




Univerza v Mariboru

Fakulteta za elektrotehniko,  
računalništvo in informatiko

---



**ROSUS 2014**  
**Računalniška obdelava slik in njena**  
**uporaba v Sloveniji 2014**  
Zbornik 9. strokovne konference

Urednik  
Božidar Potočnik

Maribor, 20. marec 2014

Zbornik prispevkov strokovne konference  
*ROSUS 2014 Računalniška obdelava slik in njena uporaba v Sloveniji 2014*  
Maribor, 20. marec 2014

Elektronska izdaja

CIP - Kataložni zapis o publikaciji  
Univerzitetna knjižnica Maribor

004.932(497.4)(082)(0.034.2)

**STROKOVNA konferenca ROSUS (9 ; 2014 ; Maribor)**

ROSUS 2014 [Elektronski vir] : računalniška  
obdelava slik in njena uporaba v Sloveniji 2014 :  
zbornik 9. strokovne konference, Maribor, 20.  
marec 2014 / urednik Božidar Potočnik. - El.  
zbornik. - Maribor : Fakulteta za elektrotehniko,  
računalništvo in informatiko, Inštitut za  
računalništvo, 2014

Dostopno tudi na:  
<http://cobsis.uni-mb.si/rosus2014/>

ISBN 978-961-248-423-1  
1. Potočnik, Božidar  
COBISS.SI-ID 77333761

ISBN 978-961-248-423-1



*Programski odbor ROSUS 2014:*

dr. Božidar Potočnik  
dr. Damjan Zazula  
dr. Boris Cigale  
dr. Nikola Guid  
dr. Baldomir Zajc  
dr. Tomaž Tomažič  
dr. Slobodan Ribarič  
dr. Veljko Vlasisavljevič  
dr. Saša Divjak

dr. Stanislav Kovačič  
dr. Zdravko Kačič  
dr. Aleš Leonardis  
dr. Janez Perš  
dr. Mitja Lenič  
dr. Franc Solina  
dr. Andrej Šoštarič  
dr. Franjo Pernuš  
dr. Aleš Holobar

*Organizacijski odbor 2014:*


dr. Božidar Potočnik  
dr. Damjan Zazula  
dr. Danilo Korže  
dr. Boris Cigale  
dr. Smiljan Šinjur  
Jurij Munda  
Vojko Glaser  
Gašper Sedej

Spoštovani!

Po osmih uspešnih konferencah ROSUS 2006–2013 želimo s konferenco ROSUS 2014 spet promovirati pomembnost ekonomske koristnosti računalniške obdelave slik na področjih industrije, biomedicine in drugih poslovnih procesov. Vezi, ki smo jih na prejšnjih konferencah stkali med raziskovalci, razvijalci, ponudniki rešitev ter uporabniki računalniške obdelave slik v slovenskem prostoru, želimo še dodatno okrepiti, ob tem pa nuditi tudi možnosti sklepanja novih sodelovanj in svetovanja pri razreševanju konkretnih poslovnih oziroma raziskovalnih problemov.

Tudi letos namenjamo glavni poudarek aplikacijam s področja računalniške obdelave slik, ki so že integrirane oziroma pripravljene za integracijo v poslovne procese. S tem želimo ne le demonstrirati, da takšna avtomatska obdelava lahko zaradi svoje natančnosti in hitrosti prinaša velike ekonomske koristi, ampak tudi dokazati, da aplikacije računalniške obdelave slik nudijo nove priložnosti za uveljavitev na trgu visokih tehnologij. Seveda ne smemo pozabiti na možnost diskusije ter predstavitev konkretnih problemov in potreb, ki se porajajo pri uporabnikih, s katerimi bomo računalniško obdelavo slik in njeno koristnost še bolj približali avditoriju.

dr. Božidar Potočnik  
predsednik konference  
ROSUS 2014



## POKROVITELJI

---



---

**ROSUS 2014**  
**<http://cobsis.uni-mb.si/rosus2014/>**

# KAZALO

---

<b>VABLJENA PREDAVANJA .....</b>	<b>1</b>
<b>Matjaž Divjak, Simon Zelič, Aleš Holobar, FERI, Maribor</b> <i>Avtomatsko ocenjevanje pacientove pozornosti na povratne informacije med rehabilitacijo hoje po možganski kapi .....</i>	<b>3</b>
<b>INDUSTRIJSKE APLIKACIJE.....</b>	<b>13</b>
<b>Jernej Bule, Đorđe Kesić, Peter Peer, FRI, Ljubljana</b> <i>Biometrična verifikacija kot storitev v oblaku – primer uporabe .....</i>	<b>15</b>
<b>Iztok Fister ml., Dušan Fister, Uroš Mlakar, Karin Ljubič, Janez Brest, Iztok Fister, FERI, Maribor</b> <i>Netopirji, kresnice in kukavice pri obdelavi slik .....</i>	<b>22</b>
<b>Jaka Pribošek, Peter Gregorčič, Janez Diaci, FS, Ljubljana</b> <i>Uporaba aktivnih kontur za segmentacijo udarnih valov v nizkokontrastni koherentni senčni fotografiji .....</i>	<b>34</b>
<b>Anton Ružič, IJS, Ljubljana</b> <i>Značilnosti zajemanja in obdelave posnetkov v proizvodnem okolju z visokimi temperaturami.....</i>	<b>42</b>
<b>Danijel Skočaj, Domen Tabernik, Domen Rački, Matjaž Hegedič, Alen Vrečko, Matej Kristan, FRI, Ljubljana</b> <i>Merjenje natančnosti pametnih mobilnih naprav v aplikacijah strojnega vida.....</i>	<b>50</b>
<b>Matjaž Divjak, Damjan Zazula, FERI, Maribor</b> <i>Primerjava postopkov za 3D-rekonstrukcijo scene iz para slik .....</i>	<b>56</b>
<b>MEDICINSKE IN BIOMEDICINSKE APLIKACIJE .....</b>	<b>67</b>
<b>Primož Poredoš, Dušan Čelan, Janez Možina, Matija Jezeršek, FS, Ljubljana, UKC, Maribor</b> <i>Prostorsko določanje krivulj hrbtenice na osnovi 3D laserske profilometrije.....</i>	<b>69</b>
<b>Tina Klenovšek, FNM, Maribor</b> <i>Analiza modularnosti objektov v biologiji .....</i>	<b>78</b>

**DRUGO..... 85**

**Milan Čoh, Vedran Hadžić, Brane Širok, Aleš Malneršič,**  
FŠ, FS, Ljubljana

*Uporaba infra rdeče termografske metode v procesu športnega treninga ..... 87*

# **VABLJENA PREDAVANJA**

---





# AVTOMATSKO OCENJEVANJE PACIENTOVE POZORNOSTI NA POVRATNE INFORMACIJE MED REHABILITACIJO HOJE PO MOŽGANSKI KAPI

**Matjaž Divjak, Simon Zelič, Aleš Holobar**

**Laboratorij za sistemsko programsko opremo**

**Univerza v Mariboru, Fakulteta za elektrotehniko, računalništvo in  
informatiko**

**E-pošta: matjaz.divjak@um.si, simon.zelic@um.si, ales.holobar@um.si**

**URL: <http://storm.uni-mb.si>**

---

**POVZETEK:** *V zahodni družbi je približno 4,7 milijona preživelih po možganski kapi. Njihova zmanjšana gibalna sposobnost prispeva k občutku stigmatiziranosti, naredi bolnike bolj dovzetne za poškodbe in močno vpliva na kakovost njihovega življenja. Novejše tehnike za rehabilitacijo hoje temeljijo na robotsko podprtih vadbah, ki se sproti prilagajajo bolnikovim sposobnostim. Njihova učinkovitost še ni povsem jasna, velik problem pa predstavlja bolnikovo nerazumevanje povratne informacije o poteku vadbe in opravljenih gibih. Slednje vodi v nepravilno vadbo in demotivacijo ter preprečuje aktivno bolnikovo udejstvovanje v rehabilitaciji.*

*V prispevku opisujemo zasnovano, razvoj in funkcionalno validacijo sistema za nemoteče ocenjevanje bolnikove pozornosti na povratno informacijo med robotsko podprto rehabilitacijo hoje po možganski kapi. Sistem temelji na realnočasovnem sledenju bolnikovemu pogledu s pomočjo video kamere, v kombinaciji z naprednimi vmesniki mišice-stroj pa odpira nove možnosti merjenja bolnikove aktivne participacije med rehabilitacijo živčnomišičnega sistema.*

---

## 1. UVOD

Možganska kap prizadene somatosenzorična vezja človeškega korteksa in zmanjša bolnikovo sposobnost zaznavanja gibanja. Vizualna povratna informacija o izvedenem gibu krepi motorično učenje in se pogosto uporablja za bogatenje bolnikove interakcije v robotsko podprti rehabilitaciji po možganski kapi. V [1] so avtorji pokazali, da uporaba interaktivne vizualne povratne zanke bistveno zmanjša potrebo bolnika po strokovni pomoči fizioterapevta in posledično zmanjšuje stroške rehabilitacije. Pozitiven vpliv vizualno obogatene povratne informacije so dokazale tudi psihofizične in nevrofiziološke študije [2], ki razkrivajo, da pri izvedbi zamišljenih in dejanskih gibov sodelujejo ista nevronska vezja.

Po drugi strani so številne študije nakazale statistično nesignifikanten vpliv vizualne povratne informacije na rehabilitacijo po možganski kapi [3]. Razlogi za opisana razhajanja v literaturi dostopnih študij so predmet aktivne razprave, eden očitnejših pa je

pomanjkanje orodij za kvantitativno vrednotenje bolnikove pozornosti na ponujeno vizualno povratno informacijo. Ker je stopnja prizadetosti po možganski kapi odvisna od več dejavnikov (predvsem od lokacije in velikosti prizadetega možganskega tkiva), se bolniki močno razlikujejo v njihovi dovzetnosti in odzivih na povratno vizualno informacijo. Omenjeno nakazuje na potrebo po personalizaciji ponujene vizualne povratne informacije in njenemu nenehnemu prilagajanju kognitivnim in motoričnim spodobnostim posameznega bolnika.

Medtem ko je sledenje pogledu dobro razvito na področju računalniškega vida, se le redko uporablja v rehabilitaciji po možganski kapi. Do sedaj predlagani pristopi spremljanja bolnikove pozornosti temeljijo na posrednih psihofizioloških indikatorjih kot sta srčni utrip in frekvenca dihanja. Slednji odražajo splošno psihofizično stanje bolnika in ne omogočajo neposrednih meritev njegove pozornosti. Cilj te študije, ki je potekala v okviru Evropskega projekta BETTER [4], je bil preveriti izvedljivost in učinkovitost meritev bolnikove pozornosti z nemotečim video nadzorom robotsko podprte rehabilitacije spodnjih okončin na napravi Lokomat švicarskega podjetja Hocoma [5].

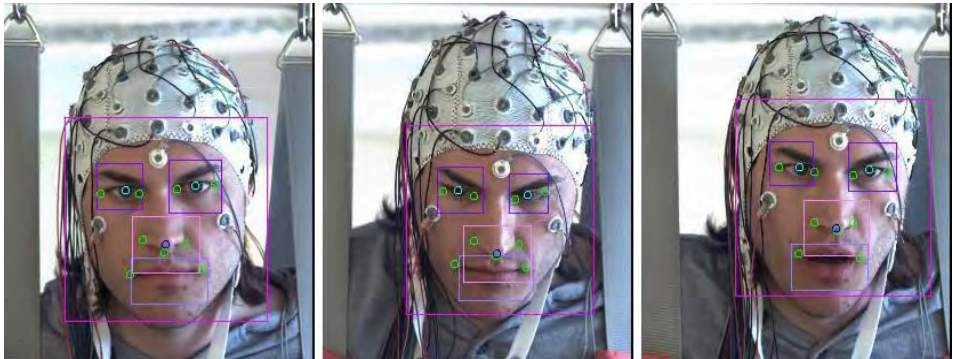
## 2. SLEDENJE PACIENTOVI POZORNOSTI

Razvili smo dva različna, a komplementarna pristopa. Prvi pristop temelji na uporabi značilnic in zbirki različnih sledilnih algoritmov. Zazna 11 najpomembnejših obraznih značilnosti: notranje in zunanje kotičke oči, središče zenic, kotičke ust, levi in desni rob nosu ter vrh nosu. Algoritmi so podrobjeje predstavljene v podpoglavju 2.1. Drugi pristop temelji na uporabi aktivnih modelov videza (*Active appearance models* - AAM). Pacientov obraz modelira z 2D mrežo, sestavljeno iz 59 točk na obrazu ter upošteva tako obliko kot tudi izgled/teksturo obraza, kar omogoča bolj natančno in robustno spremljanje obrazne mimike. Podrobneje je predstavljen v podpoglavju 2.2.

### 2.1 Zaznava značilnic

Za zaznavo obraznih značilnic smo implementirali več različnih detektorjev obraznih komponent in njihovo zmogljivost ocenili na video posnetkih, zajetih med rehabilitacijo pacientov na Lokomatu. Med implementiranimi algoritmi so detektorja SURF (*speeded up robust feature*) [6] in SIFT (*scale-invariant feature transform*) [7], Haarovi detektorji za obraz, oči, nos in usta [8] in generativni model položaja značilnic [9]. Za zaznavo zenic smo implementirali prilagodljiv pristop, opisan v [10] in radialno simetrijo [11].


Natančnost zaznave značilnic, odpornost na morebitne napake v posnetkih in odpornost na nihanja glave smo preverili na posnetkih zdravih oseb med njihovo robotsko podprto hojo na Lokomatu. Na podlagi preliminarnih rezultatov se je za najbolj obetavno rešitev izkazal generativni model položaja značilnic [9] v kombinaciji s Haarovimi detektorji za obraz, oči, nos in usta (slika 1). Za zaznavo zenic smo uporabili radialno simetrijo [11], predvsem zaradi njene nizke računske zahtevnosti in relativno dobrih rezultatov.



