4.1.6)	0.004	0.008	0.005
2	contrast_subj_whole (4.1.11)	0.004	0.010	0.005
3	hues_count_ratio (4.1.4)	0.003	0.028	0.017
4	peaks_count_subject (4.1.6)	0.001	0.045	0.023
5	hues_subj_avg (4.1.5)	-0.000	0.013	0.006
6	hues_whole_avg (4.1.5)	-0.000	0.041	0.021
7	hues_avg_diff (4.1.5)	-0.000	0.021	0.010
8	intensity_whole_avg (4.1.10)	-0.000	0.011	0.005
9	brightness_avg_diff (4.1.9)	-0.001	0.021	0.011
10	saturation_avg_diff (4.1.8)	-0.002	0.055	0.028
11	intensity_subj_avg (4.1.10)	-0.003	0.056	0.028
12	saturation_subj_avg (4.1.8)	-0.004	0.082	0.041
13	intensity_avg_diff (4.1.10)	-0.004	0.031	0.016
14	brightness_subj_avg (4.1.9)	-0.005	0.045	0.022
15	brightness_whole_avg (4.1.9)	-0.006	0.019	0.010
16	saturation_whole_avg (4.1.8)	-0.006	0.042	0.021
17	peaks_count_whole (4.1.6)	-0.007	0.079	0.041
18	hues_count_whole (4.1.4)	-0.008	0.004	0.002
19	hues_count_subject (4.1.4)	-0.013	0.005	0.003
20	peaks_avg_diff (4.1.7)	-0.014	0.027	0.014

Tabela 6.10: Značilke, razvrščene po metriki reliefF, ki opisujejo barvno paleto fotografije.

	CA	AUC
Naive Bayes	0.4326	0.4903
Majority	0.4620	0.5000
Classification Tree	0.4092	0.4374
SVM	0.5499	0.5733

Tabela 6.11: Klasifikacija fotografij glede na oceno barvne palete z uporabo 4 najboljših značilnk. Kratica CA ponazarja klasifikacijsko natančnost, AUC pa površino pod ROC krivuljo.

6.5 Diskusija rezultatov

Pri klasifikaciji fotografij v tri razrede (slaba, povprečna, dobra) glede na splošno oceno smo dosegli bolj hladne rezultate. Z uporabo poprej izbranih najboljših značilnk glede na metriko reliefF, smo dosegli klasifikacijsko natančnost 54 odstotkov z metodo SVM pri čemer je za primerjavo klasifikator, ki je vedno klasificiral primere v večinski razred, dosegel 41 odstotkov. Ko smo izračunanim značilnkam dodali še ročno določen tip fotografije se je klasifikacijska natančnost povzpela na 62 odstotkov. V nadaljevanju pa smo v duhu definicije kvalitetnega in hipnega posnetka iz uvoda, namesto v 3 razrede klasificirali samo v 2 razreda, tako da smo izločili fotografije, ki so bile v glede na definicijo iz začetka poglavja, ocenjene s povprečno oceno. S tem smo iz začetnega nabora 192 učnih primerov izločili 78 fotografij (40 % učnih primerov). Porazdelitev ocen, ki smo jo tako dobili, je bila zelo neenakomerna; 37 fotografij nizke kvalitete v primerjavi z 77 fotografijam visoke kvalitete. To smo popravili tako, da smo podvojili učne primere, ki opisujejo fotografije nizke kvalitete, in tako dobili enakomerno porazdelitev obeh razredov (74 - nizka kvalitete, 77 - visoka kvaliteta). Pri teh učnih podatkih smo dosegli klasifikacijsko natančnost 93 odstotkov z metodo SVM, z uporabo atributa tip posnetka pa 94 odstotkov. Pri tem je bil klasifikator ki je vedno klasificiral primere v večinski razred, na 50 odstotkih. Enako smo ponovili še za analizo kompozicije fotografije in pa uporabljeno

barvno paleto. Z izbiro najboljših značilk smo dosegli 56 odstotno klasi-fikacijsko natančnost s klasifikatorjem SVM pri določanju kompozicije v 3 razrede (slaba, povprečna, dobra) in pa 55 odstotno natančnost pri določanju uporabljene barvne palete (isti razredi kot pri kompoziciji).

