

UNIVERZA V LJUBLJANI  
FAKULTETA ZA RAČUNALNIŠTVO IN INFORMATIKO

Katja Rus

## **Zaznava nasmeha**

DIPLOMSKO DELO

VISOKOŠOLSKI STROKOVNI ŠTUDIJSKI PROGRAM PRVE  
STOPNJE RAČUNALNIŠTVO IN INFORMATIKA

Ljubljana 2012

UNIVERZA V LJUBLJANI  
FAKULTETA ZA RAČUNALNIŠTVO IN INFORMATIKO

Katja Rus

## **Zaznava nasmeha**

DIPLOMSKO DELO

VISOKOŠOLSKI STROKOVNI ŠTUDIJSKI PROGRAM PRVE  
STOPNJE RAČUNALNIŠTVO IN INFORMATIKA

MENTOR: viš. pred. dr. Borut Batagelj

Ljubljana 2012



Št. naloge: 00155/2011

Datum: 05.09.2011

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

Kandidat: **KATJA RUS**

Naslov: **ZAZNAVA NASMEHA**  
**SMILE DETECTION**

Vrsta naloge: Diplomsko delo visokošolskega strokovnega študija prve stopnje

Tematika naloge:

Kandidat naj v okviru svoje naloge pregleda področje računalniškega vida, ki na sliki zazna obraz in na njem nasmeh. Na podlagi pregleda različnih metod računalniškega vida in strojnega učenja naj predlaga katere metode so najuspešnejše pri zaznavi nasmeha. Potek zaznave nasmeha naj predstavi na preprostem programu, ki ga preizkusi na javno dostopni podatkovni bazi obrazov. Na koncu naj na podlagi uspešnosti poda zaključne ugotovitve.

Mentor:

  
viš. pred. dr. Borut Batagelj

Dekan:

  
prof. dr. Nikolaj Zimic



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

*Besedilo je oblikovano z urejevalnikom besedil  $\text{\LaTeX}$ .*

## IZJAVA O AVTORSTVU DIPLOMSKEGA DELA

Spodaj podpisana Katja Rus, z vpisno številko **63060282**, sem avtorica diplomskega dela z naslovom:

*Zaznava nasmeha*

S svojim podpisom zagotavljam, da:

- sem diplomsko delo izdelala samostojno pod mentorstvom viš. pred. dr. Boruta Batagelja,
- 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 15. marca 2012

Podpis avtorice:

*Rada bi se zahvalila staršem, ki so me tekom študija brezpogojno podpirali, tako finančno, kot tudi moralno. Posebna zahvala mentorju viš. pred. dr. Borutu Batagelju, za pomoč pri izdelavi diplomske naloge. Hvala tudi Janu in Tomažu.*

# Kazalo

Slovar uporabljenih kratic in simbolov

Povzetek

Abstract

<b>1</b>	<b>Uvod</b>	<b>1</b>
<b>2</b>	<b>Podatkovne baze obrazov</b>	<b>5</b>
2.1	Podatkovna baza Cohn-Kanade . . . . .	6
2.2	Podatkovna baza GENKI . . . . .	7
2.3	Podatkovna baza YALE . . . . .	8
<b>3</b>	<b>Registracija slik in izločanje značilnic</b>	<b>9</b>
3.1	Registracija slik . . . . .	9
3.2	Izločanje značilnic . . . . .	10
<b>4</b>	<b>Metode strojnega učenja</b>	<b>13</b>
4.1	Metoda podpornih vektorjev . . . . .	13
4.2	Naivni Bayesov klasifikator . . . . .	14
4.3	Uporaba nevronske mreže . . . . .	14
4.4	GentleBoost . . . . .	14
<b>5</b>	<b>Primeri razvoja različnih sistemov za zaznavanje nasmehov</b>	<b>15</b>

## KAZALO

5.1	Sistem za zaznavanje nasmehov z uporabo metod GentleBoost in SVM . . . . .	15
5.2	Sistem za zaznavanje nasmehov z uporabo nevronske mreže, algoritma J48 in naivnega Bayesovega klasifikatorja . . . . .	19
5.3	Primerjava uspešnosti sistemov za zaznavanje nasmehov . . . . .	23
<b>6</b>	<b>Primer preprostega računalniškega programa za zaznavo na-</b> <b>smechov</b>	<b>25</b>
6.1	Orodje za strojno zaznavanje . . . . .	25
6.2	Predstavitev delovanja programa . . . . .	26
6.3	Postopek zaznave nasmeha, ki je uporabljen v programu . . . . .	28
6.4	Rezultati . . . . .	29
<b>7</b>	<b>Zaključek</b>	<b>31</b>

# Slike

1.1	Nekatere izmed glavnih obraznih mišic. Primarna funkcija večine teh mišic je komuniciranje. . . . .	2
1.2	Prikaz delovanja metode Gaussovih mehurčkov. . . . .	2
1.3	Primer obraznega izraza in določitev enot premika s pomočjo sistema za kodiranje obraznih izrazov. . . . .	3
1.4	Digram poteka sistema za zaznavanje nasmehov. . . . .	4
2.1	Primer slik iz podatkovne baze Cohn-Kanade. . . . .	6
2.2	Primer slik iz podatkovne baze GENKI. . . . .	7
2.3	Primer slik iz YALE podatkovne baze. . . . .	8
5.1	Šest tipov pravokotnih škatličnih filtrov in število izbranih lastnosti z metodo GentleBoost in uporabo registracije slike. . .	17
5.2	Prikaz uporabe zaznavalca nasmehov pri projektu RUBI, s pomočjo robota ASOBO. . . . .	18
5.3	Zaznava obrazov s pomočjo tehnik za digitalno obdelavo slik. .	21

*SLIKE*

# Tabele

5.1	Testiranje zaznavalcev obrazov na 1000 naključnih slikah iz GENKI podatkovne baze . . . . .	16
5.2	Uspešnost sistemov za zaznavanje nasmehov . . . . .	23
6.1	Primerjava prepoznanih slik z nasmehi in slik, kjer se nasmeh ni zgodil iz podmnožice GENKI-4K z rezultati, pridobljenimi s pomočjo programa . . . . .	29
6.2	Število uspešno in neuspešno prepoznanih nasmehov v obeh podmnožicah podatkovne baze GENKI-4K . . . . .	30



# Slovar uporabljenih kratic in simbolov

Seznam uporabljenih kratic in simbolov, ki morajo biti enotni v celotnem delu, ne glede na označevanje v uporabljenih virih.