Slika 1. Primer rezultatov sledenja obraznih značilnic na slikah zajetih iz video posnetka zdravega prostovoljca. Izdvojene obrazne regije in deli obraza so označeni s pravokotniki. Obrazne značilnice, ki so bile zaznane z generativnim modelom položaja značilnic [9], so označene z zeleno barvo, zenice, zaznane s postopkom radialne simetrije [11] pa s svetlo modro barvo.

## 2.2 Aktivni model videza (*Active appearance model* – AAM)

Po uvodnem testiranju različnih implementacij AAM smo kot najprimernejši izbrali inverzni kompozicijski pristop (*Inverse compositional AAM*) iz [12]. S pomočjo testnih posnetkov smo najprej zgradili generični frontalni model obraza, ki je sestavljen iz triangulirane mreže z 59 točkami (slika 2), kasneje pa smo za vsakega pacienta pripravili še njegov osebni model, ki bolje zajame morebitne posebnosti obraza.



Slika 2: Aktivni model videza za obraz, prikazan na slikah dveh zdravih prostovoljcev med rehabilitacijo z Lokomatom. Mreža modela AAM (rdeče črte) je sestavljena iz 59 točk na obrazu.


Sposobnost prilagajanja modela AAM na vhodno sliko je v veliki meri odvisna od natančne in robustne inicializacije modela in začetnega prileganja pacientovemu obrazu. V literaturi so modeli AAM ponavadi inicializirani ročno, z natančnim označevanjem značilnih točk na več učnih slikah [12]. Takšen korak je zelo zamuden in zahteva

precejšnjo ročno spretnost, zato ni primeren za klinično prakso. Da bi se izognili tem težavam, smo uporabili algoritme za zaznavanje obraznih značilnic (kotičkov oči in ust, zenice, nosu; glej podpoglavje 2.1) in zaznavanje kožne barve ter z njihovo pomočjo in s pomočjo generičnega modela obraza pripravili množico učnih slik za inicializacijo osebnega modela AAM.

S pomočjo položaja oči, nosu, ust in zenic smo z metodo, opisano v [13] izračunali normalo na planarno regijo obraza in s tem 3D orientacijo obraza.

### 2.3 Vizualna povratna informacija med rehabilitacijo hoje

Poleg grafov gibanja in pospeškov nog, ki jih v programski opremi Lokomata ponuja podjetje Hocoma, smo preizkusili še v projektu BETTER [4] razvita navidezna okolja (slika 3, desno spodaj) in posebnonamenski grafični vmesnik BTM (*BETTER top-down approach*), ki omogoča sprotno spremljanje aktivnosti nožnih mišic (slika 3, zgoraj).



Slika 3: Različne oblike vizualne povratne informacije med robotsko podprto rehabilitacijo hoje. Zgornja slika prikazuje v projektu BETTER razviti grafični vmesnik BTM, ki omogoča spremljanje aktivnosti nožnih mišic med robotsko podprto hojo. Levo spodaj je prikazan zaslon za kalibracijo in vrednotenje natančnosti sledenja pogleda. Slika desno spodaj prikazuje navidezno okolje z avtarjem (perspektiva tretje osebe).

Vmesnik BTM zagotavlja vizualno povratno informacijo o aktivnosti naslednjih nožnih mišic: vastus lateralis (VL), rectus femoris (RF), biceps femoris (BF), tibialis anterior (TA), gastrocnemii (GM) in soleus (SOL). Cikel hoje je razdeljen v šestnajst enako dolgih intervalov. Štiri barvne črte, ki jih sestavlja 16 pravokotnikov (po en pravokotnik za vsakega od šestnajstih intervalov) kažejo preveliko mišično aktivnost (obarvano modro), premajhno mišično aktivnost (obarvano rdeče) in pravilno mišično aktivnost (obarvano belo) naslednjih štirih mišičnih skupin: VL-RF, BF, GM-SOL in TA (slika 3). Barvanje črt temelji na meritvah površinskih elektromiogramov in realnočasovnem izračunu mišične koaktivacije med robotsko podprto rehabilitacijo hoje [4].

## 2.4 Meritve rehabilitacije spodnjih okončin

Eksperimentalne meritve smo opravili med robotsko podprto hojo na Lokomatu. Merili smo štiri zdrave mlade udeležence in štiri starejše bolnike po možganski kapi. Meritve so bile z dovoljenjem lokalnih etičnih odborov in pisnim soglasjem vseh udeležencev izvedene v rehabilitacijskih klinikah Judendorf-Strassengel (Gradec, Avstrija) in Fondazione Santa Lucia (Rim, Italija).

Merili smo pozornost na naslednjih šest vizualnih povratnih informacij, ki smo jih prikazovali na 1,4 m oddaljenem zaslonu LCD z diagonalo velikosti 107 cm:

1. Kalibracijski zaslon: črno ozadje z belimi plusi na sredini in v kotih zaslona (slika 3). Plusi so prikazani v naključnem vrstnem redu, na zaslonu pa je vedno prikazan en sam beli plus;
2. Navidezno okolje z avatarjem, prikazanim s perspektive tretje osebe (slika 3, desno spodaj);
3. Navidezno okolje, prikazano s perspektive prve osebe;
4. Vmesnik BTM (slika 3, zgoraj);
5. Grafi podjetja Hocoma (trenutne pozicije in koti kolkov in kolen);
6. Brez vizualne povratne informacije (izklopljen zaslon).

Vsaka meritev je trajala štiri minute. Med meritvijo je bilo udeležencem naročeno, naj hodijo aktivno, ohranjajo konstantno hitrost hoje in pri tem minimalno nasprotujejo robotu. Obraz udeležencev smo snemali z visokozmogljivo kamero Basler Ace acA2000, ki omogoča zajem videa v ločljivosti  $2040 \times 1086$  pikslov pri hitrosti 100 slik na sekundo. Kamero smo namestili na vrh zaslona, ki je prikazoval vizualno povratno informacijo. Algoritmi sledenja pogledu (podpoglavji 2.1 in 2.2) so tekli na osebem računalniku s centralno procesno enoto Intel Core i7-930 in 6 GB pomnilnika, implementirani pa so bili deloma v Matlabu, deloma v C++ z uporabo knjižnice OpenCV [14].

### 3. REZULTATI

V povprečju je Haarov detektor zaznal obraz na 95 % slik, za zaznavo pa je v porabil  $43,8 \pm 3,5$  ms na sliko. Radialna simetrija je zaznala zenice na 99,9 % slik z razpoznanim obrazom, za zaznavo pa je porabila  $5,5 \pm 0,7$  ms. Povprečni raztros zaznanih obraznih značilnic je znašal  $3,0 \pm 2,5$  piksla. Model AAM je obraz zaznal na 95 % slik, v povprečju je porabil  $162 \pm 26$  ms procesorskega časa na sliko, povprečen raztros zaznanih obraznih značilnic pa je znašal  $0,5 \pm 0,3$  piksla.

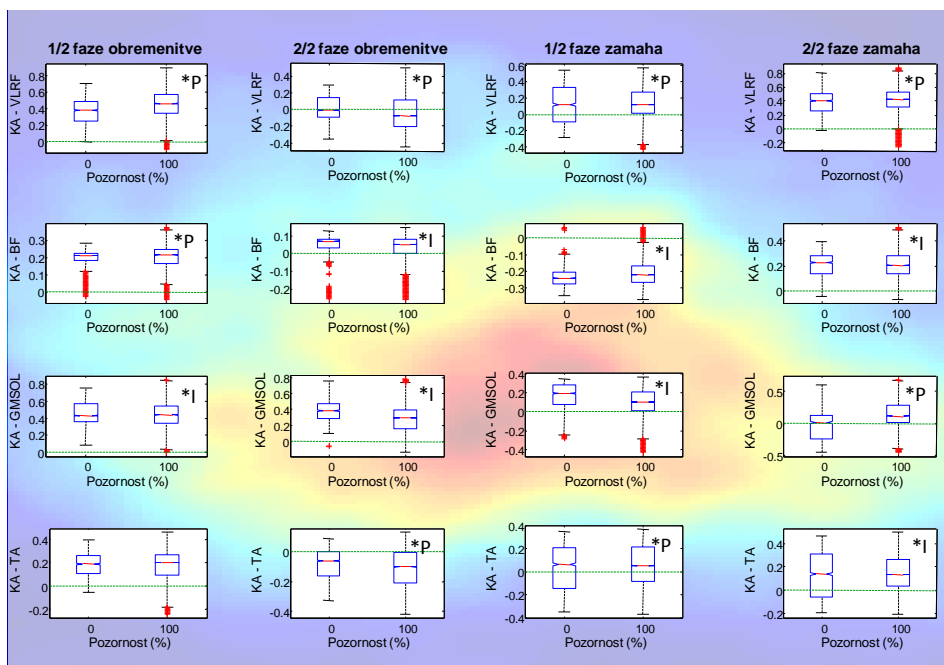
Natančnost sledenja pogledu smo ocenili s pomočjo sledečega postopka:

1. Pregledali smo video posnetke, posnete med prikazom kalibracijskega zaslona (slika 3, spodaj levo) in označili vse časovne intervale, v katerih je bil pogled merjenca fiksiran na enega izmed prikazanih belih plusov. Časovna obdobja, ki ustrezajo gibanjem očesnih zrkel ali utripu z očmi smo prezri. Tako smo dobili referenčne smeri pogleda.
2. S pomočjo najdenih obraznih značilnic in generičnega modela obraza AAM (glej podpoglavje 2.1) smo inicializirali osebni model obraza in ga prilagodili posameznemu merjencu (slika 2). Nato smo sledili premikom kotičkov oči, zenic, vrha nosu in kotičkov ust ter sproti izračunavali smer pogleda.
3. Dvajset zaporednih smeri pogleda smo združili v vektor značilnic in ga klasificirali z metodo podpornih vektorjev, pri čemer smo prvo polovico vsakega video posnetka (okrog 120 s) uporabili kot učno, drugo polovico pa kot testno množico.
4. Pridobljene rezultate smo primerjali z referenčnimi smermi pogleda iz koraka 1 in izračunali natančnost klasifikacije.

Pri zdravih osebkih je bila smer pogleda razpoznana s povprečno natančnostjo  $94 \pm 6$  %. Večina napak je izvirala iz manjše sposobnosti razlikovanja med smermi zgoraj-levo proti spodaj-levo in zgoraj-desno proti spodaj-desno (slika 3, spodaj levo). Pri bolnikih po možganski kapi je bila smer pogleda razpoznana s povprečno natančnostjo  $85 \pm 11$  %.

Da bi preverili učinkovitost prikaza povratne informacije z vmesnikom BTĐ, smo pri bolnikih po možganski kapi izračunali korelacijo med mišično koaktivacijo in pozornostjo na različne predele vmesnika BTĐ (slika 3, zgoraj). V ta namen smo cikel hoje razdelili na štiri dele: prva polovica faze opore (prvi štirje pravokotniki na skrajni levi strani slike 3), druga polovica faze opore (pravokotniki od 5 do 8 na sliki 3), prva polovica faze zamaha (pravokotniki od 9 do 12) in druga polovica faze zamaha (pravokotniki od 13 do 16 na skrajni desni strani slike 3). Meritve smo razdelili v enosekundne neprekrivajoče se časovne intervale in v vsakem intervalu za vsako mišično skupino posebej izračunali stopnjo mišične koaktivacije (prevelika, optimalna, premajhna) v odvisnosti od bolnikove pozornosti na vmesnik BTĐ. Statistično analizo smo izvedli s testom Kruskal-Wallis. Stopnjo zaupanja smo nastavili na 0.05. Reprezentativni rezultati za bolnika številka 3 so prikazani na sliki 4.

Bolnik št. 3 je vmesniku BTD posvetil veliko pozornosti. S pozornostjo na vizualno povratno informacijo je v fazi opore bistveno izboljšal koaktivacijo treh (VL-RF, BF in TA) od štirih mišičnih skupin, v fazi zamaha pa koaktivacijo dveh (GM-SOL in TA) od štirih mišičnih skupin (slika 4). Hkrati je s pozornostjo na zaslon v fazi opore poslabšal koaktivacijo mišične skupine GM-SOL, v fazi zamaha pa koaktivacijo mišičnih skupin VL-RF in BF. Podrobnejša analiza smeri pogleda je razkrila pozitivno korelacijo med usmerjenostjo bolnikovega pogleda in pravilnostjo mišičnih koaktivacij. Bolnik je največ pozornosti namenil osrednjemu delu zaslona, torej območju, kjer so se prikazovale povratne informacije o mišični koaktivaciji mišic GM, SOL in BF v zadnji polovici faze opore in prvi polovici faze zamaha (slika 4). Koaktivacijski vzorci vseh opazovanih mišičnih skupin so se s pozornostjo na zaslon bistveno izboljšali, medtem ko so se koaktivacijski vzorci mišičnih skupin zunaj območja pozornosti (TA, VL in RF) poslabšali (slika 4). Podobni rezultati so bili izmerjeni tudi pri bolnikih št. 1 in št. 4, medtem ko bolnik št. 2 vmesniku BTD ni posvečal velike pozornosti.



Slika 4: Stopnja mišične koaktivacije (KA) v odvisnosti od pozornosti na vmesnik BTD pri pacientu št. 3. Vrednost 0 predstavlja optimalno mišično aktivnost. Pozitivne vrednosti predstavljajo prevelike mišične aktivnosti, negativne vrednosti pa premajno mišično aktivnost. V ozadju je z barvo prikazana porazdelitev gostote pogledov, ocenjena z modelom AAM. Rdeča barva prikazuje področja v veliko pozornostjo, temno modra barva pa območja brez bolnikove pozornosti; \*I – statistično signifikantno izboljšanje mišične aktivnosti s pozornostjo na vmesnik BTD; \*P – statistično signifikantno poslabšanje mišične aktivnosti s pozornostjo na vmesnik BTD.