Analizo vpliva izračunanih značilk smo opravili na učnih podatkih, ki smo jih uporabili pri klasifikaciji v 2 razreda glede na splošno oceno fotografije. Značilke smo analizirali glede na metriko reliefF in kot dobre značilke štejemo vse značilke s pozitivno vrednostjo te metrike. Vseh značilk, ki zadoščajo temu pogoju, je 20. Lahko jih vidimo v tabeli 6.5. Od teh 20 značilk je kar 14 značilk odvisnih od definicije subjekta. Če teh 20 najboljših značilk razdelimo glede na v poglavju 4 definirane kategorije značilk, opazimo da kar 18 izmed teh značilk opisuje barvno paleto fotografije, značilka `offset_top` (4.3.2) opisuje kompozicijo, `subj_relative_size` (4.2.2) pa proporce fotografije. V nadaljevanju si bomo ogledali podrobno analizo značilk po že predhodno definiranih kategorijah.

6.5.1 Barvna shema

V okviru analize barvne sheme smo si ogledali:

- število barvnih odtenkov,
- povprečen odtenek,
- število dominantnih barv,
- povprečno dominantno barvo,
- povprečno nasičenost barve,
- povprečno osvetlitev,
- povprečna intenziteta pikslov,
- kontrast med subjektom in celotno sliko.

Izmed značilnk, ki podajajo število barvnih odtenkov, se je kot ustrezna izkazala značilka `hues_count_whole` (4.1.4), ki opisuje število uporabljenih barvnih odtenkov v celotni fotografiji. Z nomograma lahko razberemo, da imajo kvalitetne fotografije majhno število barvnih odtenkov, od 1 pa do 5. Značilki `hues_count_subject` 4.1.4 (št. barvnih odtenkov subjekta) in `hues_count_ratio` 4.1.4 (razmerje med številom barv subjekta in celotne fotografije) se nista izkazali za ustrezni. Podobno lastnost so opisovale značilke, ki so podajale število dominantnih barv (`peaks_count_whole` 4.1.6, `peaks_count_subject` 4.1.6, `peaks_count_ratio` 4.1.6). Te značilke so se izkazale za dobre, saj imajo kar najboljše vrednosti metrike `reliefF` (2.,3. in 6. mesto v tabeli 6.5). Število dominantnih barv je po našem mnenju samo boljša implementacija značilnk, ki podajajo število barvnih odtenkov. Z analizo nomograma pri značilki `peaks_count_ratio` (4.1.6) opazimo, da obstaja pozitivna verjetnost za kvalitetno fotografijo, kadar subjekt vsebuje od 1.3 do 2.0 krat več dominantnih barvnih odtenkov kot celotna fotografija. To se sklada s teorijo, da kvalitetne fotografije uporabljajo majhno število barvnih odtenkov [10].

Dobro so se izkazale tudi značilke, ki podajajo povprečni barvni odtenek v fotografiji. Značilka, ki izračuna povprečen barvni odtenek subjekta (`hues_subj_avg` 4.1.5), ima najboljšo vrednost metrike `reliefF` v tabeli, sledita pa ji značilka, ki izračuna povprečen odtenek na celotni sliki in pa njihovo razmerje (1.,9.,13. mesto v tabeli 6.5). Iz teorije ne moremo potrditi, da povprečen odtenek igra vlogo pri estetski kvaliteti fotografije. Podobno lastnost kot že poprej povprečen odtenek opisuje tudi značilka `peaks_avg_diff` (4.1.7), ki podaja povprečni dominantni barvni odtenek, in se prav tako izkaže za ustrezno (17. mesto v tabeli 6.5).