**AU** (ang.) Action Units; Enota premikov.

**FACS** (ang.) Facial Action Coding System; Sistem za kodiranje obraznih gibov.

**SVM** (ang.) Support Vector Machine; Metoda podpornih vektorjev.

**GEF** (ang.) Gabor Energy Filter; Gaborjev energijski filter.

**BF** (ang.) Box filter; Škatlični filter.

**EOH** (ang.) Edge orientation histograms; Histogrami za orientacijo robov.

**MPT** (ang.) Machine Perception Toolbox; Orodje za strojno zaznavanje.



# Povzetek

Mimika obraza je najmočnejše in neposredno sredstvo za posredovanje čustev, kognitivnega stanja, namena in mnenja med ljudmi. Glede na njeno pomembnost je razumno pričakovati, da ima razvoj orodij, ki zaznavajo obrazne izraze, velik učinek na vsakodnevno življenje. Razvijalci so v zadnjih letih na tem področju dosegli velik napredek pri razvoju klasifikatorjev, ki so potrebni za to vrsto zaznavanja, vendar se še vedno pojavlja velika razlika med stanjem v realnih okoliščinah in poskusih v laboratorijih.

V diplomskem delu se bomo osredotočili na raziskavo že razvitih algoritmov za zaznavanje nasmehov, za kar je predhodno potrebna zaznava obrazov. Predstavili bomo različne pristope, metode strojnega učenja in podatkovne baze, ki se uporabljajo, in razložili potek razvoja dveh sistemov, ki sta se pokazala za najbolj natančna.

V zaključku diplomskega dela bomo predstavili delovanje zaznavalca nasmehov na preprostem računalniškem programu.

Ključne besede: mimika obraza, zaznava, podatkovna baza, metode strojnega učenja.



# Abstract

Facial expressions are one of the most powerful and indirect means of transferring feelings, cognitive status, ulterior motive and opinion among people. Considering their significance it is reasonable to expect that the development of tools recognizing facial expressions would have a big effect on everyday life. In the past years, the developers have made big progress on the development of classifiers that are needed for this kind of expression detection; however there is still a great gap between real life situations and laboratory experiments.

This thesis is focused on researching the existing algorithms of smile detection, for which face detection must be executed beforehand. Various approaches, methods and databases that are being used will be presented and the development of two systems, proved to be most efficient, will be explained.

In conclusion the functioning of smile detection on a simple computer program will be presented.

Key words: facial expressions, recognition, database, machine learning algorithms.

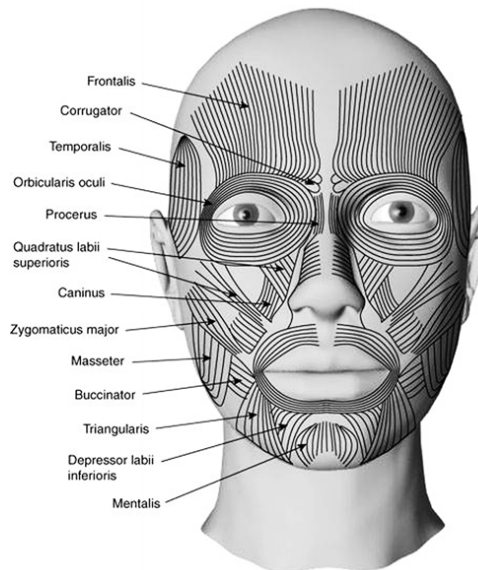


# Poglavje 1


## Uvod

Obrazni izrazi so najmočnejše orodje, s katerim ljudje izražamo čustva. Že s samim opazovanjem človeka lahko s pomočjo izrazov na obrazu ugotovimo njegovo počutje in razpoloženje. S pomočjo raziskav psihofizikov na področju človeškega zaznavnega sistema so znanstveniki razvili vrsto metod, ki omogočajo zaznavo obraznih izrazov na slikah.

Ker je sistem za prepoznavanje obraznih izrazov precej kompleksen, se bomo osredotočili na preprosto zaznavanje nasmeha. Nasmeh je najpogostejši obrazni izraz v vsakodnevnem življenju. Pogosto se kaže pri sreči, spoštovanju ali zadovoljstvu ljudi. Slika 1.1 prikazuje, da obraz v osnovi oblikuje sedem parov obraznih mišic in sicer par velikih ličničnih mišic, malih ličničnih mišic, smejalnih mišic, trobilk, dvigalk zgornje ustnice, dvigalk ustnega kota in krožnih ustničnih mišic. Kombinacija mišic lahko izoblikuje veliko različnih nasmehov. Prototipni nasmeh, ki ga znanstveniki uporabljajo pri razvijanju metod za zaznavanje nasmehov, izoblikuje le par velikih ličničnih mišic (lat. *Zygomaticus major*), zaradi česar takšnemu nasmehu rečemo tudi ličnični nasmeh. Zaznavanje obraznih izrazov je problematično celo pri ljudeh, saj včasih ne znamo preceniti ali so izrazi pristni ali ne. Znanstveniki so si pri razvoju sistemov za zaznavanje nasmehov tako pomagali s psihofizičnimi raziskavami, ki so razvili različne metode za analizo človeškega zaznavalnega sistema.

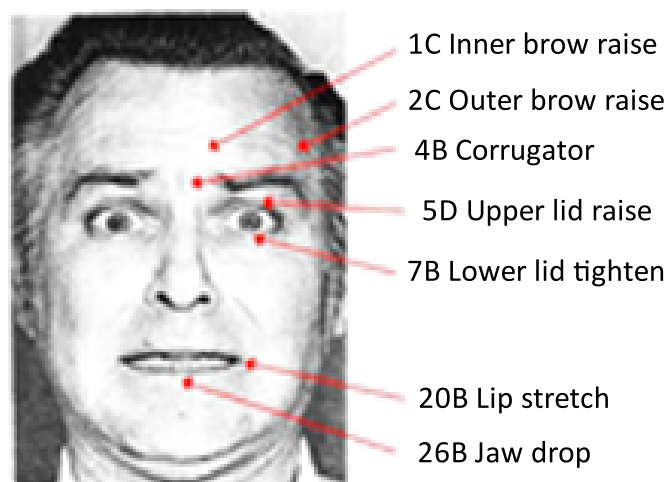


Slika 1.1: Nekatere izmed glavnih obraznih mišic. Primarna funkcija večine teh mišic je komuniciranje.



Slika 1.2: Prikaz delovanja metode Gaussovih mehurčkov.

Slika 1.2 prikazuje Gaussove mehurčke (ang. Gaussian Bubbles), metodo, ki je bila prvotno razvita za določevanje delov obraza, ki so bistveni, ko ljudje ocenjujemo spol, identiteto in obrazne izraze [2].




Slika 1.3: Primer obraznega izraza in določitev enot premika s pomočjo sistema za kodiranje obraznih izrazov.

Za boljše razumevanje delovanja človeškega zaznavnega sistema je potrebno omeniti tudi sistem za kodiranje obraznih gibov (FACS), ki sta ga razvila Ekman in Friesen [3]. Gre za kompleksno metodo, namenjeno kodiranju obraznih izrazov. FACS razvijalci so razbili obrazne izraze glede na intenzivnost posameznega izraza na 46 gibov, ki približno določajo posamezno obrazno mišico. Slika 1.3 prikazuje te elementarne gibe, ki jih poimenujejo enote premika (AU).