## 4. ZAKLJUČEK

Opisan pristop sledenja pogledu med rehabilitacijo hoje po možganski kapi omogoča učinkovito vrednotenje bolnikove pozornosti na prikazano vizualno povratno informacijo. V tej študiji smo ga preizkusili na štirih zdravih merjencih in štirih bolnikih po možganski kapi. Kot so pokazali rezultati, gibanje bolnikovega obraza zaradi hoje na Lokomatu ne vpliva bistveno na natančnost sledenja v študiji obravnavanih predelov obraza, še posebej v primeru uporabe modela AAM. Predstavljeni pristop torej omogoča popolnoma nemoteče, relativno robustno in povsem avtomatsko sledenje pogledu bolnika z razdalje ~ 1,5 m.

Nadaljnja analiza je pokazala pozitivno korelacijo med pozornostjo na vmesnik BTM in pravilnostjo sočasne aktivacije nožnih mišic v treh od štirih bolnikov po možganski kapi. Preostali bolnik ni vmesniku BTM posvečal skoraj nobene pozornosti, njegova rehabilitacija pa je bila, v primerjavi z ostalimi bolniki, manj uspešna. Z rehabilitacijskega stališča so bile manj uspešne tudi povratne informacije, ki so jih posredovala v projektu BETTER implementirana navidezna okolja in Hocomini grafi premikov nog. Podrobnejša analiza teh rezultatov bo predstavljena drugje.

## ZAHVALA

Raziskave so bile financirane s strani 7. okvirnega programa Evropske komisije v okviru projektov »*BETTER – Brain-Neural Computer Interaction for Evaluation and Testing of Physical Therapies in Stroke Rehabilitation of Gait Disorders*« (FP7-2009-7.2 –247935) in »*qFATIGUE - Quantification of mental fatigue by means of visual and physiological measures*« (FP7-PEOPLE-2010-RG-269438).

Avtorji se zahvaljujejo Teodoru Solis-Escalante in Johanni Wagner s Tehnične univerze v Grazu (Avstrija), in osebju Rehabilitacijske klinike Judendorf-Strassengel (Graz, Avstrija) za organizacijo video snemanj zdravih prostovoljcev. Prav tako gre zahvala prof. Marcu Molinariju, dr. Febu Cincotti, Federici Tamburella, dr. Luci Muzioli in Fabiu Aloise iz bolnišnice Fondazione Santa Lucia v Rimu (Italija) za organizacijo in izvedbo snemanja pacientov po možganski kapi.

## LITERATURA

1. A. Gaggioli, F. Morganti, R. Walker, A. Meneghini, M. Alcaniz, J.A. Lozano, J. Montesa, J.A. Gil, G. Riva (2004), Training with Computer-Supported Motor Imagery in Post-Stroke Rehabilitation”, *Cyberpsychology & Behavior*, 7(3).
2. P.L. Jackson, M.F. Lafleur, F. Malouin et al (2001), Potential role of mental practice using motor imagery in neurologic rehabilitation, *Archives of Physical Medicine and Rehabilitation*, vol. 82, str. 1133–1141.
3. R.P.S. Van Peppen, M. Kortsmit, E. Lindman, G. Kwakkel (2006), Effects of visual feedback therapy on postural control in bilateral standing after stroke: A systematic review, *Journal of Rehabilitation Medicine*, 38(1), str. 3-9.



4. BETTER – Brain-Neural Computer Interaction for Evaluation and Testing of Physical Therapies in Stroke Rehabilitation of Gait Disorders« (FP7-2009-7.2 – 247935): <http://www.car.upm-csic.es/bioingenieria/better/>
5. Hocoma Lokomat: <http://www.hocoma.com/products/lokomat/lokomatpro/>
6. H. Bay, A. Ess, T. Tuytelaars, L. Van Gool (2008), SURF: Speeded Up Robust Features, *Computer Vision and Image Understanding (CVIU)*, 110 (3), str. 346-359.
7. D. G. Lowe (2004), Distinctive Image Features from Scale-Invariant Keypoints, *International Journal of Computer Vision*, 60 (2), str. 91-110.
8. P. Viola and M. Jones (2001), Robust Real-time Object Detection, *Second international workshop on statistical and computational theories of Vision – modeling, learning, computing, and sampling*, Vancouver, Canada.
9. J. Sivic, M. Everingham, A. Zisserman (2009), “Who are you?” Learning person specific classifiers from video, *In Proc. of IEEE Conference on Computer Vision and Pattern Recognition*, str. 1145-1152.
10. M. Asadifard, J. Shanbezadeh (2010), Automatic Adaptive Center of Pupil Detection Using Face Detection and CDF Analysis, *In. Proc. of IMECS 2010 conference*, Vol. I, Hong Kong.
11. G. Loy, A. Zelinsky (2003), A Fast Radial Symmetry Transform for Detecting Points of Interest, *IEEE PAMI*, 25 (8), str. 959-973.
12. I. Matthews, J. Xiao, S. Baker (2007), 2D vs. 3D Deformable Face Models: Representational Power, Construction, and Real-Time Fitting, *International Journal of Computer Vision*, 75(1), str. 93-113.
13. A.H. Gee and R. Cipolla (1994), Determining the gaze of faces in images, *Image and Vision Computing*, 12. str. 639-647.
14. Spletna stran Open Source Computer Vision: <http://opencv.org/>.



## **INDUSTRIJSKE APLIKACIJE**

---



# BIOMETRIČNA VERIFIKACIJA KOT STORITEV V OBLAKU – PRIMER UPORABE

**Jernej Bule, Dorde Kesić, Peter Peer**

**Laboratorij za računalniški vid, Fakulteta za računalništvo in informatiko,  
Univerza v Ljubljani, Tržaška cesta 25, 1000 Ljubljana  
E-pošta: {jernej.bule, peter.peer}@fri.uni-lj.si, dordekesic.keso@gmail.com**

---

**POVZETEK:** *Ko govorimo o avtentikaciji na internetu, v večini primerov še vedno mislimo na gesla. Eden izmed največjih problemov trenutnih avtentikacijskih pristopov je vsekakor dejstvo, da si mora uporabnik zapolniti preveliko število uporabniških imen in gesel, kar vodi k pozabljanju ali uporabi istih uporabniških imen in gesel za različne spletne strani. Rešitev tega problema lahko najdemo v uporabi biometrije. V članku predstavljamo biometrično verifikacijo kot storitev v oblaku in primer uporabe takšne storitve v aplikaciji za preverjanje prisotnosti študentov na predavanju.*

---

## 1. UVOD

Biometrija je relativno pogosto uporabljena v lokalnih okoljih (za privatno uporabo), medtem ko je njena uporaba na internetu zelo redka. Glavni razlog za to dejstvo so odprta vprašanja, ki se nanašajo predvsem na dostopnost, razpoložljivost in hitrost obstoječe biometrične tehnologije.

Glede na hitro naraščanje biometričnih podatkov in vedno večja pričakovanja uporabnikov bo v bližnji prihodnosti potrebno imeti visoko razširljive biometrične sisteme, ki bodo lahko operirali nad ogromno količino podatkov (procesorska moč) in hkrati zagotavljali ustrezne kapacitete za hrambo podatkov [1]. Teh lastnosti s tradicionalnimi biometričnimi sistemi ni mogoče zagotoviti. Mnogo strokovnjakov se strinja, da se rešitev nahaja v integraciji obstoječih biometričnih sistemov v oblačne platforme, ki omogočajo ustrezno razširljivost tehnologije, zadostno količino prostora za hrambo podatkov, možnost paralelnega procesiranja in z razširjeno uporabo mobilnih naprav tudi možnost dostopa do takšnih storitev preko mobilnega telefona [2]. Računalništvo v oblaku torej lahko rešuje vprašanja in probleme v zvezi z uporabo nove generacije biometričnih tehnologij, hkrati pa ponuja nove možnosti uporabe obstoječih biometričnih sistemov in aplikacij.

## 2. BIOMETRIJA IN STORITVE V OBLAKU

### 2.1. Storitve v oblaku

Način uporabe programske in strojne opreme se je v zadnjem času zelo spremenil. Uporaba storitev nameščenih na lokalnih računalnikih in strežnikih se zmanjšuje, medtem, ko se vse več uporabljajo oblačne storitve. Oblačne storitve so nameščene na

strežnikih ponudnikov oblčnih storitev, kar je v nasprotju s tradicionalnim pristopom nameščanja opreme na lokalne strežnike podjetja. Računalništvo v oblaku je načrtovano na način, da omogoča preprost in fleksibilen dostop do aplikacij, virov in različnih storitev. Storitve so največkrat nameščene v virtualnih okoljih in so v celoti vzdrževane s strani ponudnika. Uporabniki jih lahko dinamično prilagajajo glede na lastne potrebe. Ker ponudnik storitev priskrbi strojno in programsko opremo potrebno za pravilno delovanje, ni potrebe po lastni porabi virov za vzdrževanje. Primeri oblčnih storitev vključujejo spletna podatkovna skladišča (angl. online data storages), rešitve na področju varnostnih kopij, e-poštne storitve ipd. Bistvene prednosti, ki jih ta tehnologija prinaša so cenovna učinkovitost, skalabilnost, varnost, neodvisnost lokacije od naprave, varnostno kopiranje, redundanca.

## **2.2. Biometrični sistemi**

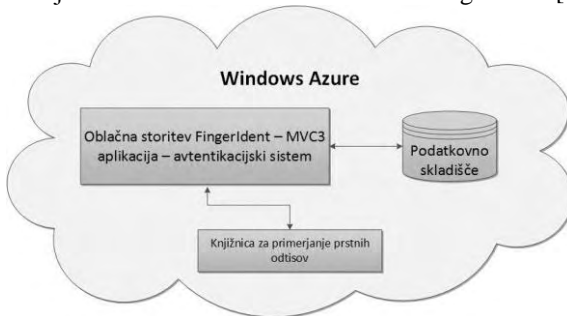
Biometrija se dandanes v svetu uveljavlja kot glavna metoda za identifikacijo in verifikacijo oseb. Ko govorimo biometriji, običajno mislimo na prstne odtise, obraz, šarenico, glas, hojo, podpis, itd. Biometrična identifikacija se nanaša na prepoznavanje posameznika na podlagi edinstvenih fizioloških ali vedenjskih značilnosti. V teoriji in praksi obstajata dva tipa biometričnih značilnosti. Prvi tip temelji na značilnostih, ki so pridobljene z direktnim fizičnim kontaktom z biometričnim čitalcem (npr. prstni odtis, vzorec šarenice itd.), medtem ko drugi tip ne zahteva fizičnega kontakta s čitalcem (npr. oblika obraza, glas itd.). V sistemih, kjer je zahtevana visoka stopnja varnosti, je identiteto osebe mogoče preverjati s kombinacijo več biometričnih metod, ob tem pa upoštevati stopnjo napake posamezne biometrične metode. Delovanje biometričnega sistema lahko razdelimo na dva glavna dela. To sta registracija uporabnika (ang. Enrollment) in proces identifikacije uporabnika (ang. Identification). V procesu registracije se s pomočjo biometrične naprave zajamejo podatki, v naslednji fazi pa se preveri kvaliteta zajetega vzorca. Če je kvaliteta ustrežna, se v zajetem vzorcu poiščejo značilnosti, ki se shranijo v bazo. V procesu identifikacije se na zajetem vzorcu poiščejo značilnosti, ki se primerjajo s tistimi, ki so shranjeni v bazi. Uporabnik se uspešno identificira, ko pride do ujemanja vzorcev [3].

Medtem, ko je osnovna zgradba biometričnih sistemov bolj ali manj enaka na vseh platformah (in različnih biometričnih modalnostih), vseeno obstajajo aspekti, ki so specifični za oblčne platforme. Ti aspekti in opis takšne rešitve so podani v naslednjem poglavju.

## **2.3. Oblčna biometrična storitev FingerIdent**

Kot smo izpostavili že v prejšnjem poglavju, imajo biometrični sistemi v oblaku nekaj specifičnih lastnosti v primerjavi s tradicionalnimi biometričnimi sistemi. Kot prvo, biometrični motor je lociran v oblaku in ne na kakšni lokalni enoti, kot je to značilno za tradicionalne biometrične sisteme za kontrolo dostopa. Ta karakteristika omogoča, da je biometrična tehnologija dostopna od kjerkoli in ponuja možnosti za integracijo v katerokoli aplikacijo, ki ima dostop do interneta. Kot drugo, hranjenje biometričnih podatkov v oblaku naredi sistem zelo skalabilen in omogoča hitro ter zanesljivo


prilagoditev tehnologije ob širitvi baze uporabnikov [2]. V nadaljevanju poglavja predstavljamo delovanje biometrične storitve v oblaku – FingerIdent [3].



Slika 1 - Arhitekturna zgradba oblachne storitve FingerIdent.

Oblachna storitev FingerIdent teče kot .NET spletna storitev in je integrirana v oblachno platformo Microsoft Windows Azure [6], ki je oblachna platforma tipa PaaS. Poganja jo operacijski sistem Windows Azure, ki služi kot osnova vsem aplikacijam in zagotavlja storitve, potrebne za razvoj, upravljanje in gostovanje aplikacij. Za implementacijo smo uporabili ogrodje MVC3, predvsem zaradi enostavne integracije v oblachno platformo Windows Azure. V aplikacijo smo vgradili lastno knjižnico za primerjanje oseb na podlagi prstnega odtisa in implementirali ustrezno logiko za interakcijo z zunanjimi storitvami [3]. Pri tem smo med drugim morali zagotoviti tudi ustrezno kodiranje za prenos podatkov preko omrežja. Arhitekturna zgradba rešitve je predstavljena sliki 1.

Posamezni koraki procesiranja prstnega odtisa, ki so izvedeni s pomočjo knjižnice za primerjanje odtisov so predstavljeni na sliki 2. V prvi fazi se prstni odtis zajame in loči od ozadja. Nato se izvedeta binarizacija in izboljšanje kvalitete slike. V drugi fazi se grebeni prstnega odtisa stanjšajo na en slikovni element, poiščejo se singularne točke, na koncu pa se izvede iskanje ujemanja.