Kot kvalitetne so se izkazale značilke, ki opisujejo povprečno nasičenosti barve. S pomočjo nomograma smo si ogledali značilko `saturation_avg_diff` (4.1.8), ki opisuje razmerje med nasičenostjo barve pri subjektu in celotni fotografiji. Ugotovili smo da imajo razmerja od 5.0 do 15 pozitiven vpliv na kvaliteto fotografije, kar bi lahko interpretirali, kvalitetne fotografije imajo

manj barvno živa ozadja, kar se sklada z lastnostmi dobre fotografije, opisane v poglavju 3.

Pozitivno so se izkazale značilke, ki opisujejo povprečno osvetljenost fotografije: `brightness_subj_avg`, `brightness_whole_avg`, `brightness_avg_diff` (4.1.9). Vplivna značilka, glede na nomogram, je `brightness_avg_diff` (4.1.9), ki opisuje razliko med povprečno osvetljenostjo med subjektom in celotno fotografijo. Iz nomograma lahko sklepamo, da prevelika razlika v osvetljenosti med subjektom in celotno fotografijo negativno vpliva na kvaliteto fotografije (pre/podosvetljenost).

Zmerno se se izkazale značilke, ki opisujejo intenziteto pikselov v fotografiji: `intensity_subj_avg`, `intensity_whole_avg`, `intensity_avg_diff` (4.1.10). Iz nomograma smo razbrali, da je večja razlika med intenziteto pikselov subjekta in celotne fotografije (`intensity_avg_diff`) negativno vpliva na kvaliteto fotografije (za razmerja večja od 8), kar sklepamo, da opisuje isti fenomen kot že prej značilka, ki je predstavljala razliko v osvetljenosti subjekta in celotne fotografije (pre/podosvetljenost).

Kot ustrezna se je izkazala tudi značilka, ki podaja kontrast med subjektom in celotno fotografijo: `contrast_subj_whole` (4.1.11).

6.5.2 Razmerja velikosti fotografije

V okviru analize razmerij velikosti fotografije smo si ogledali:

- razmerja velikosti stranic fotografije
- in relativno velikost subjekta v primerjavi s celotno sliko.

Pri analizi razmerij velikosti fotografije (4.2.1) smo si ogledali razmerje velikosti subjekta (`aspect_ratio_subj`), celotne fotografije (`aspect_ratio`) in razliko med tema vrednostima (`aspect_ratio_diff`). Nobena izmed teh značilk se ni izkazala za dobro. V nasprotju z značilkami, ki opisujejo razmerja velikosti stranic fotografije, pa se je izkazala značilka, ki opisuje relativno velikost subjekta glede na celotno fotografijo (`subj_relative_size` 4.2.2). Iz

nomograma lahko razberemo, da subjekt pri kvalitetnih fotografijah zaseda od 70 pa do 80 odstotkov celotne fotografije.

6.5.3 Kompozicija


V okviru analize kompozicije fotografije smo si ogledali:

- postavitev subjekta fotografije sledi pravilu tretjin
- za koliko je subjekt oddaljen od stranic fotografij
- analizo prostorske porazdelitve robov

V nasprotju s pričakovanji se ni izkazala značilka `min_distance_stress_point` (4.3.1), ki opisuje, kako postavitev subjekta fotografije sled pravilu tretjin. Pravilo tretjin, ki smo ga opisali v podpoglavju 3.2.1, je eno izmed najpogostejših uporabljenih pravil pri kompoziciji fotografij zato sklepamo, da naš izračun te lastnosti ni dovolj sofisticiran. Prav tako se ni izkazala značilka `edges_dist_sum` (4.3.3); njen namen je analizirati, kje se nahajajo pomembnejši elementi fotografije in nam podaja vsoto oddaljenosti izračunanih robov od središča slike. Pri postavitvi subjekta v okvir fotografije oziroma oddaljenosti subjekta od stranic okvira fotografije smo ugotovili, da je vplivna značilka, ki podaja odmik subjekta od zgornjega roba okvira fotografije (`offset_top` 4.3.2). Iz nomograma lahko razberemo, da obstaja pozitivna verjetnost za kvalitetno fotografijo na intervalu od 0.525 do 0.76, kar pomeni, da se subjekt pri kvalitetnih fotografijah nahaja v spodnji polovici fotografije. Značilke, ki podajajo odmik subjekta (4.3.2) od levega (`offset_left`), desnega (`offset_right`) in spodnjega roba (`offset_bottom`) se niso izkazale za ustrezne.