Slika 1.4 prikazuje diagram poteka za uspešen razvoj sistema za zaznavanje nasmehov na področju računalniškega vida, ki je uporaben v nekontroliranih, vsakodnevnih situacijah. Za razvoj takšnega sistema je potrebno točno definirati vse potrebne parametre:

- velikost in tip podatkovne baze;
- registracija slik;
- izločanje značilnic;
- metode strojnega učenja.



Slika 1.4: Digram poteka sistema za zaznavanje nasmehov.

V nadaljevanju bomo predstavili podatkovne baze obrazov, povzeli kako poteka sama registracija slik, predstavili filtre, ki so namenjeni izločanju značilnic, in metode strojnega učenja z največjo uspešnostjo. Razložili bomo razvoj dveh sistemov za zaznavanje nasmehov, na koncu pa prikazali delovanje preprostega računalniškega programa za zaznavanje nasmehov. V zaključku bomo združili ugotovitve ter izpostavili prisotnost aplikacij za zaznavanje nasmehov na trgu.

# Poglavje 2

## Podatkovne baze obrazov

Pri razvoju algoritmov je priporočena uporaba standardnih podatkovnih baz za lažjo primerjavo rezultatov. Znanstveniki so naredili vrsto podatkovnih baz, izmed katerih so nekatere tudi prosto dostopne, vendar je izbira primerne odvisna od posameznega problema, ki ga rešujemo. Obstaja tudi več podatkovnih baz obraznih izrazov, na katerih so testirali zaznavanje nasmehov. V osnovi gre za podatkovne baze, ki so namenjene iskanju obrazov na slikah, razlikujejo pa se predvsem po tem ali so pridobljene v kontroliranih okoliščinah v laboratorijih ali so pridobljene z interneta.

Pomembno je, da so podatkovne baze dovolj velike, in da zajemajo vrsto slikovnih pogojev. Velike morajo biti od 1000 do 10000 slik za določen obrazni izraz in zajemati različne osebne lastnosti človeka, kot na primer etničnost, starost, spol, prisotnost obraznih dlak in prisotnost očal. Slike, pridobljene z interneta, sicer zajemajo širok razpon slikovnih pogojev, vendar vsebujejo veliko variacij obraznih izrazov, kar predstavlja slabost.

Za namene testiranja je tako najbolj primerna kombinacija podatkovne baze, pridobljene v laboratoriju, in podatkovne baze, v kateri so zbrane slike, pridobljene z interneta. Na tak način lahko razvijemo sistem, ki ni občutljiv na širok razpon slikovnih pogojev in variacijo obraznih izrazov.



Slika 2.1: Primer slik iz podatkovne baze Cohn-Kanade.

## 2.1 Podatkovna baza Cohn-Kanade

Cohn-Kanade podatkovna baza obraznih izrazov je najbolj primerna podatkovna baza za namene testiranja na področju avtomatske analize obraznih slik. Slikovni podatki podatkovne baze so sestavljeni iz približno 500 slikovnih sekvenc 100 ljudi. Označeni so z enotami premikov in specifičnimi obraznimi izrazi. Osebe na slikah v podatkovni bazi so stare od 18 do 30 let in imajo različne barve kože. Slike so bile posnete v kontroliranih okoliščinah v laboratoriju in sicer z dvema kamerama, priključenima na video snemalnik. Ena izmed kamer je bila postavljena točno pred človeka, druga pa 30 stopinj desno od njega. Ljudem so bila podana navodila in razlaga celotnega postopka. Slika 2.1 prikazuje primer posnetih slik. Najprej so posneli slike nevtralnih izrazov, nato pa so morali ljudje izraziti 6 različnih čustev in sicer veselje, presenečenje, jezo, strah, gnus in žalost. Slike so velike 640x480 ali 640x490 pikslov. Podatkovna baza Cohn-Kanade je dostopna na internetu [4], vendar samo za raziskovalne namene. Uporaba v komercialne namene je prepovedana.



Slika 2.2: Primer slik iz podatkovne baze GENKI.

## 2.2 Podatkovna baza GENKI

GENKI podatkovna baza, ki so jo naredili v laboratoriju za strojno zaznavanje MPLab, se konstantno dopolnjuje. Slika 2.2 prikazuje slike, ki so različno osvetljene, z različnih geografskih območij in zajemajo različne osebne lastnosti ter etničnost ljudi.

Podatkovna baza GENKI-R2009a je razdeljena na dve podmnožici slik, ki imata vsaka svoje oznake. Vsaka izmed slik ima unikatno ime. Podatkovna baza je prosto dostopna na internetu [5] in na voljo za uporabo.

### 2.2.1 GENKI-4K

GENKI-4K je podmnožica podatkovne baze GENKI. Vsebuje 4000 obraznih slik, ki so jih označili z z oznakama ali se obraz na sliki smeji ali ne. Vse slike so s svojim avtomatskim zaznavalcem obrazov določili za približno frontalne.

### 2.2.2 GENKI-SZSL

GENKI-SZSL podmnožica podatkovne baze GENKI je sestavljena iz 3500 slik, ki vsebujejo obraze. Slike so označene z lokacijo obraza in njegovo velikostjo.



Slika 2.3: Primer slik iz YALE podatkovne baze.

## 2.3 Podatkovna baza YALE

YALE podatkovna baza vsebuje 165 sivinskih slik 15 posameznikov. Zbrali so jo tako, da so posneli 11 slik vsakega posameznika in sicer za vsak obrazni izraz posebej. Slika 2.3 prikazuje slike, ki so omejene z določenimi lastnostmi. Posneli so posnetke pri različni osvetlitvi in sicer pri osvetlitvi z leve, desne in s sredinsko osvetlitvjo, posnetke, kjer posameznik nosi očala in kjer jih ne, na katerih je posameznik vesel, žalosten, zaspan in presenečen ter na katerih posameznik mežika z očmi. Podatkovna baza je prosto dostopna na internetu [6], vendar ne za komercialne namene.

## Poglavje 3

# Registracija slik in izločanje značilnic

### 3.1 Registracija slik

Registracija slik je proces preoblikovanja različnih sklopov podatkov. Uporablja se na področju računalniškega vida, poleg tega pa je uporabna tudi za prepoznavanje tarč v vojaške namene in pri pretvarjanju ter analiziranju slik in podatkov iz satelitov.