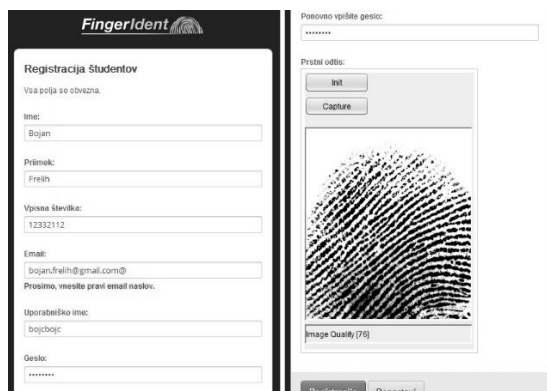
Slika 2 – Koraki procesiranja prstnega odtisa – 1) zajem odtisa, 2) segmentacija, 3) binarizacija in izboljšava kvalitete, 4) tanjšanje grebenov, 5) iskanje singularnih točk, 6) iskanje ujemanja.

Proces verifikacije poteka tako, da uporabnik na spletni strani, ki za avtentikacijo uporablja biometrično storitev FingerIdent, najprej vpiše uporabniško ime in zajame prstni odtis. Spletna aplikacija nato pošlje kodirano sliko oblačni storitvi v oblaku, ki sprocesa sliko (slika 2) in spletni aplikaciji sporoči rezultate ujemanja. Varnost predstavljene storitve je zagotovljena na več nivojih in sicer z uporabo HTTPS protokola za prenos podatkov, z uporabo certifikatov, z enkripcijo biometričnih značilnk v podatkovni bazi, itd. Storitve je zasnovana modularno, kar pomeni, da so potencialne nadgradnje v smislu dodajanja novih biometričnih metod enostavne.

### 3. RAZVOJ OBLAČNE APLIKACIJE ZA KONTROLO PRISTOPA

Da bi lažje predstavili uporabnost biometrične storitve v oblaku smo razvili koncept aplikacije za kontrolo pristopa – AccessControlManagement, ki s pomočjo oblačnega sistema za verifikacijo beleži prisotnost študentov na predavanjih [5]. Identifikacija in verifikacija velikega števila ljudi v kratkem času je za človeka skoraj neizvedljiva naloga, medtem ko takšna aplikacija omogoča hitro in zanesljivo verifikacijo. Prednosti tako zasnovanega sistema, so v tem, da je vse skupaj nameščeno v oblaku in deluje neodvisno od prostora.

Aplikacijo sestavljata uporabniški in administrativni modul, kot je prikazano na sliki 4. Uporabniški modul je namenjen študentom in vsebuje formi za registracijo in prijavo (slika 3). Oba postopka se opravita s pomočjo bralnika prstnih odtisov in oblačne storitve FingerIdent. Administrativni modul uporabljajo profesorji. Njegov glavni namen je vpogled v statistiko o prisotnosti posameznih študentov pri posameznih predmetih in generiranje poročil.




Slika 3 - Registracija študenta v sistemu za kontrolo dostopa AccessControlManagement [5].

Zgradbo sistema bi lahko ločili na krmilnike, modele oz. logično plast in poglede. Vsaka zahteva, ki pride v sistem požene krmilnik, ki ji pripada. Ob zagonu krmilnika se najprej opravi inicializacija sistema, nato pa obdelava zahteve. Ta se v celoti izvede v krmilniku. Po končani obdelavi podatkov je te potrebno predstaviti še vizualno. To je naloga



pogledov. Preusmeritev na posamezen pogled se opravi s klicem posebne metode krmilnika. Dinamična vsebina pogledov je zapolnjena s spremenljivkami pogleda, ki se prav tako, pred klicem funkcije za preusmeritev, definirajo v krmilniku.



Slika 4 - Arhitekturna zgradba aplikacije AccessControlManagement [5].

Z izdelavo aplikacije smo dosegli večjo stopnjo zaščite proti goljufanju oz. ponarejanju identitet in avtomatizacijo procesa preverjanja prisotnosti študentov. Poleg tega pa aplikacija nudi konstanten vpogled v statistiko in možnost generiranja poročil.

#### 4. REZULTATI


Razviti koncept smo testirali pri enem izmed predmetov na Fakulteti za računalništvo in informatiko, Univerze v Ljubljani. Sodelovalo je 18 študentov, katerih prisotnost se je beležila s pomočjo aplikacije za kontrolo pristopa AccessControlManagement in biometrične storitve v oblaku FingerIdent.

Postopek verifikacije je bil takšen, da se je vsak študent, ki je bil prisoten na predavanjih verificiral preko profesorjevega računalnika. Aplikacija je konec predavanja generirala


poročila, ki jih je profesor dobil po e-pošti. V poročilu je vidna statistika za vsakega študenta posebej, kakor tudi povzetek prisotnosti študentov v celotnem obdobju predavanj. Povzetek poročila o prisotnosti študentov pri predavanju je prikazan na sliki 5 in 6 ter v tabeli 1. Iz grafa na sliki 5 je vidno, da je bila udeležba na predavanjih na začetku skoraj 100%, potem pa je postopoma začela padati, medtem ko se iz statistike na tabeli 1 enostavno določi, kdo je zadostil pogojem prisotnosti pri predmetu (npr. vsaj 70% udeležba na predavanjih). Na sliki 6 je predstavljen skupni delež sprejetih, zavrnjenih in manjkajočih prijav.

Tabela 1 - Primer tabelarične statistike prisotnosti študentov pri predmetu.

Ime in Priimek	Vpisna številka	Prisotnost (%)
Jože Novak	123456	30%
Miha Novak	123457	70%
Luka Novak	123458	100%
Nejc Novak	123459	90%



Slika 5 - Graf prisotnosti študentov na posameznih predavanjih.



Slika 6 - Skupni delež sprejetih, zavrnjenih in manjkajočih prijav.

## 5. ZAKLJUČEK

Biometrične storitve v oblaku imajo zelo velik tržni potencial in prav zato privabljajo interes številnih raziskovalcev in razvojnih ekip iz celega sveta. V tem članku smo predstavili koncept prenosa obstoječe biometrične tehnologije v oblak in predstavili primer uporabe takšne storitve v aplikaciji za preverjanje prisotnosti. Aplikacija za preverjanje prisotnosti z uporabo biometrije nudi višjo stopnjo zaščite in hkrati avtomatizira proces beleženja prisotnosti.

Storitev biometrične verifikacije v oblaku bi bila zelo uporabna predvsem v sistemih, kjer je zahtevana povečana stopnja varnosti, kot recimo v spletnem bančništvu, v raznih trgovnih platformah ali v aplikacijah javne uprave, kjer se nahaja veliko število osebnih podatkov.

## LITERATURA

- [1] D. Balfanz et al., "The future of authentication", *IEEE Security & Privacy*, vol. 10, str. 22-27, 2012.
- [2] E. Kohlwey, A. Sussman, J. Trost, and A. Maurer, "Leveraging the Cloud for Big Data Biometrics: Meeting the performance requirements of the Next Generation Biometric Systems," in *Proceeding of the IEEE World Congress on Services*, str. 597-601, 2011.
- [3] P. Peer, J. Bule, J. Žganec-Gros, V. Štruc. "Building cloud-based biometric services". *Informatica*, vol. 37, no. 1, str. 115-122. 2013.
- [4] H. Vallabhu and R.V. Satyanarayana, "Biometric Authentication as a Service on Cloud: Novel Solution," *International Journal of Soft Computing and Engineering*, vol. 2, str. 163-165, 2012.
- [5] Đ. Kesić, "Oblačna spletna aplikacija za podporo sistemu za verifikacijo na podlagi prstnega odtisa", diplomsko delo na univerzitetnem študiju, Fakulteta za računalništvo in informatiko Univerze v Ljubljani, Slovenija, 2013.
- [6] M. Tulloch, "Introducing Windows Azure", Microsoft Press, ZDA, 2013.

# NETOPIRJI, KRESNICE IN KUKAVICE PRI OBDELAVI SLIK

Iztok Fister Jr., Dušan Fister, Uroš Mlakar, Karin Ljubič, Janez  
Brest, Iztok Fister

Univerza v Mariboru

Fakulteta za elektrotehniko, računalništvo in informatiko

E-pošta: iztok.fister2@uni-mb.si

---

**POVZETEK:** Znanstveniki so vedno iskali vzor za reševanje najtežjih problemov, ki se pojavljajo na področju računalništva, matematike in industrije, v naravi. Narava ponuja različne smeri in poti za razvoj novih algoritmov. Dandanes se pojavlja veliko različnih algoritmov po vzorih iz narave, ki jih v splošnem lahko razdelimo v tri kategorije. Prva skupina algoritmov temelji na Darwinovi teoriji boja za obstanek, v drugo skupino spadajo algoritmi temelječi na obnašanju inteligence rojev ter drugih bioloških sistemov in zadnja skupina so algoritmi, ki delujejo po principih fizikalnih ali kemijskih procesov in celo po vzorih iz družboslovnih znanosti. Te vrste algoritmov so se v zadnjem času začele uporabljati tudi za reševanje problemov na področju obdelave slik. Ta članek obravnava najpomembnejše aplikacije algoritmov inteligence rojev novejšega datuma, kot npr. algoritmi na snovi obnašanja netopirjev, kresnic in kukavic, pri obdelavi slik.

---

## 1. UVOD

Računalniški strokovnjaki so se v zadnjih letih pri reševanju najtežjih problemov, s katerimi se soočajo vsakodnevno, vse bolj zatekali k vzorom iz narave. Večina naravnih procesov je v osnovi optimizacijskih, zato lahko modeliranje teh procesov na digitalnih računalnikih predstavlja osnovo za razvoj učinkovitih algoritmov za reševanje najtežjih problemov v realnem svetu. Z začetkom v 50 letih prejšnjega stoletja pa vse do danes je tako nastalo veliko algoritmov, ki temeljijo na vzorih iz narave.

Najpomembnejši predstavniki te vrste so prav gotovo evolucijski algoritmi [10], ki posnemajo Darwinovo teorijo boja za obstanek [11]. Po tej teoriji imajo največ možnosti za obstanek in razvoj tisti posamezniki, ki so najbolj prilagojeni pogojem v okolju. V devetdesetih letih prejšnjega stoletja so se tej družini algoritmov pridružili tudi algoritmi, ki temeljijo na kolektivnem obnašanju žuželk (npr. mravlje, čebele, termiti, ipd.) in socialnih vrst živali (npr. jate ptičev, rib, delfinov, ipd.). Posebnost teh živalskih vrst je, da je njihova eksistenca odvisna od relativno enostavnih posameznikov, ki so sposobni avtonomnega izvajanja enostavnih akcij, vendar pa pri reševanju kompleksnejših opravil

znajo stopiti skupaj in se za izpolnitev skupnih ciljev samo-organizirati. Primere takih samo-organizacij lahko najdemo tudi v človeški družbi, kjer so se npr. v starem Egiptu, 4.000 let pred našim štetjem, organizirali sužnji pri gradnji veličastnih piramid. Ta decentralizacija in samo-organizacija socialnih vrst žuželk in živali sta postali osnovi za nastanek algoritmov na osnovi obnašanja inteligence rojev. Prvi je izraz inteligence rojev uporabil Beni leta 1989 [12]. Vzor za reševanje težkih problemov pa poleg biologije predstavljajo tudi druge naravoslovne znanosti, kot npr. kemija in fizika (npr. simulirano ohlajanje [16], črne luknje [15]), in nekatere družboslovne znanosti (npr. anarhična družba) ter celo glasba (npr. iskanje harmonij (*angl. Harmony Search*, krajše HS) [13]). Te tri skupine algoritmov so se uporabljale za reševanje velikega števila realnih problemov, kot so npr. reševanje: problema trgovskega potnika, barvanja grafov, generiranja šolskih urnikov, podatkovnega rudarjenja in ostalih.

Omenjene vrste algoritmov so zelo uporabne tudi pri obdelavi slik. Različni avtorji so aplicirali te algoritme na različna področja obdelave slik, kot so npr. izboljšava, kompresija, in segmentacija slik ter razpoznavanje objektov. Na teh področjih se srečujemo s specifičnimi problemi, kot npr. kako z odstranitvijo šuma oz. spreminjanjem kontrasta izboljšati sliko. Pri reševanju takih problemov imamo opravka z različnimi algoritmi obdelave slik, katerih največjo težavo predstavlja njihova velika časovna zahtevnost.

V tem članku se osredotočamo na pregled algoritmov na osnovi inteligence rojev (natančneje algoritmov na osnovi obnašanja netopirjev, kresnic in kukavic), ki so jih razvili na področju obdelave slik. V ta namen podrobneje analiziramo več člankov s tega področja. Na podlagi te analize poskušamo algoritme, opisane v njih, klasificirati v različne kategorije, glede na vrsto problemov, ki jih rešujejo. Na osnovi te klasifikacije poskušamo napovedati, v katero smer bo šel razvoj teh algoritmov v prihodnosti.

Struktura tega članka je v nadaljevanju naslednja: v naslednjem poglavju na kratko opišemo probleme, s katerimi se soočamo na področju obdelave slik. V tretjem poglavju izpostavimo značilnosti inteligence rojev, ter opišemo glavne značilnosti in principe delovanje algoritmov netopirjev, kresnic in kukavic. Četrto poglavje je osredotočeno na pregled aplikacij, ki jih lahko najdemo na področju obdelave slik. V zaključku povzamemo glavne značilnosti našega opravljenega dela in napovemo možne smeri prihodnjega razvoja tega naglo razvijajočega se področja.

## **2. OBDELAVA SLIK**

Danes živimo v svetu, kjer se skoraj vsakodnevno srečujemo s signali, med katerimi so najbolj pogoste fotografije oz. videoposnetki. Razvitih je vedno več sistemov za analizo teh signalov, predvsem zaradi poenostavljanja, oz. avtomatizacije, nekaterih vsakdanjih opravil. Obdelava slik je področje, ki se ukvarja z analizo dvodimenzionalnih slik (2D) in se po navadi nanaša na digitalno obdelavo slik. Glavni cilj digitalne obdelave sliko je izluščiti pomembne informacije o sceni, ki je bila zajeta in jih na razumljiv način predstaviti človeku ali računalniku, ki te informacije uporablja za nadaljnje procesiranje.