6.5.4 Primerjava rezultatov z deli drugih avtorjev

Rezultate našega dela bi lahko primerjali z rezultati dela avtorjev Ke et al [10]. Avtorji omenjenega dela so podobno kot mi za učne podatke vzeli fotografije iz fotografskega spletnega portala DPChallenge.com. Za klasifikacijo so izbrali fotografije, ki spadajo v zgornjih (in spodnjih) 10 odstotkov



Slika 6.6: Nomogram klasifikatorja Naivni Bayes za fotografije z najvišjo oceno, kjer lahko vidimo vpliv 5 najboljših značilik glede na uporabljen klasifikator.

glede na povprečno oceno fotografije. Upoštevali so samo fotografije z vsaj 100 ocenami. Na teh učnih podatkih so dosegli klasifikacijsko natančnost 72 odstotkov. Za razliko od nas niso posebej definirali subjekta fotografije. Prav tako pa bi lahko naše delo primerjali z delom Bhattacharya et al [1], kjer so avtorji dosegli klasifikacijsko natančnost 86 odstotkov pri klasifikaciji estetike fotografij v 4 razrede. Prav tako so se zanašali na definicijo subjekta s pomočjo uporabnika. Njihovo učno množico so sestavljale fotografije dveh vrst: 1. fotografije z izrazitim osprednjim objektom ter 2. fotografije pokrajine in morja, ki nimajo izrazitega osprednjega objekta.

Poglavje 7

Sklepne ugotovitve

Izbira estetsko najprivlačnejših fotografij je v današnji poplavi fotografij zamudno opravilo, zato bi si želeli opravilo avtomatizirati. V teku izdelave te diplomske naloge smo si zadali cilj identificirati lastnosti, ki določajo estetsko kvaliteto fotografije, in jih pretvoriti v značilke, ki jih je mogoče učinkovito izračunati. S pomočjo strojnega učenja smo želeli na podlagi teh značilk definirati model, ki je sposoben ločevati med estetsko privlačnimi oz. profesionalnimi fotografijam in pa nizko kvalitetnimi hipni posnetki.

V našem delu smo dali poudarek opazovanju subjekta fotografije v primerjavi s celoto. Subjekt smo identificirali ročno, in sicer s pomočjo izkušenih fotografov. Med našim delom smo definirali in implementirali 31 značilk, ki analizirajo barvno shemo, kompozicijo in pa proporce fotografije. Te značilke smo potem uporabili kot attribute za strojno učenje za kar smo uporabili metode Naivni Bayes, klasifikacijsko drevo in pa klasifikator SVM. S klasifikatorjem SVM smo dosegli klasifikacijsko natančnost 93 odstotkov. Na koncu smo opravili še analizo izračunanih značilk.

V našem delu smo dosegli pozitivne rezultate, in sicer v primeru, ko razlikujemo med visoko in nizko kvalitetnimi fotografijami. V nadaljevanju bi morali naš model preizkusiti na večjem naboru učnih podatkov, kar nam trenutno onemogoča ročno označevanje subjekta fotografije, zato bi bilo v nadaljevanju potrebno implementirati samodejno prepoznavanje subjekta fo-

tografije.

Razpoznavanje subjekta fotografije je zahtevna naloga s področja računalniškega vida, ki sega na področje interpretacije slik, zato se ga v okviru naše diplomske naloge nismo odločili implementirati. Lahko pa bi razpoznavanje subjekta reševali s pomočjo različnih hevristik. Pri portretih in pri fotografijami z ljudmi bi lahko razpoznavanje subjekta realizirali s pomočjo detekcije obrazov.