Postopek registracije slike je namenjen rotaciji, obrezovanju in skaliranju slike. Zagotoviti je potrebno, da so vse slike v podatkovni bazi enako urejene. Postopek registracije slik je potrebno izvesti najprej na testnih slikah, potem pa prav tako na vseh slikah ki vstopajo v sistem za zaznavanje. Slike so lahko različno velike in napačno obrnjene, obrazi na njih pa imajo lahko različen naklon. Za uspešno delovanje sistema je potrebno vse slike ustrezno obrniti, pomanjšati in obrezati, da so vse slike enake. Z obrezovanjem slik odstranimo nepomembne in moteče dele slike in hkrati zmanjšamo informacijo, ki jo mora sistem obdelati, kar pomeni, da povečamo hitrost delovanja sistema.

Eno izmed glavnih vprašanj pri razvoju sistema za zaznavanje nasmehov je, kako pomembna je natančna registracija slike, ki temelji na primer na položaju oči. V preteklih raziskavah [7] pri uporabi standardne podatkovne

baze poročajo, da natančnost registracije določene obrazne značilnosti ni vplivala na zmogljivost prepoznavanja obraznih izrazov. Raziskovalci [1] so v zadnjih raziskavah ugotovili, da pri uporabi podatkovnih baz, ki vsebujejo realne slike, kot na primer GENKI podatkovna baza, natančna registracija oči pri sistemih za zaznavanje nasmehov igra pomembno vlogo. V laboratoriju za strojno učenje MPLab so razvili eno izmed najbolj učinkovitih metod za iskanje oči na slikah. Vendar je potrebno poudariti, da je avtomatsko iskanje oči z uporabo metode še vedno precej manj natančno kot človeško označevanje. Izguba pri avtomatskem iskanju oči je pokazala slabše delovanje in zmogljivost sistemov za zaznavanje nasmehov [1].

## **3.2 Izločanje značilnic**

Filtri za izločanje značilnic so namenjeni prepoznavanju točno določenih delov obraza. Vsak zase je namenjen reševanju različnih problemov.

### **3.2.1 Gaborjev energijski filter**

Gaborjev energijski filter predstavlja kompleksne celice vidne možganske skorje pri primatih. Vsak izmed energijskih filtrov je sestavljen iz dveh povezanih linearnih filtrov, ki jih imenujemo realni in imaginarni del filtra. Impulzni odziv teh dveh filtrov je prikazan kot 2-dimenzionalna sinusoida, modelirana z Gaussovo ovojnico [8]. Gaborjev energijski filter je največkrat uporabljen filter v aplikacijah za procesiranje obrazov, ki vključujejo zaznavanje obraza in obraznih izrazov.

### **3.2.2 Škatlični filtri**

Škatlični filtri (ang. Box Filters) so zaradi svoje oblike vhodni uporabni za aplikacije, ki so narejene za digitalne računalnike. Uporabljajo jih pri procesiranju signalov in niso tako prisotni na področju računalniške grafike. Na področju računalniškega vida jih povezujejo s filtri avtorjev Viola in Jones

in značkami, ki so podobne Haarovim valčkom [9].

### 3.2.3 Histogrami orientacije robov

Gre za histograme, ki so precej prisotni že v preteklih raziskavah računalniškega vida in so v zadnjem času zelo popularni pri nalogah, ki vključujejo objektno prepoznavanje in zaznavanje obrazov. So bolj tolerantni pri raznolikosti slik in zagotovljajo bistveno boljšo generalno predstavitev kot škatlični filtri, v primeru, da so podatkovne baze majhne [1].



# Poglavje 4

## Metode strojnega učenja

Strojno učenje je področje umetne inteligence, ki se ukvarja z razvojem metod, ki so namenjene učenju računalnikov oziroma strojev. Ima širok spekter uporabnosti, saj se uporablja pri vsakodnevnih nalogah, kot je na primer brskanje po internetu, zaznavi ponarejenih dokumentov, prepoznavanju objektov pri strojnem vidu, pri robotih in računalniških igrah. Metode strojnega učenja so zasnovane tako, da jim podamo neke vrednosti in jih naučimo prepoznavanja določenega vzorca. Ko jih testiramo na novih primerih, imajo način prepoznavanja vzorca že naučen.

Sistemi strojnega učenja se zelo razlikujejo, v osnovi pa metode strojnega učenja delimo na več vrst, glede na to kaj je njihov cilj.

### 4.1 Metoda podpornih vektorjev

Metoda podpornih vektorjev (SVM) predstavlja niz povezanih nadzorovanih metod strojnega učenja, namenjenih za analiziranje podatkov in prepoznavanje vzorcev. Cilj metode je zmanjšati zgornjo mejo pričakovane napake posplošitve [10].

## 4.2 Naivni Bayesov klasifikator

Naivni Bayesov klasifikator predpostavlja neodvisnost vhodnih vzorcev. Dobro določi porazdelitveno funkcijo [10].

## 4.3 Uporaba nevronske mreže

Nevronske mreže se uporabljajo pri problemih prepoznavanja vzorcev. Pri iskanju obrazov na slikah delimo prepoznavanje vzorcev na dva razreda in sicer iskanje slik, ki ne vsebujejo obrazov, in iskanje slik z vsebovanostjo obraza. Prednost uporabe nevronskih mrež pri učenju zaznave obraza je sposobnost mreže, da se lahko nauči kompleksnosti vzorca. Za uspešno učenje nevronske mreže jo je potrebno predhodno razgraditi in določiti pravo število nivojev in število nevronov na vsakem nivoju [10].

## 4.4 GentleBoost

GentleBoost je povečevalni algoritem strojnega učenja, ki minimizira kvadratno napako med oznakami in predstavlja napoved. Pri večini takih algoritmov se testiranje izvaja v zaporednem načinu, začne pa se s preprostim klasifikatorjem in hitrim dodajanjem novih komponent obstoječemu klasifikatorju [1].

## Poglavje 5

# Primeri razvoja različnih sistemov za zaznavanje nasmehov

### 5.1 Sistem za zaznavanje nasmehov z uporabo metod GentleBoost in SVM

J. Whitehill, G. Littlewort, I. Fasel, M. Bartlett in J. Movellan, člani laboratorija za mehansko zaznavanje, so razvili sistem za zaznavanje nasmehov na slikah, ki je uporaben v nekontroliranih, vsakodnevnih okoliščinah [1]. Predvideli so, da je za uspešen razvoj takšnega sistema potrebna natančna določitev določenih parametrov in se osredotočili na dve vrsti ciljnih aplikacij:

- SPROŽILEC NASMEHA - aplikacija, namenjena za digitalne kamere. Avtomatski sprožilec posname sliko, ko se oseba nasmeji;
- ROBOT - prepozna človeški nasmeh v vsakodnevnih situacijah.

Njihov sistem so testirali pod različnimi pogoji in upošteva spremembo osvetlitve, geografsko lokacijo, etničnost, spol in starost.