Algoritmi, ki jih danes uporabljamo pri obdelavi slik, so razširjeni predvsem na področjih:

- računalniškega vida, kot npr.:
  - o industrijske proizvodnje,
  - o interakcije človek-računalnik (*angl. Human-Computer Interface*, krajše HCI).
- razpoznavanja obrazov,
- varne vožnje,
- zdravstva,
- računalniških iger,
- stiskanja slik,
- itd.

Računalniški vid je morda eno izmed najzanimivejših področij za raziskovalce, saj s pomočjo algoritmov računalniškega vida računalniki oz. stroji, ki ga uporabljajo, postajajo avtonomni sistemi. Zelo razširjeno aplikativno področje računalniškega vida je, t. i. strojni vid [25], kjer se zajete informacije iz slik uporabljajo za nadzor proizvodnih procesov, kot npr. nadzor kvalitete proizvodnje in izločanje nekakovostnih proizvodov, nadzor robotske roke, ipd. Računalniki so danes nepogrešljivo delovno orodje, zato postaja področje interakcije človeka z računalnikom vse pomembnejši predmet raziskav. Raziskovalci na tem področju skušajo razviti nove preproste načine za komunikacijo z računalnikom, kjer je v ospredje postavljeno intuitivno brez-kontaktno upravljanje. Primer take tehnologije je senzor Kinect [26], ki je sicer primarno namenjen za igranje računalniških iger, vendar je mogoče njegovo uporabo s pomočjo aplikacijskega vmesnika Microsoft relativno enostavno razširiti tudi na druga področja [27][28].

Zelo raziskano področje je tudi prepoznavanje obrazov, predvsem zaradi širokega aplikativnega področja. Danes je detektor obrazov vgrajen v skoraj vsako digitalno kamero in se uporablja za ostrenje zajete scene. Med drugim se za detekcijo obrazov zanimajo na področju marketinga, saj bi lahko s pomočjo vgrajene kamere razpoznali svoje kupce, njihovo starost in spol, ter na podlagi tega predvajali ustrezne oglase.

Novejše aplikativno področje obdelave slik je avtonomno vozilo oz. podporni sistemi za pomoč vozniku med vožnjo. Tukaj lahko uporabljamo senzorje za spremljanje koncentracije voznika pri vožnji, spremljanje nenadnih sprememb na cestišču, itd.

Eno izmed pomembnejših aplikativnih področij obdelave slik je zagotovo obdelava medicinskih slik. Zdravniki pogosto porabijo veliko časa za preglede različnih vrst medicinskih slik pacientov, zato bi jim postopki obdelave slik časovno precej skrajšali delo. Tukaj govorimo predvsem o procesiranju rentgenskih slik, angiogramov, ultrazvoka, ipd., za namene diagnosticiranja pacientov (npr. detekcije tumorjev, arterioskleroze, itd.). Na področju obdelave medicinskih slik se v literaturi pojavlja

veliko algoritmov [29], ki še ne delujejo popolnoma avtomatsko, saj od uporabnika zahtevajo vhodne podatke, njihove rezultate pa trenutno lahko uporabimo zgolj le kot pomoč pri postavljanju diagnoz.

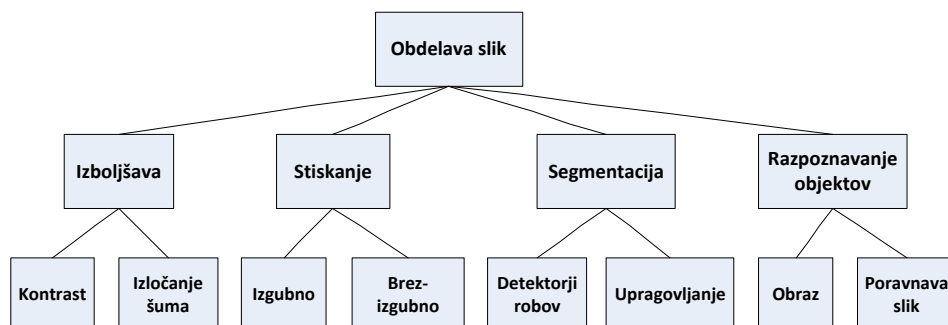
Z razvojem naprednih senzorjev za zajem slik v visoki ločljivosti se vzporedno pojavlja problem shranjevanja teh podatkov. S temi problemi se spopadajo raziskovalci na področju stiskanja slik. Algoritmi stiskanja slik v veliki meri iščejo redundanco v podatkih oz. skušajo surove podatke, zajete s senzorji, spraviti v kompaktno in predvsem manjšo obliko. Največja težava, s katero se srečujejo na tem področju je izguba informacij, ki jo vnašajo nekateri algoritmi stiskanja.

V nadaljevanju razdelimo domeno obdelave slik na problemska področja, te pa na specifične probleme, s katerimi se soočamo na problemskih področjih. Domeno obdelave slik delimo na naslednja problemska področja in specifične probleme (slika 1):

- izboljšava:
  - o odstranjevanje šuma: zajete slike po navadi vsebujejo odvečne informacije, ki nas ne zanimajo, oz. nad lahko motijo pri kasnejšem procesiranju slike, zato jih moramo odstraniti. Za odstranjevanje šuma je bilo razvitih že veliko postopkov, med katerimi največkrat uporabljamo filtriranje (npr. mediana, nizko sito, itd).
  - o izboljševanje kontrastov: zajeta slika je lahko slabe kvalitete, kar lahko popravimo npr. z izenačevanjem histogramov.
- stiskanje:
  - o izgubno: pri stiskanju podatkov se nekatere informacije o sliki izgubijo. Izgubno stiskanje je primerno za uporabo pri fotografijah zajetih s fotoaparatom.
  - o brez-izgubno: pri stiskanju podatkov ne izgubljam informacij v sliki. Brez-izgubno stiskanje uporabljamo večinoma za arhiviranje, stiskanje medicinskih in tehničnih risb, itd.
- segmentacija: na sliki izločimo objekte, ki nas zanimajo, od ozadja. V to področje spadajo:
  - o detektorji robov,
  - o upragovljanje (*angl. thresholding*).
- razpoznavanje objektov:
  - o razpoznavanje obrazov,
  - o poravnava slik.

Težava, s katero se srečujemo pri odstranjevanju šuma, je posredno poslabšanje kvalitete slike, predvsem zaradi napačne izbire filtrov oz. njegovih parametrov. Največja težava pri stiskanju slik je učinkovito zmanjšanje velikosti datoteke, ne da bi pri tem sliko poslabšali (brez-izgubno), oz. da slika ne izgubi preveč informacij (izgubno). Pri segmentaciji slik je glavna težava, da ne obstaja splošen algoritem, ki bi ga lahko uspešno aplicirali na poljubni sliki in bi pri tem dosegli dobre rezultate. Prav tako se pri

segmentaciji pojavlja problem osvetlitve scene na sliki, kar lahko rezultate segmentacije dodatno poslabša.



Slika 1: Področja in problemi, s katerimi se običajno srečujemo v domeni obdelave slik.

### 3. INTELIGENCA ROJEV

Vzor za nastanek algoritmov inteligence rojev (*angl. Swarm Intelligence*, krajše SI) prihaja iz biologije [17], kjer so socializirane žuželke (npr. kolonije termitov, mravelj, čebel, ipd.) in nekatere vrste socializiranih živali (npr. jate ptic, rib, ipd.) sposobne opravljanja kompleksnih opravil v skupini, čeprav jim je narava kot posameznikom namenila avtonomno izvajanje samo preprostih operacij. Značilnost teh bitij je, da sama brez pomoči drugih članov v skupini ne bi preživela. Tudi človek je družbeno bitje, ki je v skupini sposoben opravljanja zelo kompleksnih nalog (npr. poleta na Luno).

Socializacija je pojav, kjer posamezniki živijo skupaj v istih bivališčih in se med seboj sporazumevajo. Razlogov za tako obnašanje posameznikov je običajno več, najpogosteje pa so vzroki za socializirano vedenje nekaterih naravnih bitij predvsem naslednji: iskanje hrane, gradnja skupnih bivališč, in razmnoževanje.

Termiti so, npr., razmeroma enostavna bitja, ki so v interakciji z drugimi člani kolonije sposobna gradnje veličastnih bivališč (termitnjakov). Mravlje in čebele živijo skupaj zaradi iskanja hrane. Pri tem se mravlje sporazumevajo med seboj posredno, s pomočjo kemične snovi feromona, katerega količina določa najkrajšo pot do hrane. Čebele komunicirajo med seboj s pomočjo plesa z mahanjem (*angl. waggle dance*), s katerim izvidniki (*angl. scout*) vabijo ostale čebele delavke (*angl. employed bees*) na področja bogata s hrano (nektarjem). Netopirji se orientirajo v prostoru s pomočjo fizikalnega pojava eho-lociranja. Kresnice pri razmnoževanju uporabljajo fizikalni pojav svetilnosti, kjer se svetilnost zmanjšuje s kvadratom razdalje med dvema posameznikoma. Svetlobo oddajajo samo moški posamezniki, in jo lahko občudujemo v toplih poletnih nočeh. Na to svetlobo se odzivajo samice godne za parjenje. Kukavice izkazujejo parazitsko vedenje, pri čemer v gnezda ostalih ptičev podtikajo svoja jajca, za katera ti skrbijo, kakor da bi šlo za njihova. Ptice selivke se pred nastopom zime selijo v toplejše kraje.



Algoritmi SI izkoriščajo vse te pojave za svoje delovanje. Tabela 1 prikazuje omenjene vrste socializiranih žuželk in živali skupaj s pojavi, ki omogočajo interakcijo med njimi, vzroki za njihovo socializirano obnašanje, algoritmi SI, ki delujejo na teh principih, in avtorji teh algoritmov.

Tabela 1: Najpomembnejši algoritmi SI in njihovi vzori iz narave

Vrsta	Interakcija	Social. vedenje	Algoritem SI	Vir
Termiti	Feromon	Iskanje hrane	TCO	[24]
Mravlje	Feromon	Iskanje hrane	ACO	[23]
Čebele	Ples z mahanjem	Iskanje hrane	ABC	[21]
Netopirji	Eho-lokacija	Orientacija v prostoru	BA	[20]
Kresnice	Svetilnost	Razmnoževanje	FA	[18]
Kukavice	Podtikanje jajc	Parazitsko vedenje	CS	[19]
Ptice selivke	Migracije	Kje živeti	PSO	[22]

Iz tabele 1 razberemo, da so najpomembnejši algoritmi SI naslednji: optimizacija s kolonijami termitov (*angl. Termite Colony Optimization*, krajše TCO), optimizacija s kolonijami mravelj (*angl. Ant Colony Optimization*, krajše ACO), optimizacija s kolonijami umetnih čebel (*angl. Artificial Bee Colony*, krajše ABC), algoritem na osnovi obnašanja netopirjev (*angl. Bat Algorithm*, krajše BA), algoritem na osnovi obnašanja kresnic (*angl. Firefly Algorithm*, krajše FA), kukavičje iskanje (*angl. Cuckoo Search*, krajše CS) in optimizacija s roji delcev (*angl. Particle Swarm Optimization*, krajše PSO). Čeprav gre za različne algoritme, pa imajo vsi podobno strukturo prikazano v psevdokodu algoritma 1.

```

1: inicializiraj_populacijo_z_nakljucnimi_delci;
2: ocena = oceni_vsak_delec;
3: while !zakljucni_pogoj do
4:     premakni_delec_proti_najboljsemu_posamezniku;
5:     ocena+=oceni_vsak_delec;
6:     izberi_najboljse_posameznike_za_naslednjo_generacijo;
7: end while

```

Algoritem 1: Psevdo-kod algoritma SI

Algoritem SI na gornji sliki začenja z inicializacijo populacije (vrstica 1), ki sestoji iz posameznikov (delcev). Nato izračunamo funkcijo uspešnosti, da bi dobili oceno kakovosti vsakega delca (vrstica 2). Osrednji del algoritma predstavlja zanka **while ... end while** (vrstice 3-7), ki generira novi delec z operacijo premika (vrstica 4), ga oceni (vrstica 5) in izbere najboljše delce za naslednjo generacijo (vrstica 6). Zanko zaključimo z ustavitvenim pogojem '!zakljucni\_pogoj' (vrstica 4), ki običajno konča optimizacijski proces po predvidenem številu izračunavanj funkcije uspešnosti.

Značilnost algoritma SI je, da je proces preiskovanja iskalnega prostora odvisen od najboljše rešitve v trenutni populaciji. Ta proces napreduje, dokler se ta najboljša rešitev izboljšuje, t.j. pri premikanju slabših rešitev proti najboljši v populaciji odkrivamo nove najboljše rešitve. Ko takih rešitev proces preiskovanja ne odkriva, ta ne napreduje več. V

tem primeru pravimo, da je prišlo do stagnacije oz. je proces preiskovanja padel v lokalni optimum.

V nadaljevanju članka se osredotočamo na algoritme na osnovi netopirjev, kresnic in kukavičjega iskanja.

## 2.1 Algoritem na osnovi obnašanja netopirjev

Algoritem na osnovi obnašanja netopirjev (*angl. Bat Algorithm*, krajše BA), katerega avtor je Xin-She Yang, je bil razvit leta 2010. Navdih za ta algoritem predstavljajo mikro-netopirji in njihov fizikalni pojav eho-lociranja, pri katerem netopirji med letenjem oddajajo zvočni signal, in poslušajo njegov odboj (eho), ki se odbija od ovir. Pri eho-lociranju so pomembni trije parametri: frekvenčno območje  $Q_i \in [Q_{\min}, Q_{\max}]$ , stopnja  $r_i \in [0,1]$  in glasnost  $A_i \in [A_0, A_{\min}]$  oddanega pulza. Frekvenca oddanega pulza je odvisna od velikosti žrtve, t.j. manjša kot je žrtev, višja je frekvenca. Stopnja pulza se povečuje, ko se netopir približuje svoji žrtvi. Glasnost je višja, ko so netopirji v lovu za žrtvami in nižja, ko se ti vračajo domov.