Prav tako se nam zdi smiselno fotografije razlikovati glede na njihov tip (pokrajina, portret, itd). V našem primeru smo tip fotografije določili ročno. V nadaljevanju bi bilo smiselno raziskovati lastnosti fotografij, s pomočjo katerih bi lahko samodejno razvrstili fotografije glede na njihov tip.

Literatura

- [1] Subhabrata Bhattacharya, Rahul Sukthankar, and Mubarak Shah. A framework for photo-quality assessment and enhancement based on visual aesthetics. In *Proceedings of the international conference on Multimedia*, MM '10, pages 271–280, New York, NY, USA, 2010. ACM.
- [2] Eli Billauer. Peak detection using matlab. <http://billauer.co.il/peakdet.html>.
- [3] M. Boutell and J. Luo. Bayesian fusion of camera metadata cues in semantic scene classification. In *Computer Vision and Pattern Recognition, 2004. CVPR 2004. Proceedings of the 2004 IEEE Computer Society Conference on*, volume 2, pages II–623 – II–630 Vol.2, june-2 july 2004.
- [4] Gary Bradski and Adrian Kaehler. *Learning OpenCV*. O'Reilly Media Inc., 2008.
- [5] N. Damera-Venkata, T.D. Kite, W.S. Geisler, B.L. Evans, and A.C. Bovik. Image quality assessment based on a degradation model. *Image Processing, IEEE Transactions on*, 9(4):636 –650, apr 2000.
- [6] Ritendra Datta, Dhiraj Joshi, Jia Li, and James Ze Wang. Studying aesthetics in photographic images using a computational approach. In *ECCV (3)*, pages 288–301, 2006.
- [7] Ritendra Datta, Jia Li, and James Z. Wang. Learning the consensus on visual quality for next-generation image management. In *Proceedings*

- of the 15th international conference on Multimedia, MULTIMEDIA '07*, pages 533–536, New York, NY, USA, 2007. ACM.
- [8] M. Freeman. *Fotografov pogled : kompozicija in oblikovanje za boljše digitalne fotografije / Michael Freeman ; [prevod Miha Zorec]*. Ljubljana : Tehniška založba Slovenije, 2011.
- [9] M. Freeman. *Fotografov pogled : kompozicija in oblikovanje za boljše digitalne fotografije / Michael Freeman ; [prevod Miha Zorec]*., chapter 1. Ljubljana : Tehniška založba Slovenije, 2011.
- [10] Yan Ke, Xiaoou Tang, and Feng Jing. The design of high-level features for photo quality assessment. In *Computer Vision and Pattern Recognition, 2006 IEEE Computer Society Conference on*, volume 1, pages 419 – 426, june 2006.
- [11] Noah Kuntz. Opencv tutorial 1. <http://dasl.mem.drexel.edu/noahKuntz/openCVTut1.html>.
- [12] Yiwen Luo and Xiaoou Tang. Photo and video quality evaluation: Focusing on the subject. In *Proceedings of the 10th European Conference on Computer Vision: Part III, ECCV '08*, pages 386–399, Berlin, Heidelberg, 2008. Springer-Verlag.
- [13] Sebastian Thrun, Mike Montemerlo, Hendrik Dahlkamp, David Stavens, Andrei Aron, James Diebel, Philip Fong, John Gale, Morgan Halpenny, Gabriel Hoffmann, Kenny Lau, Celia Oakley, Mark Palatucci, Vaughan Pratt, Pascal Stang, Sven Strohband, Cedric Dupont, Lars-Erik Jendrossek, Christian Koelen, Charles Markey, Carlo Rummel, Joe van Niekerk, Eric Jensen, Philippe Alessandrini, Gary Bradski, Bob Davies, Scott Ettinger, Adrian Kaehler, Ara Nefian, and Pamela Mahoney. Stanley: The robot that won the darpa grand challenge: Research articles. *J. Robot. Syst.*, 23(9):661–692, September 2006.

- [14] Laboratorij za bioinformatiko. Orange – data mining fruitful & fun.
<http://orange.biolab.si>.