	Fasel et al	OpenCV
uspešnost	82.7%	81.6%
št. napak	75	53

Tabela 5.1: Testiranje zaznavalcev obrazov na 1000 naključnih slikah iz GENKI podatkovne baze

Za začetek so predvideli, da so njihove testne osebe gledale direktno v kamero z rotacijo obraza, maksimalno 5 do 10 stopinj.

Sistem za zaznavanje nasmehov deluje tako, da naprej locira obraz in oči. Slika se potem zakodira kot vektor z realnimi številkami, ki so vidne kot skupek filtrov. Izhodi so integrirani s klasifikatorjem v eno realno številko, na podlagi katere potem določijo ali se oseba na sliki smeji ali ne.

### 5.1.1 Podatkovna baza


Za učenje so uporabili GENKI podatkovno bazo, v kateri so vse slike označene z oznakami, ali se obraz na sliki smeji ali ne.

### 5.1.2 Zaznavanje obrazov

Za zaznavanje obrazov na slikah so uporabili združena sistema za zaznavo oči in obrazov in sicer zaznavalec avtorjev Fasel et al [11]. Tabela 5.1 prikazuje primerjavo uspešnosti zaznavalca obrazov iz odprtokodne knjižnice OpenCV in zaznavalca obrazov avtorjev Fasel et al, ki je dosegel boljše rezultate.

### 5.1.3 Registracija slik

Postopek registracije slik so izvedli tako, da so najprej vse slike pretvorili v vrednosti sivinske lestvice, potem pa so jih normalizirali z rotacijo, obrezovanjem in skaliranjem okoli oči, tako da so dosegli obraz velikosti 24 pikslov. Primerjali so zmogljivost zaznavalca v primeru avtomatske zaznave oči in ročnega določanja položaja oči in ugotovili, da je registracija oči zelo



Slika 5.1: Šest tipov pravokotnih škatličnih filtrov in število izbranih lastnosti z metodo GentleBoost in uporabo registracije slike.

pomembna. Nenatančna registracija slik je bila eden izmed glavnih razlogov slabih rezultatov.

#### 5.1.4 Izločanje značilnic

Primerjali so delovanje treh najpogosteje uporabljenih filtrov za izločanje značilnic ter kombinacijo histogramov za orientacijo robov in škatličnih filtrov.

- Gaborjev energijski filter - uporabili so celoto 40 Gaborjevih energijskih filtrov, ki so sestavljeni iz 8 orientacij in 5 prostorskih frekvenc. Filter se je izkazal za izredno diskriminatornega.
- Škatlični filter - v implementacijo so vključili 6 tipov škatličnih filtrov, ki vključujejo 2, 3 in 4 pravokotna orodja navpične orientacije, sorodne tistim, ki so uporabljene pri filtru avtorjev Viola in Jones in dodatni dve orodji, ki sta pravokotni in prostorsko centrirani.
- Histogrami orientacije robov - uporabili so dve vrsti histogramov za orientacijo robov in sicer dominantnega in simetričnega.
- Histogrami za orientacijo robov + škatlični filtri.



Slika 5.2: Prikaz uporabe zaznavalca nasmehov pri projektu RUBI, s pomočjo robota ASOBO.

### **5.1.5 Metode strojnega učenja**

Primerjali so delovanje dveh metod strojnega učenja, ki sta na področju zaznave obraznih izrazov v preteklih raziskavah dosegli najboljši uspeh. Slika 5.1 prikazuje uporabo GentleBoost metode, ki je ena izmed dveh, ki so jo testirali.

- Gentleboost - vsi GentleBoost klasifikatorji so bili učeni s pomočjo 500 zaporednih ponovitev;
- SVM - pri učenju SVM metode, so uporabili vse Gaborjeve energijske filtre in škatlične filtre.

### **5.1.6 Rezultati**

Zaznavalec nasmehov testiran z GentleBoost metodo strojnega učenja in z uporabo kombinacije škatličnih filtrov in histogramov za orientacijo robov, se je izkazal za najbolj zanesljivega in uporabnega za uporabo v praktičnih aplikacijah. Pred začetkom raziskave so se osredotočili na dve vrsti ciljnih aplikacij, na katerih so na koncu testirali svoj zaznavalec nasmehov. Ta je pri aplikaciji, ki so jo poimenovali Sprožilec nasmeha, dosegel 96.18% uspešnost,

kar pomeni, da je za uporabo v digitalnih kamerah zelo primeren. Za testiranje druge vrste ciljne aplikacije, in sicer robotskega zaznavanja nasmehov, so uporabili projekt RUBI, katerega cilj je naučiti robote pomagati učiteljem pri učenju otrok. Slika 5.2 prikazuje robota Asobo, ki so ga naredili za namen testiranja zaznave nasmehov otrok. Zaznavalec nasmehov se je izkazal za manj uspešnega, saj je bila podatkovna baza slik precej drugačna od GENKI baze, na kateri so testirali zaznavanje nasmehov. Slike, ki so jih pridobili s pomočjo robota Asobo so vključevale samo obraze otrok, pri katerih se je pojavil manjši odstotek zob, prav tako pa je bilo veliko napak zaradi igrač, ki jih je robot zaznal kot človeške obraze.

## **5.2 Sistem za zaznavanje nasmehov z uporabo nevronske mreže, algoritima J48 in naivnega Bayesovega klasifikatorja**

Sistem za zaznavanje nasmehov s pomočjo kombinacije metod za analizo slik in nevronske mreže so razvili avtorji E. C. L. Choi, G. Peaker in P. Wong [12]. Odločili so se, da bodo razvili svoj algoritem, pri čemer so uporabili kombinacijo najmočnejših točk pri že obstoječih metodah.

Razvoja sistema so se lotili tako, da so uporabili tri znane metode strojnega učenja in sicer J48 algoritem, naivni Bayesov klasifikator in metodo strojnega učenja s pomočjo nevronske mreže za prepoznavanje nasmehov. Tehnike za slikovno analizo so uporabili za določitev obrazov na slikah, nato pa še za določitev ali se je nasmeh na sliki zgodil ali ne. Rezultati so pokazali, da je zaznava nasmehov s takšno tehnologijo možna in primerna za uporabo v praktičnih aplikacijah.

### **5.2.1 Zaznava obrazov s pomočjo tehnik za digitalno obdelavo slik**


Najprej so se lotili zaznave obrazov na danih slikah. Za potrebe razvoja svojega sistema za zaznavo obrazov so uporabili kombinacijo že poznanih algoritmov. Nov algoritem za zaznavo obrazov opredelijo kot serijo zavrnitvenih blokov, pri čemer je slika obdelana z vrsto različnih skript in nato poslana v obdelavo z zadnjo skripto za zaznavo obrazov. Slika 5.3 prikazuje uporabo tehnik za digitalno obdelavo slik, ki so opisane v nadaljevanju.