Obnašanje netopirjev pri eho-lociranju lahko modeliramo v optimizacijski algoritem, kjer to obnašanje zajamemo v funkciji uspešnosti optimizacijskega problema, ki ga rešujemo. Kakovost takega algoritma je seveda odvisna od odkrivanja novih rešitev v prostoru preiskovanja. Pri algoritmičnih SI generiramo nove rešitve s pomočjo operacije premika umetnih netopirjev po prostoru preiskovanja. Ta operacija izkorišča fizikalne zakone Dopplerjevega efekta, ki jih izrazimo z naslednjimi enačbami:

$$\begin{aligned} Q_i^{(t)} &= Q_{\min} + (Q_{\max} - Q_{\min})N(0,1), \\ v_i^{(t+1)} &= v_i^{(t)} + (x_i^{(t)} - best)Q_i^{(t)}, \\ x_i^{(t+1)} &= x_i^{(t)} + v_i^{(t+1)}, \end{aligned} \quad (1)$$

kjer  $N(0,1)$  označuje generirano naključno število iz Gaussove distribucije s povprečno vrednostjo nič in standardnim odklonom ena,  $\mathbf{v} \in \{v_i\}$  je hitrost premika, in  $\mathbf{x}_i \in \{x_{ij}\}$  populacija umetnih netopirjev.

Med preiskovanjem lahko glasnost  $A_i^{(t)}$  in stopnjo  $r_i^{(t)}$  oddanega pulza spreminjamo. V naravi se glasnost netopirjev zmanjšuje in stopnja oddanih pulzov povečuje, ko netopirji najdejo svoje žrtve. To značilnost izrazimo v algoritmu BA z naslednjo enačbo:

$$A_i^{(t+1)} = \alpha A_i^{(t)}, \quad r_i^{(t)} = r_i^{(0)} [1 - \exp(-\gamma \varepsilon)], \quad (2)$$

kjer sta  $\alpha$  in  $\gamma$  konstanti.

## 2.2 Algoritem na osnovi obnašanja kresnic

Kresnice oddajajo čudovito svetlobo, ki jo lahko občudujemo v jasnih poletnih nočeh. Produkt te svetlobe je plod zapletene biokemijske reakcije bioluminiscenca. Namen svetlikanja teh žuželk je dvojen, saj služi tako iskanju partnerjev, kakor tudi kot obrambni mehanizem, ki jih varuje pred plenilci. Obnašanja kresnic je navdihnilo avtorja Xin-She Yang [12][31][32], da je, leta 2010, razvil algoritem na osnovi obnašanja kresnic (*angl. Firefly Algorithm*, krajše FA).

Tudi v tem primeru je omenjeni pojav pri obnašanju kresnic zajet v funkciji uspešnosti. Operator premika umetnih kresnic po prostoru preiskovanja sloni na fizikalnem zakonu svetilnosti  $I$ , ki se zmanjšuje s kvadratom razdalje  $r^2$  od svetlobnega vira. Z razdaljo od svetlobnega vira se povečuje tudi absorpcija svetlobe, ki povzroči, da svetloba postaja vse šibkejša. Svetilnost izrazimo z naslednjo enačbo:

$$I(r) = I_0 \exp^{-\gamma r^2}, \quad (3)$$

kjer  $I_0$  označuje svetilnost svetlobnega vira in je  $\gamma$  fiksni absorpcijski koeficient svetlobe. Atraktivnost kresnic  $\beta$  je proporcionalna njihovi svetilnosti  $I(r)$  in jo glede na enačbo (3) lahko izrazimo kot:

$$\beta = \beta_0 \exp^{-\gamma r^2}, \quad (4)$$

kjer je  $\beta_0$  atraktivnost pri  $r = 0$ . Razdaljo med dvema kresnicama  $\mathbf{x}_i$  in  $\mathbf{x}_j$  izrazimo z Evklidsko razdaljo kot:

$$r_{ij} = \sqrt{\sum_{k=1}^n (x_{ik} - x_{jk})^2}, \quad (5)$$

kjer  $n$  označuje velikost problema. Premikanje  $i$ -te kresnice privlači atraktivnejša kresnica  $j$  po naslednji enačbi:

$$\mathbf{x}_i = \mathbf{x}_i + \beta_0 \exp^{-\gamma r_{ij}^2} (\mathbf{x}_j - \mathbf{x}_i) + \alpha \varepsilon_i, \quad (6)$$

kjer je  $\varepsilon_i$  naključno število iz Gaussove distribucije in  $\alpha \in [0,1]$  naključno število iz uniformne distribucije.

## 2.3 Kukavičje iskanje

Kukavičje iskanje (*angl. Cuckoo Search*, krajše CS) je algoritem inteligence rojev, ki sta ga razvila, leta 2009, Xin-She Yang in Suash Deb [13][14][30]. Navdih za razvoj tega algoritma prihaja iz obnašanja kukavic v naravi. Kukavice so živali, ki izkazujejo parazitsko vedenje, saj samice odlagajo jajca v gnezda od ostalih ptic.

Avtorja sta definirala algoritem na naslednji način: vsako jajce v gnezdu predstavlja rešitev, medtem ko kukavičje jajce predstavlja novo rešitev. Te rešitve so po navadi

predstavljene kot vektorji realnih števil. Obstajajo pa tudi druge predstavitve, npr. binarna predstavitev. Namen kukavičjega iskanja je uporaba in raziskovanje novih boljših rešitev, z namenom zamenjave najslabših rešitev v gnezdih.

Ta algoritem poskuša uravnovežiti lokalno naključno iskanje, ki izkorišča pridobljeno znanje v populaciji, z globalnim naključnim iskanjem z namenom preiskovanja novih področij v preiskovalnem prostoru. Preklop med obema vrstama preiskovanja reguliramo s parametrom  $p_\alpha$ . Lokalno naključno iskanje matematično izrazimo kot:

$$\mathbf{x}_i^{(t+1)} = \mathbf{x}_i^{(t)} + \alpha s \otimes H(p_\alpha - \varepsilon) \otimes (\mathbf{x}_j^{(t)} - \mathbf{x}_k^{(t)}), \quad (7)$$

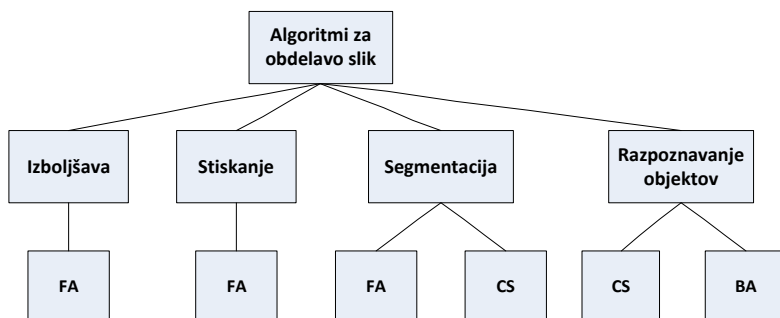
kjer sta  $\mathbf{x}_j^{(t)}$  in  $\mathbf{x}_k^{(t)}$  naključno izbrani rešitvi v populaciji,  $H(u)$  je funkcija Heaviside,  $\varepsilon \in [0,1]$  naključno število iz uniformne distribucije, in  $s$  je velikost koraka. Globalno naključno iskanje uporablja distribucijo Levi flights in generira novo rešitev po naslednji enačbi:

$$\mathbf{x}_i^{(t+1)} = \mathbf{x}_i^{(t)} + \alpha L(s, \lambda), \quad (8)$$

kjer  $L(s, \lambda)$  označuje naključno generirano število iz distribucije Levi flights.

## 4. APLIKACIJE

Namen tega članka je narediti podrobnejši pregled del, ki se ukvarjajo z aplikacijo algoritmov SI na področju obdelave slik. Pri tem so nas zanimali predvsem algoritmi novejšega datuma, t.j. BA, FA in CS. Čeprav je uporaba uveljavljenih algoritmov SI, kot npr. PSO, ABC in ACO, na tem področju zelo pogosta, ugotavljamo, da se novejši algoritmi SI tukaj še niso povsem uveljavili. Tukaj smo odkrili samo 9 člankov, ki rešujejo probleme obdelave slik z algoritmi BA, FA in CS. Po drugi strani pa so jih avtorji aplicirali že na večino problemov, ki nastopajo na tem področju (slika 2).



Slika 2: Implementacije algoritmov BA, FA in CS na področjih obdelave slik.

Iz slike 2 lahko ugotovimo, da z algoritmi BA, FA in CS rešujemo dandanes že praktično večino problemov, ki se pojavljajo na problemskih področjih domene obdelave slik. Največkrat se pri obdelavi slik pojavi algoritem FA, katerega so avtorji uporabili pri reševanju problemov iz področij izboljšave, stiskanja in segmentacije slik. Algoritem CS

je prisoten tudi pri segmentaciji slik in razpoznavanju objektov, medtem ko algoritem BA za enkrat uporabljamo samo pri razpoznavanju objektov.

Uporabo algoritmov BA, FA in CS na problemih obdelave slik prikazuje tabela 2.

Tabela 2: Uporaba algoritmov BA, FA in CS na problemih obdelave slik

Problem	Avtorji	Alg.	Ref.
Upragovljene s pomočjo entropije	Horng in Liou	FA	[1]
Izgubno stiskanje slik	Horng in Jiang	FA	[2], [3]
Izboljšava kontrastov v sliki	Hassanzadeh in ostali	FA	[4]
Segmentacija slik - upragovljanje	Hassanzadeh in ostali	FA	[5]
Večnivojsko upragovljenje slik	Brajevic in ostali	FA, CS	[6], [7]
Razpoznavanje obrazov	Tiwari	CS	[8]
Poravnava slik	Zhang in Wang	BA	[9]

Novejši algoritmi SI, t.j. BA, FA in CS, rešujejo večino problemov domene obdelave slik, ki smo jih navedli v sliki 1. Iz tabele 2 je razvidno, da največ problemov ponovno rešujemo z algoritmom FA. To dejstvo ne preseneča, saj je ta algoritem tudi najstarejši med opazovanimi. Po drugi strani pa je algoritem BA, najmlajši med njimi, uporabljen samo na problemu poravnave slik.

## 4. ZAKLJUČEK

V članku smo predstavili pregled uporabe novejših algoritmov SI, t.j. BA, FA in CS, na problemih iz domene obdelave slik. Podrobnejša analiza stanja tega področja je pokazala, da obstaja malo rešitev s to vrsto algoritmov, po drugi strani pa smo z njimi poskušali reševati že večino problemov iz te domene. Uporaba omenjenih algoritmov se je v praksi pokazala kot uspešna, rezultati obdelave slik pa so primerljivi s 'state-of-the-art' algoritmi iz te domene.

Glavni namen članka je seznaniti bralce z možnostmi uporabe teh novodobnih algoritmov v domeni obdelave slik in signalov. Po eni strani so ti algoritmi zelo enostavni za implementacijo, po drugi strani pa dovolj zmogljivi in hitri za uporabo v praksi. V prihodnosti lahko pričakujemo razvoj večjega števila aplikacij, ki bodo uporabljale omenjene algoritme po vzorih iz narave in se uspešno spopadale s problemi na področjih obdelave slik.

## LITERATURA

1. M. Horng, R. Liou (2011), Multilevel minimum cross entropy threshold selection based on the firefly algorithm, *Expert Systems with Applications* vol. 38 (12), str. 14805–14811.

2. M. Horng, T. Jiang (2010), The codebook design of image vector quantization based on the firefly algorithm, *Computational Collective Intelligence Technologies and Applications*, str. 438–447.
3. M. Horng (2012), Vector quantization using the firefly algorithm for image compression, *Expert Systems with Applications*, vol. 39 (1), str. 1078–1091.
4. T. Hassanzadeh, H. Vojodi, F. Mahmoudi (2011), Non-linear grayscale image enhancement based on firefly algorithm, in: B.K. Panigrahi, P.N. Suganthan, S. Das, S.C. Satapathy (Eds.), *Swarm, Evolutionary, and Memetic Computing*, Springer, str. 174–181.
5. T. Hassanzadeh, H. Vojodi, A. Moghadam (2011), An image segmentation approach based on maximum variance intra-cluster method and firefly algorithm, *The Seventh International Conference on Natural Computation*, vol. 3, IEEE, str. 1817–1821.
6. I. Brajevic, M. Tuba, N. Bacanin, (2012), Multilevel image thresholding selection based on the cuckoo search algorithm. In: *Proceedings of the 5th International Conference on Visualization, Imaging and Simulation (VIS'12)*, Sliema, Malta, str. 217–222.
7. I. Brajevic, M. Tuba (2014) , Cuckoo search and firefly algorithm applied to multilevel image thresholding, *In Studies in Computational Intelligence*, vol. 516, str. 115–139.
8. V. Tiwari (2012): Face recognition based on cuckoo search algorithm, *Indian Journal of Computer Science and Engineering*, vol. 3 (3), str. 401–405.
9. J. W.Zhang, G. G. Wang (2012), Image Matching Using a Bat Algorithm with Mutation, *Applied Mechanics and Materials*, vol. 203, str. 88–93.
10. A. Eiben, J. Smith (2003), *Introduction to Evolutionary Computing*. Berlin: Springer-Verlag.
11. C. Darwin (1859). *On the Origin of Species*. London: Harvard University Press (1964).
12. G. Beni, J. Wang (1989), Swarm Intelligence in Cellular Robotic Systems, *Proceedings of NATO Advanced Workshop on Robots and Biological Systems*, str. 26 – 30
13. Z. W. Geem (2012), *Recent Advances in Harmony Search Algorithm*. Berlin: Springer-Verlag.
14. I. Fister Jr., D. Fister, I. Fister (2013), A Comprehensive review of cuckoo search: variants and hybrids, *Int. J. Mathematical Modeling and Numerical Optimisation*, vol. 4 (4), str. 387–409.
15. A. Hatamlou (2013): Black hole: A new heuristic optimization approach for data clustering. *Information Sciences*, vol. 222, str. 175–184.
16. S. Kirkpatrick, C. J. Gellat, M. Vecchi (1983), Optimization by Simulated Annealing, *Science*, vol. 220(4578), str. 671–680.
17. C. Blum, D. Merkle (2008), *Swarm Intelligence*. Berlin: Springer-Verlag.