#### **Barvna segmentacija**

Najprej so določili barvno segmentacijo kože na sliki. Pri tem so uporabili že znan algoritem in sicer histogram za barvno segmentacijo. Pri izvajanju programa so uporabili 5 različnih barv kože, kar jim je omogočilo vključitev slik obrazov ljudi različnih ras. Zbrali so testne slike in jih pretvorili v HSV barvni prostor, ki je za segmentacijo barv kože primernejši od RGB barvnega prostora. Iz testnih slik so nato naredili histogram in uporabili najbolj pogosto zaznane vrednosti ter jih označili kot barve kože, ki so jih uporabili v nadaljni raziskavi. Na vsaki sliki so tako poiskali prej omenjene vrednosti in izločili piksele, ki so te vrednosti vsebovali. Ostale piksele so enostavno nastavili na 0. Končni rezultat so bile slike, ki so vsebovale le tiste piksele, za katere so predvideli, da predstavljajo človeško kožo.

#### **Morfološka transformacija in filter velikosti**

Slike, ki so jih predhodno obdelali z metodo barvne segmentacije, še vedno niso bile jasne zaradi raztresenosti pikslov in možnosti prekrivanja pikslov drugih objektov. Poleg tega so na določenih delih obraza lahko določeni piksli manjkali zaradi prenatane barvne segmentacije, ki jih je odstranila, kljub temu da so piksli predstavljali kožo.



Slika 5.3: Zaznava obrazov s pomočjo tehnik za digitalno obdelavo slik.

### Zaznava obrazov s pomočjo nevronske mreže

Želeli so dobiti jasno sliko, ki bi bila lahko obdelana z algoritmom za zaznavo obrazov s pomočjo nevronske mreže. S tem namenom so uporabili kombinacijo operacij za zapolnitev praznega prostora na sliki in odstranitev nejasnosti. Kljub temu operacije niso odstranile večjih objektov, za katere so predvideli, da niso obrazi. Zato so uporabili filter velikosti, s pomočjo katerega so izločili prevelike objekte od povprečne velikosti obraza na sliki, ki so jo predhodno izračunali. Določili so, da je razmerje obraza na slikah enako 10:16, na podlagi katerega so izločili objekte, ki so odstopali od povprečne vrednosti.

Pri testiranju so naleteli na več problemov. Osnovni problem je bilo prekrivanje obrazov, kar so rešili s pomočjo odstranitve določenih območji. Prav tako je problem predstavljalo testiranje nevronske mreže z negativnimi primeri. Da bi rešili to vrsto problema, so algoritem najprej testirali na slikah, ki niso vsebovale obrazov, in dodali takšne primere slik v testno podatkovno bazo. Nato so postopek ponovili, da je sistem v nadaljnjem samostojno prepoznal negativne primere slik. Zadnji problem, na katerega so naleteli je bila nekonsistentnost osvetlitve, saj so bili nekateri deli obraza prepoznani kot pretemni. Ta problem so rešili s histogramom normalizacije.

Ugotovili so, da metoda zazna obraze na slikah z 82% uspešnostjo. Na nekaterih slikah je bil obraz napačno prepoznani zaradi objektov s podobno barvo kot je barva kože. Na nekaterih slikah obraz ni bil zaznan zaradi premajhne velikosti, ki so jo predhodno določili. A kljub vsemu so bili rezultati

dovolj dobri, da so metodo lahko uporabili za nadaljno zaznavo nasmehov.

### **5.2.2 Zaznava nasmehov z uporabo metod strojnega učenja**

Zaznavalec obrazov so razširili tako, da so dodali komponento zaznave nasmeha. Pri razvoju algoritma za zaznavo nasmeha so uporabili že znane metode strojnega učenja.

Razvoj sistema za zaznavanje nasmeha so razvijali ločeno od zaznavanja obrazov na slikah. Uporabili so zbirko 134 slik, ki so jih pridobili na internetu, med katerimi jih je nekaj vsebovalo nasmeh, preostale slike pa so definirali kot slike brez nasmehov. Zbirko slik so razdelili v dve skupini in sicer so 46 slik uporabili za namene učenja in 88 slik kot testne slike. Vsak obraz na sliki je bil velik vsaj 250x350 pikslov, da so lahko na njem prepoznali obrazne lastnosti. Prepoznali so 10 lastnosti obraza, ki določajo človeški nasmeh in z uporabo algoritmov za obdelavo slik izračunali njihove vrednosti. Določili so lastnosti, ki predstavljajo attribute za testiranje:

- Odstotek zob v ustih na sliki;
- normalizirana os, ki predstavlja premer med očmi;
- višina in širina nosu;
- lok zgornje in spodnje ustnice;
- ali se pri nasmehu na licih pojavi črta;
- ali so na obrazu prisotne čelne gube;
- vodoravna razdalja med obrvema.

Podatke, ki so jih zbrali so preučili in testirali s tremi različnimi klasifikatorji in sicer s pomočjo nevronskih mrež, naivnega Bayesovega klasifikatorja in J48 algoritma.

	GentleBoost+SVM	Naivni Bayesov klasifikator
uspešnost	82.7%	87.5%

Tabela 5.2: Uspešnost sistemov za zaznavanje nasmehov

Za ugotavljanje odstotka zob na sliki so uporabili algoritem, ki so ga predhodno uporabili za zaznavo obrazov in ga prilagodili tako, da se je naučil poiskati druge barve. Izračun ukrivljenosti loka spodnje in zgornje ustnice so naredili s pomočjo algoritma za zaznavanje mej, s pomočjo katerega so lahko hkrati izračunali ali so na obrazu prisotne gube oziroma če se med nasmehom na obrazu pojavijo dodatne črte.

Metoda za prepoznavanje obrazov jim je prav tako pomagala pri iskanju oči in nosu na obrazu. Z njo so izračunali velikost posameznih delov obraza.

### 5.2.3 Rezultati in analiza

Ko so zbrali vse potrebne informacije iz vseh slik, so za namen analize podatkov uporabili program Weka. Gre za odprtokodni program, ki vsebuje klasifikatorje strojnega učenja. Rezultati so pokazali, da je najbolj natančen naivni Bayesov klasifikator, saj je v 87.5% pravilno zaznal nasmeh. Na drugo mesto se je uvrstila metoda nevronske mreže, ki je bila uspešna v 84.1%, medtem ko se je na zadnje mesto uvrstil J48 algoritem z 80.7% uspešnostjo. Ugotovili so, da sta najbolj pomembna atributa pri vseh klasifikatorjih ukrivljenost zgornje ustnice in odstotek zob v predelu ustnic.

## 5.3 Primerjava uspešnosti sistemov za zaznavanje nasmehov

Rezultati so pokazali, da je sistem, ki so ga razvili avtorji E. C. L. Choi, G. Peaker in P. Wong, z uporabo naivnega Bayesovega klasifikatorja bolj uspešen od sistema, ki so ga razvili avtorji J. Whitehill, G. Littlewort, I.

Fasel, M. Bartlett in J. Movellan, z uporabo metod GentleBoost in SVM. Tabela 5.2 prikazuje pridobljene rezultate obeh sistemov, pri čemer opazimo, da je razlika uspešnosti sistemov skoraj 5%.

# Poglavje 6

## Primer preprostega računalniškega programa za zaznavo nasmehov

AutoSmiley [14] je računalniški program s področja računalniškega vida in je prosto dostopen na internetu. Izvaja se v ozadju med delom z računalnikom. Program s pomočjo video kamere analizira obraz in v okno, ki je v tistem trenutku v uporabi, zaporedno izpiše znaka : in ), ki združena predstavljata nasmešek. Program je bil narejen z namenom nadziranja pristinih čustev pri komunikaciji preko spletnih pogovorov.

Projekt je bil razvit z uporabo orodja OpenFrameworks, Code:blocks in orodja MPT, ki se uporablja za strojno zaznavanje.

### 6.1 Orodje za strojno zaznavanje

MPT je orodje, ki se uporablja za stojno zaznavanje [13]. Sestavljeno je iz knjižnic, ki vsebujejo metode za različne vrste zaznavanja pri ljudeh. Nekatere izmed metod, ki so uporabljene v programu AutoSmiley so zaznavanje obrazov, zaznavanje oči in mežikanja ter sledenje barv. MPT funkcije lahko vključimo v OpenFrameworks, kot smo to storili tudi v našem programu.

## 6.2 Predstavitev delovanja programa

Uporabili smo program AutoSmiley in ga prilagodili tako, da smo lahko testirali delovanje algoritma na GENKI-4K podatkovni bazi. V main.cpp se nahaja funkcija testPics(), ki je namenjena procesiranju naših slik. Uporabnika najprej vprašamo iz katerega mesta na disku bi rad, da program prebere slike in odpremo izbrano mapo. Če je slika pravilno najdena, odpremo datoteko output.txt, v katero zapisujemo naše rezultate. V naslednjem koraku se sprehodimo skozi vse datoteke, ki so najdene v izbrani mapi in imajo končnico .jpg ter ignoriramo datoteke, ki se začnejo s piko. Sliko nato odpremo in uporabimo algoritem za zaznavo nasmeha. Rezultate zapišemo v datoteko output.txt, ime obdelane slike prikažemo na zaslonu in datoteko zapremo.

```
// Funkcija za procesiranje slik z diska
void testPics() {
    ofImage img;
    bool found;
    float smilePct;

    // Vprasamo uporabnika za direktorij, kjer se nahajajo slike
    char dir[255];
    cout << "Vpisi pot do direktorija (slike .jpg): ";
    cin >> dir;

    // Dodamo \ na koncu, ce ga ni
    if (dir[strlen(dir)-1] != '\\')
        strcat(dir, "\\");

    // Odpremo direktorij
    DIR *dp;
    struct dirent *dirp;
```

```
if((dp = opendir(dir)) == NULL) {

    // Napaka, direktorija ni bilo mozno odpreti
    cout << "Error(" << errno << ") opening " << dir << endl;
    return;
}

// Odpremo datoteko za zapisovanje rezultatov
ofstream ofile;
char outPath[255];
strcpy(outPath, dir);
strcat(outPath, "ouput.txt");
ofile.open(outPath);

// Gremo cez datoteke v direktoriju
while ((dirp = readdir(dp)) != NULL) {
    char path[255];

    // Ignoriramo datoteke ki se zacnejo s piko, ali nimajo
    // koncnice jpg
    if ((strlen(dirp->d_name) < 4) || (dirp->d_name[0] == '.')
        ||((strcmpi((LPCSTR) ((int) dirp->d_name + strlen
            (dirp->d_name) - 3), "jpg") != 0) &&
            (strcmpi((LPCSTR) ((int) dirp->d_name + strlen(
                dirp->d_name) - 4), "jpeg") != 0))) continue;

    // V path zapisemo polno pot do datoteke
    strcpy(path, dir);
    strcat(path, dirp->d_name);

    // Odpremo sliko
```

```
img.loadImage(path);

// Zaznava nasmeha
found = ofxSmile::getSmile(img, smilePct);

// Zapis rezultata
ofile << dirp->d_name << " " << bool2str(found) << endl;

// Pokazemo ime obdelane slike na zaslonu
cout << dirp->d_name << endl;
}

// Zapremo datoteko in direktorij
ofile.close();
closedir(dp);
}
```

### 6.3 Postopek zaznave nasmeha, ki je uporabljen v programu

Postopek zaznave nasmeha temelji na tem, da najprej določimo pozicijo oči in s tem posledično pozicijo obraza. Ko je pozicija obraza približno določena, lahko uporabimo algoritem za zaznavo nasmeha. Tako algoritem za iskanje oči kot algoritem za ugotavljanje nasmeha temeljita na Viola - Jones metodi za detekcijo. Algoritem sestavljajo štirje temeljni koncepti:

- uvedba značilnic Haar;
- opredelitev integralne slike za hitro računanje značilnic;
- uporaba metode strojnega učenja AdaBoost za izgradnjo kaskade močnih klasifikatorjev;

	GENKI-4K	program
Se smeji	2162	2840
Se ne smeji	1838	1160

Tabela 6.1: Primerjava prepoznanih slik z nasmehi in slik, kjer se nasmeh ni zgodil iz podmnožice GENKI-4K z rezultati, pridobljenimi s pomočjo programa

- opredelitev zaporedja v kaskadi klasifikatorjev z namenom optimizacije izvajalnega časa.

Parametri za algoritem Viola - Jones pri detekciji nasmeha so bili določeni s strojnim učenjem na približno 5000 slikah. V uporabljeni knjižnici ni navedeno, iz katere podatkovne baze so uporabljene slike. Uporabili smo že izračunane parametre, ki so zapisani v `smile_wts.cc`.

## 6.4 Rezultati

Za testiranje smo uporabili testno aplikacijo, izdelano na podlagi AutoSmiley, pri čemer smo uporabili knjižnici `ofImage` in `ofxSmiley` oz. `OpenFrameworks`. Program smo testirali na podmnožici podatkovne baze GENKI in sicer na GENKI-4K, ki poleg izvornih datotek `file*.jpg` (z zvezdico so označene zaporedne številke slik od 0001 do 4000) vsebuje tudi datoteko `labels.txt`, v kateri so zbrane oznake vseh slik. Te so podane s 4 vrednostmi, od katerih je za naše testiranje pomembna samo prva številka (0 ali 1), ki določa ali je na sliki prisoten nasmeh ali ne (0 - se ne smeji, 1 - se smeji). Rezultate programa AutoSmiley smo shranili v datoteko `output.txt`, kjer so zbrana imena slik in oznaka 0 ali 1. Oznake obeh datotek `labels.txt` in `output.txt` smo tako vnesli v Excel in primerjali vrednosti.