18. X.-S Yang (2008), Firefly Algorithm. V X.-S. Yang, Nature-Inspired Metaheuristic Algorithms, London, UK: Luniver Press, str. 79–90.
19. X.-S. Yang, S. Deb (2009), Cuckoo Search via Levy Flights. *World Congress & Biologically Inspired Computing*, str. 210–214.
20. X.-S. Yang (2010), A New Metaheuristic Bat-inspired Algorithm. V C. Cruz, J. Gonzales, G. Krasnogor, & D. Pelta, Nature Inspired Cooperative Strategies for Optimization (NISCO 2010), Springer-Verlag: Berlin, str. 65–74.
21. D. Karaboga, B. Bastruk (2007), A Powerful and Efficient Algorithm for Numerical Function Optimization: Artificial Bee Colony (ABC) Algorithm, *Journal of Global Optimization*, vol. 39(3), str. 459–471.
22. J. Kennedy, R. Eberhart (1999), The Particle Swarm Optimization; Social Adaptation in Information Processing. V D. Corne, M. Dorigo, & F. Glover, New Ideas in Optimization, London, UK: McGraw Hill, str. 379–387.
23. M. Dorigo, G. Di Caro (1999), The Ant Colony Optimization Meta-heuristic. V D. Corne, M. Dorigo, & F. Glover, New Ideas in Optimization, London, UK: McGraw Hill, str. 11–32.
24. R. Hedayatzadeh, F.A. Salmassi, M. Keshtgari, R. Akbari, K. Ziarati (2010), Termite colony optimization: A novel approach for optimizing continuous problems. *V 18th Iranian Conference on Electrical Engineering (ICEE)*, str. 553–558.
25. M. Sonka, V. Hlavac, R. Boyle (2008), Image Processing, Analysis, and Machine Vision, Second Edition.
26. Kinect. From Wikipedia, the free encyclopedia. Pridobljeno s <http://en.wikipedia.org/wiki/Kinect>, dne 1.2.2014.
27. K. Khoshelham, S. O. Elberink (2012), Accuracy and Resolution of Kinect Depth Data for Indoor Mapping Applications. *Sensors*, vol. 12, str. 1437–1454.
28. Z. Ren, J. Meng, J. Yuan (2011), Depth Camera Based Hand Gesture Recognition and its Applications in Human-Computer-Interaction, *Proc. of 8th International Conference on Information, Communication and Signal Processing*, str. 1–5.
29. D. L. Pham, C. Y. Xu, J. L. Prince (2000), Current methods in medical image segmentation, *Annual review of biomedical engineering*, vol. 2, str. 315–337.
30. I. Fister Jr., X.-S. Yang, D. Fister, I. Fister (2014), Cuckoo search: A brief literature review, V Cuckoo search and firefly algorithm, str. 49–62.
31. I. Fister, X.-S. Yang, D. Fister, I. Fister Jr. (2014), Firefly algorithm: A brief Review of the expanding literature, V Cuckoo search and firefly algorithm, str. 347–360.
32. I. Fister, I. Fister Jr., X.-S. Yang, J. Brest (2013), A comprehensive review of firefly algorithms, *Swarm and Evolutionary Computation*, vol. 13, str. 34–46.

# UPORABA AKTIVNIH KONTUR ZA SEGMENTACIJO UDARNIH VALOV V NIZKOKONTRASTNI KOHERENTNI SENČNI FOTOGRAFIJI

**Jaka Pribošek, Peter Gregorčič, Janez Diaci**

**Katedra za optodinamiko in lasersko tehniko  
Fakulteta za strojništvo, Univerza v Ljubljani  
E-pošta: jaka.pribosek@fs.uni-lj.si**

---

**POVZETEK:** Članek predstavlja avtonomen sistem hitre senčne fotografije, zmožen samodejnega zajemanja in obdelave velikega števila posnetkov udarnih valov. Za potrebe obdelave zajetih slik predstavljamo metodo avtomatske segmentacije. Ta temelji na dvostopenjskem algoritmu z uporabo aktivnih kontur. V prvi stopnji grobe segmentacije uporabimo klasične kače, ki koristijo teksturne značilnice. Rezultat grobe segmentacije udarnega vala se nato uporabi kot inicializacija sekundarne izboljšave detekcije z t.i. potratnimi kačami. Tu se kontura lokalno optimizira z ozirom na odzive usmerjenih filtrov za detekcijo robov in Bayesove formulacije za kombinacijo različnih značilnic. Predstavljeno metodo smo preizkusili na vzorcu 12 nizko kontrastnih senčnih fotografij in jih primerjali z rezultati ročne segmentacije. Dobljeni rezultati kažejo na izredno robustnost algoritma in visoko točnost.

---

## 1. UVOD

Študij udarnih valov je velikega pomena na različnih področjih fizike in medicine [1]. Za globlje razumevanje fizike udarnih valov in njihovih interakcij z materiali so še zlasti pomembne: študije optodinamske učinkovitosti energetske pretvorbe [2], izpeljava enačb stanja [3] in potrjevanje analitičnih in numeričnih modelov udarnih valov [4]. V preteklih letih je bilo uporabljenih več različnih sistemov za spremljanje udarnih valov, vključujoč Schlieren [5], [6], in bliskovno senčno fotografijo [7]. Z obema metodama je možno opazovanje variacij lomnega količnika medija [8], ki jih povzročajo udarni valovi. Kontrast tako posnetih slik je odvisen od razlike v lomnem količniku, zato so tovrstne metode primernejše za preučevanje v trdnih snoveh in tekočinah. V plinih, kjer so razlike lomnega količnika bistveno manjše kot v trdnem stanju ali tekočinah, pa imajo senčne slike izredno nizek kontrast. Opazovanje udarnih valov v plinih je zato zahteven problem. Nedavne izboljšave obstoječih Schlieren sistemov z namenom povečanja občutljivosti in zagotavljanja slik z višjimi kontrasti [9] kažejo na aktualnost problema. Kljub temu ostajajo tovrstne študije redke.

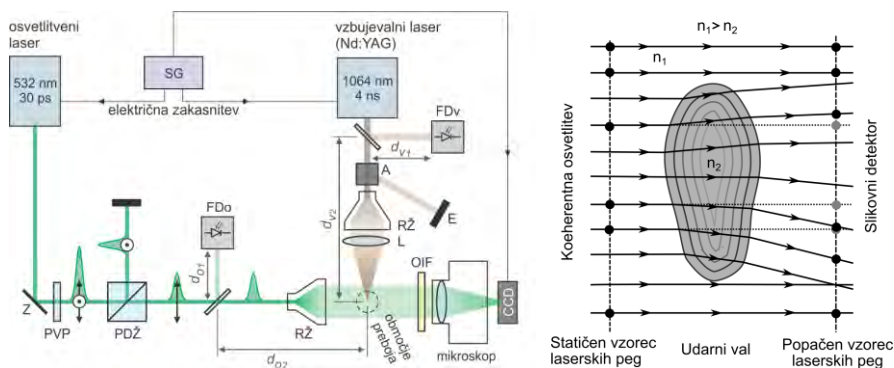
Nedavno smo poročali o avtomatiziranem in računalniško krmiljenem sistemu za eksperimentalni študij lasersko inducirane plazme in udarnih valov [10]. Sistem ima možnost zajemanja velikega nabora slik udarnih valov z dobro časovno in prostorsko ločljivostjo, ki je pomembna za temeljito potrjevanje analitičnih in numeričnih modelov. Ozko grlo pri obdelavi podatkov, zajetih s tem sistemom, predstavlja ročna segmentacija



udarnih valov [10], kar pomembno ovira ustvarjanje velike baze podatkov. Da bi odpravili to oviro, razvijamo avtomatizirano detekcijo udarnih valov, temelječo na obdelavi slik. Trenutno v dostopni literaturi ni moč najti temeljite študije o avtomatizirani obdelavi slik udarnih valov in detekciji le-teh. Širok spekter enostavnejših prijemov zadostuje potrebam segmentacije visoko-kontrastnih slik [11], pri čemer se v praksi izkaže, da ti algoritmi ne zadoščajo v primeru segmentacije nizkokontrastnih slik. Glavni cilj tega članka je tako rešiti segmentacijski problem v primeru nizko kontrastnih senčnih fotografij.

## 2. EKSPERIMENTALNI SISTEM

Sistem za hitro bliskovno senčno fotografijo je shematsko prikazan na sl. 1 levo. Eksperimentalni sistem je podrobneje opisan drugje [7,10], zato ga bomo tukaj le na kratko predstavili. Preboj v zraku povzročimo z Nd:YAG laserjem s preklopom kvalitete ( $\lambda = 1064 \text{ nm}$ , Brio, Quantel). Poskusi so bili izvedeni pri trajanju vzbujevalnega bliska 4 ns in energiji bliskov  $12.7 \text{ mJ} \pm 0.5 \text{ mJ}$ . Energijo bliskov smo izmerili z energometrom (E) po izhodu bliska iz atenuatorja (A). Blisk nato razširimo z razširjevalnikom žarka (RŽ) in ga z lečo (L) zberemo v gorišču tako, da polmer snopa v zraku znaša  $50 \mu\text{m}$ . Na ta način povzročimo preboj v zraku, ki ga osvetljujemo s frekvenčno podvojenim Nd:YAG laserjem ( $\lambda = 532 \text{ nm}$ ; PL2250-SH-TH, Ekspla) s trajanjem bliska 30 ps. Osvetlitveni žarek najprej vodimo skozi  $\lambda/2$  valovno ploščico (PVP). Blisk nato vodimo skozi prvi polarizacijski delilnik žarka (PDŽ), ki ga razdeli na dva bliska z med seboj pravokotnima polarizacijama. To omogoča enostavno regulacijo jakosti osvetlitve. Žarek, ki je polariziran pravokotno glede na optično mizo, uporabimo kot osvetlitveni žarek. Pred mikroskop postavimo ozkopasovni interferenčni filter (OIF), ki prepušča svetlobo z valovno dolžino  $532 \text{ nm} \pm 10 \text{ nm}$ . Laserja in kameri sinhronizirano prožimo s pomočjo signalnega generatorja (SG), ki je povezan z osebnim računalnikom (PC).




Slika 1: Levo: Eksperimentalni sistem senčne fotografije, Desno: detajl območja preboja

### 3. AVTOMATSKA DETEKC IJA

Koherentna laserska osvetlitev zaradi šuma, laserskih interferenčnih peg, in uklonskih vzorcev močno kvari kvaliteto slik (sl. 2A), kar močno otežuje obdelavo slike. Na sl. 2A vidimo, da je meja udarnega vala spričo nizkega kontrasta precej zabrisana in sama po sebi ne zadostuje za robustno detekcijo. Za uspešno integracijo več slikovnih značilnic v višjenivojski algoritem je ključnega pomena razumevanje nastanka slike.

Na sl. 1 desno vidimo območje preboja, t.j. udarni val, ki je osvetljen s koherentno svetlobe. Črne pike predstavljajo edinstven in statičen pegasti vzorec koherentne osvetlitve, ki ga zajamemo predhodno in nam služi kot slika ozadja. Ko svetloba prehaja skozi udarni val, se zaradi gradientov lomnega količnika pegasti vzorec popači in premakne, kot je shematsko predstavljeno sliki 1: desno. Z odštevanjem prej zajete slike ozadja se tako učinek pegastega vzorca za objektom podvoji in izgine drugod (glej sl. 2B) Odštevanje ozadja v splošnem izboljšuje razmerje signal/šum (SNR) in ustvari pomembno spremembo notranje strukture opazovanega objekta. Na ta način laserske interferenčne pege, ki jih v splošnem obravnavamo kot nezaželene, izkoristimo in obrnemo v prid detekciji.



Slika 2: A) Originalna slika, B) po odštevanju ozadja C) teksturna slika D) slika robov

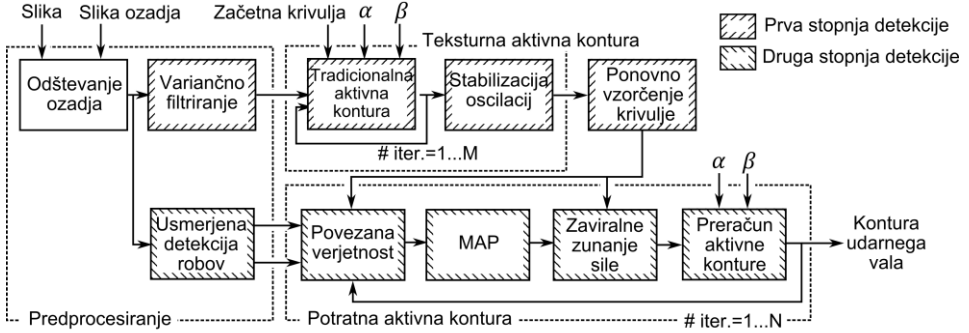
Metoda obdelave senčnih fotografij, ki jo opisujemo v nadaljevanju, temelji na uporabi dvostopenjske segmentacije. V prvi stopnji uporabljamo teksturne značilnice za grobo določitev približne konture. S tem se izognemo vplivom visoko-kontrastnih uklonskih vzorcev. Tej grobi detekciji sledi popravljalna stopnja, kjer detektirano konturo dodatno optimiziramo v skladu z detektiranimi robovi na sliki. Na obeh stopnjah uporabljamo algoritme aktivnih kontur. Celotna metoda dvonivojske segmentacije je predstavljena na sl. 3.