Za lažje razumevanje rezultatov smo podatkovno bazo GENKI-4K razdelili na dve podmnožici in sicer podmnožico Se smeji, ki vsebuje 2162 slik in podmnožico Se ne smeji, ki vsebuje 1838 slik. V prvi podmnožici so tako

	GENKI-4K	uspešno prepoznane slike	napaka
Se smeji	2162	1594	568
Se ne smeji	1838	592	1246

Tabela 6.2: Število uspešno in neuspešno prepoznanih nasmehov v obeh podmnožicah podatkovne baze GENKI-4K

zbrane slike, ki so označene z oznako 1, kar pomeni, da se je teh slikah nasmeh zgodil, v drugi podmnožici pa se nahajajo slike z oznako 0, kar pomeni, da se nasmeh ni zgodil. Tabela 6.1 prikazuje koliko slik obrazov z nasmehi in koliko slik obrazov brez nasmeha se nahaja v podatkovni bazi GENKI-4K ter koliko nasmehov in slik brez nasmeha je našel naš program.

Tabela 6.2 prikazuje da je program v podmnožici Se smeji uspešno zaznal 1594 nasmehov, kar pomeni, da je dosegel 73.7% uspešnost, pri napaki 67.8%. V podmnožici Se ne smeji je program uspešno prepoznal 592 slik obrazov brez nasmeha, kar pomeni, da je slike obrazov brez nasmeha uspešno prepoznal v 32.3%, pri napaki 26.3%.

Napake se pojavijo predvsem v podmnožici Se ne smeji, ki so v datoteki labels.txt označene kot slike brez nasmehov. V tej podmnožici se program zmoti v 1246 primerih, saj zazna nasmeh na sliki, kljub temu, da ga tam ni. Ti primeri predstavljajo 68.7% vseh napak.

Pri pregledu slik iz podatkovne baze opazimo, da težava nastane pri slikah, pri katerih je nasmeh na meji (npr. file3397.jpg, file3948.jpg, file3800.jpg, file3646.jpg ...). Poleg tega smo opazili tudi, da se algoritem velikokrat zmoti pri slikah, ki so bolj svetle od ostalih (npr. set slik od file3630.jpg do file3640.jpg). Da bi preverili vpliv osvetljenosti slik na delovanje programa, smo 5 slik iz tega seta slik potemnili in preizkusili program še enkrat, tokrat le na teh 5 slikah. Program je pred potemnitvijo slik vse slike označil kot slike z nasmehi, po rahli potemnitvi slik, pa je nasmeh zaznal le še na treh. Ugotovimo, da neprimerna osvetlitev slik vpliva na uspešnost programa.

# Poglavje 7

## Zaključek

Raziskave so pokazale, da obstajajo različni zaznavalci nasmehov, ki so že vključeni v vrsto aplikacij, ki služijo različnim namenom. Uspešnost sistema za zaznavanje nasmehov je odvisna od podatkovne baze, na kateri je bil zaznavalec nasmehov učen in testiran, ter od registracije slike in uporabe pravih metod strojnega učenja za zaznavanje. Razvoj samega sistema za zaznavanje nasmeha ni enostaven, saj je delovanje človeškega zaznavnega sistema precej kompleksno. Razvijalci zato pri razvijanju aplikacij, ki vsebujejo zaznavanje nasmehov uporabljajo že preizkušene podatkovne baze za testiranje in metode strojnega učenja, ki so v zadnjih letih pokazale za najbolj uspešne. Na podlagi raziskave smo ugotovili, da je pri zaznavi nasmehov najbolj natančen in uspešen naivni Bayesov klasifikator, ki so ga pri razvoju sistema za zaznavanje nasmehov uporabili avtorji E. C. L. Choi, G. Peaker in P. Wong. Dober rezultat doseže tudi sistem za zaznavanje nasmehov, ki so ga razvili avtorji J. Whitehill, G. Littlewort, I. Fasel, M. Bartlett in J. Movellan, na podlagi GentleBoost in SVM metod strojnega učenja. Ugotovljeno je bilo, da sta najbolj pomembna atributa pri vseh klasifikatorjih ukrivljenost zgornje ustnice in odstotek zob v predelu ustnic. Na trgu obstaja veliko kamer, ki že imajo funkcijo zaznavanja nasmehov, od Sony Cyber-shot kamer do telefonov znamke Samsung in LG. Vendar se zaradi hitrega razvoja računalniške strojne opreme in različnih programskih tehnologij potreba po

novih, zmogljivejših aplikacijah hitro povečuje.

# Literatura

- [1] J. Whitehill, G. Littlewort, I. Fasel, M. Bartlett, J. Movellan, “Developing a Practical Smile Detector”.
- [2] F. Gosselin, P. G. Schyns, “Bubbles: a technique to reveal the use of information in recognition tasks”, *Vision Research*, vol. 41, 2001.
- [3] P. Ekman and W. Friesen, “The Facial Action Coding System: A Technique For The Measurement of Facial Movement”, *Psychologists Press, Inc.*, San Francisco, CA, 1978.
- [4] Cohn-Kanade AU-Coded Facial Expression Database. Dostopno na: <http://www.pitt.edu/~jeffcohn/CKandCK+.htm>
- [5] GENKI Database. Dostopno na: <http://mplab.ucsd.edu/wordpress/>
- [6] Yale Face Database. Dostopno na: <http://cvc.yale.edu/projects/yalefaces/yalefaces.html>
- [7] G. Littlewort, M. Bartlett, I. Fasel, J. Susskind, J. Movellan, “Dynamics of facial expression extracted automatically from video”, *Image and Vision Computing*, vol. 24, no. 6, pp. 615–625, 2006.
- [8] Tutorial on Gabor Filters. Dostopno na: <http://mplab.ucsd.edu/tutorials/gabor.pdf>
- [9] B. Batagelj, “Prepoznavanje človeških obrazov s pomočjo hibridnega sistema (doktorska dizertacija)”, 2007.

- [10] B. Batagelj, "Iskanje obrazov na osnovi barv s pomočjo statističnih metod razpoznavanja vzorcev (magistrska naloga)", 2004.
- [11] I. Fasel, B. Fortenberry, J. Movellan, "A generative framework for real time object detection and classification", *Computer Vision and Image Understanding*, vol. 98, 2005.
- [12] E. C. L. Choi, G. Peaker, P. Wong, "Face Detection and Smile Classification".
- [13] The Machine Perception Toolbox. Dostopno na:  
<http://mplab.ucsd.edu/grants/project1/free-software/mptwebsite/introduction.html>
- [14] AutoSmiley.cbp. Dostopno na:  
<http://ffff.at/auto-smiley/>