#### 2.1 Aktivne konture

Aktivne konture oz. kače, kot jih je predlagal Kass idr. [12], so energijske krivulje, formulirane na podlagi notranjih energij, ki so odvisne od oblike konture, in zunanjih energij, ki rezultirajo iz slikovnih značilnic. Določitev oblike konture  $s(p) = [x(p), y(p)]$  se tako formulira kot energijska optimizacija enačbe (1) in se vrši iterativno po metodi najhitrejšega spusta:

$$\alpha(p) s''(p) - \beta s^{(4)}(p) - \nabla E_{ext}(s(p)) = 0 \quad (1)$$

kjer je  $\alpha(p)$  parameter, ki nadzira togost,  $\beta(p)$  parameter ukrivljenosti kače,  $\nabla E_{ext}$  pa predstavlja vektorsko polje v smeri najhitrejšega spusta. Celotno teoretično ozadje smo izpustili, saj ga bralec lahko najde drugod [12], [13].



Slika 3: Shema avtomatske detekcije

## 2.2 Prva stopnja: teksturna aktivna kontura


Pred obdelavo slik se vnaprej zajeto ozadje odšteje od vsake novo zajete slike. Razlika v teksturi se jasno pokaže z nelinearnim filtriranjem, temelječem na izračunu variance slike v območju 3x3 pik. Rezultat po filtriranju je predstavljen na sl. 2C. Za segmentacijo uporabimo klasični pristop aktivnih kontur / kač, kjer gradient zunanje energije (za podrobnosti glej [12], [13]) definiramo na podlagi teksturnih značilnic:

$$\nabla E_{ext}(x, y) = \begin{cases} -I_{var} \frac{v}{\|v\|} & ; I_{var} \geq I_{thresh} \\ (1 - I_{var}) \frac{v}{\|v\|} & ; I_{var} < I_{thresh} \end{cases} \quad (2)$$

Ko aktivna kontura doseže rob udarnega vala, postane nestabilna in tresoča zaradi nezveznega gradienta zunanega energijskega polja. To se izkaže kot koristno pri iskanju globalnega optimuma z en. (1), saj omogoča sunkovite spremembe v konturi. Tresenje konture ublažimo z zmanjševanjem amplitude zunanega gradientnega polja in na ta način konturo stabiliziramo v le nekaj dodatnih iteracijah. Ta algoritem grobe detekcije se je izkazal kot bolj robusten od drugih segmentacijskih tehnik, kot npr. morfološko filtriranje in segmentacija z Markovimi naključnimi polji, ki smo jih tudi preskusili.

### 2.3 Druga stopnja: robna aktivna kontura

Z grobo detekcijo smo se izognili vplivu visoko-kontrastnega uklonskega vzorca, kar sicer resno ovira obdelavo slik. Rezultat grobe detekcije je dovolj blizu želene konture, zato lahko njeno obliko zgolj lokalno optimiziramo. V ta namen smo zavoljo potrebne adaptivnosti uporabili princip t.i. požrešne kače [14], pri čemer smo detekcijo osnovali na detekciji robov. Zaradi slabega kontrasta slik smo uporabili usmerjene filtre drugega reda [15], [16] (Laplace Gaussove funkcije), preko katerih smo uspešno zaznali robove udarnega vala (slika 2D) in njihove orientacije. Osnovna ideja optimizacije je, da naj konturo privlačijo samo izraziti robovi podobnih orientacij. V ta namen v vsaki iteraciji določimo kot tangente konture v izbrani točki konture in ga primerjamo z orientacijo detektiranih robov v njeni neposredni okolici. Z uvedbo Bayesove povezane verjetnosti poiščemo okolico z visokimi odzivi detekcije robov in visoko podobnostjo smeri robov. Dobljene povezane verjetnosti in detektirani maksimum a-posteriori (MAP) so prikazani na sl. 4. Med trenutno pozicijo in najbližjim lokalnim maksimumom modeliramo privlačne sile, ki v teh točkah nadomestijo gradiente zunanje energije aktivne konture, kot sledi iz en. (1). Tak postopek ponavljamo do konvergence, oz. predvidenega največjega št. korakov.




Slika 4: Proces optimizacije konture med drugo stopnjo detekcije. Ozadja slik predstavljajo: A) Robna gostota porazdelitvene verjetnosti, B) Smerna gostota porazdelitve verjetnosti in C) Povezana gostota porazdelitvene verjetnosti.

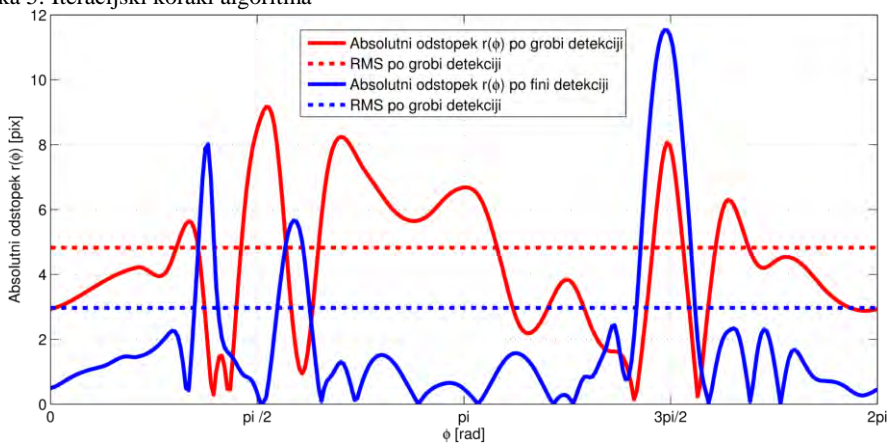
Tovrstna detekcija se izkaže kot izredno učinkovito povsod, kjer je rob zvezen in gladek. Algoritem ima nekaj težav v zgornjem in spodnjem delu udarnega vala, kjer odziv detekcije robov zaradi izredno nizkega kontrasta in uklonskih pojavov ni izrazit in zvezen. To pogosto vodi v napačno detekcijo, zato smo na teh mestih zmanjšali vpliv zunanjih sil. To smo naredili z uvedbo dodatnih zunanjih privlačnih sil med točkami trenutne konture in konture teksturne segmentacije. Te dodatne sile smo uvedli samo v zgornjem in spodnjem delu udarnega vala, s čimer smo omilili vpliv napačne optimizacije.

## 4. REZULTATI IN DISKUSIJA

Predstavljeni algoritem smo v celoti implementirali v okolju Mathworks Matlab, kjer smo ga empirično optimizirali. Končne nastavitve grobe detekcije so sledeče:  $N=25$ ,  $\alpha=0.01$ ,  $\beta=0.08$ ; končne nastavitve fine detekcije pa sledeče:  $N=25$ ,  $\alpha=0.01$ ,  $\beta=0.07$ . Delovanje algoritma smo preverili na vzorcu 12 referenčnih, ročno segmentiranih slik. Slika 5 prikazuje iteracijske korake v obeh stopnjah detekcije na primeru ene izmed kontur. Ročno in avtomatsko segmentirani krivulji smo pretvorili v polarne koordinate in vzorčili enakomerno po kotu. Na ta način lahko točnost segmentacije ocenimo kot razliko med amplitudama obeh krivulji (slika 6).



Slika 5: Iteracijski koraki algoritma



Slika 6 : Odstopanja avtomatske detekcije od ročne segmentacije po prvi (grobi) in drugi (končni) detekciji

Iz sl. 6 je razvidno dobro ujemanje avtomatske in ročne detekcije, pri čemer je opazna občutna izboljšava točnosti detekcije z dodano drugo stopnjo algoritma. Odstopanja avtomatske detekcije od ročno segmentiranih so majhna (tabela 1) in nikjer ne presegajo 15 pikslov na slikah velikosti 1392x1040. Omeniti je potrebno, da spričo slabega kontrasta in uklonskih in interferenčnih pojavov, ročna segmentacija pogostokrat predstavlja problem celo izkušenemu operaterju.

Tabela 1: Primerjava avtomatske in ročne segmentacije

	<i>Min</i> <i>[pix]</i>	<i>Max</i> <i>[pix]</i>	<i>Razpon</i> <i>[pix]</i>	<i>RMS</i> <i>[pix]</i>
1	-4,67	6,89	11,55	1,86
2	-3,33	11,6	14,92	3,02
3	-7,68	6,11	13,79	1,95
4	-9,76	5,86	15,62	2,51
5	-2,34	11,53	13,87	2,97
6	-5,38	11,36	16,74	2,43
7	-4,24	12,73	16,97	2,68
8	-4,99	8,44	13,43	2,48
9	-5,00	12,2	17,2	2,83
10	-5,83	10,01	15,84	3,22
11	-3,13	9,82	12,95	3,33
12	-5,33	6,21	11,55	2,06
<b>Povprečje</b>	<b>-5,14</b>	<b>9,39</b>	<b>14,53</b>	<b>2,61</b>

## 5.ZAKLJUČEK

V prispevku smo predstavili razvoj dvostopenjskega segmentacijskega algoritma na nizko kontrastnih senčnih fotografijah. Z njim lahko rešimo tri probleme v laserski koherentni senčni fotografiji: (i) splošno pomanjkanje kontrasta, (ii) pojav uklona in (iii) laserskih interferenčnih peg. Z uvedbo koncepta dvostopenjskih aktivnih kontur izkoristimo teksturne in robne značilke ter tako zagotovimo uspešno detekcijo udarnih valov. Uspešnost algoritmov je bila ovrednotena na vzorcu 12 ročno segmentiranih referenčnih slik. Primerjava ročne in avtomatske segmentacije dokazuje točnost in splošno robustnost predlaganega algoritma. Razvita metoda omogoča analizo velikega nabora zajetih slik in s tem odpira nove možnosti za študij lasersko-povzročenih udarnih valov, ki so zanimivi z vidika karakterizacije in nadzora laserskih obdelovalnih procesov ter medicinskih posegov. Obsežne podatkovne baze bodo omogočile dodatne izboljšave v obdelavi slike in možnost integracije naprednejših statističnih metod, kot npr. modelov aktivnih oblik.

## LITERATURA

- [1] M. Thiel, M. Nieswand, and M. Dörffel, “The use of shock waves in medicine—a tool of the modern OR: an overview of basic physical principles, history and research,” *Minim. Invasive Ther. Allied Technol. MITAT Off. J. Soc. Minim. Invasive Ther.*, vol. 9, no. 3–4, pp. 247–253, 2000.
- [2] J. Diaci and J. Možina, “Measurement of energy conversion efficiency during laser ablation by a multiple laser beam deflection probe,” *Ultrasonics*, vol. 34, no. 2, pp. 523–525, 1996.
- [3] M. Koenig, B. Faral, J. M. Boudenne, D. Batani, A. Benuzzi, S. Bossi, C. Remond, J. P. Perrine, M. Temporal, and S. Atzeni, “Relative consistency of equations of state by laser driven shock waves,” *Phys. Rev. Lett.*, vol. 74, no. 12, p. 2260, 1995.
- [4] W. Lauterborn and A. Vogel, “Shock Wave Emission by Laser Generated Bubbles,” in *Bubble Dynamics and Shock Waves*, Springer, 2013, pp. 67–103.
- [5] J. Noack and A. Vogel, “Single-shot spatially resolved characterization of laser-induced shock waves in water,” *Appl. Opt.*, vol. 37, no. 19, pp. 4092–4099, 1998.
- [6] H. Kleine and H. Grönig, “Color schlieren methods in shock wave research,” *Shock Waves*, vol. 1, no. 1, pp. 51–63, Mar. 1991.
- [7] P. Gregorčič and J. Možina, “High-speed two-frame shadowgraphy for velocity measurements of laser-induced plasma and shock-wave evolution,” *Opt. Lett.*, vol. 36, no. 15, pp. 2782–2784, 2011.
- [8] G. S. Settles, *Schlieren and shadowgraph techniques: visualizing phenomena in transparent media*. Berlin; New York: Springer, 2001.
- [9] A. Vogel, I. Apitz, S. Freidank, and R. Dijkink, “Sensitive high-resolution white-light Schlieren technique with a large dynamic range for the investigation of ablation dynamics,” *Opt. Lett.*, vol. 31, no. 12, pp. 1812–1814, 2006.
- [10] P. Gregorčič, J. Diaci, and J. Možina, “Two-dimensional measurements of laser-induced breakdown in air by high-speed two-frame shadowgraphy,” *Appl. Phys. A*, vol. 112, no. 1, pp. 49–55, Sep. 2012.
- [11] J. O. Kokaj, “Morphological image processing of a bubble in laser-induced shock-wave lithotripsy,” in *Intelligent Systems and Smart Manufacturing*, 2000, pp. 98–106.
- [12] M. Kass, A. Witkin, and D. Terzopoulos, “Snakes: Active contour models,” *Int. J. Comput. Vis.*, vol. 1, no. 4, pp. 321–331, 1988.
- [13] J. Ivins and J. Porrill, “Everything you always wanted to know about snakes (but were afraid to ask),” *Artif. Intell.*, vol. 2000, 1995.
- [14] K.-M. Lam and H. Yan, “Fast greedy algorithm for active contours,” *Electron. Lett.*, vol. 30, no. 1, pp. 21–23, Jan. 1994.
- [15] T. Lindeberg, “Edge detection and ridge detection with automatic scale selection,” *Int. J. Comput. Vis.*, vol. 30, no. 2, pp. 117–156, 1998.
- [16] J.-M. Geusebroek, A. W. Smeulders, and J. van de Weijer, “Fast anisotropic Gauss filtering,” in *Computer Vision—ECCV 2002*, Springer, 2002, pp. 99–112.

# ZNAČILNOSTI ZAJEMANJA IN OBDELAVE POSNETKOV V PROIZVODNEM OKOLJU Z VISOKIMI TEMPERATURAMI

**Anton Ružič**

**Odsek za avtomatiko, biokibernetiko in robotiko**

**Institut Jožef Stefan**

**E-pošta: anton.ruzic@ijs.si**

**URL: <http://abr.ijs.si>**

---

**POVZETEK:** *V prispevku analiziramo značilnosti industrijskega okolja za proizvodnjo steklenih izdelkov, ki zaradi visokih temperatur, nizkih viskoznosti obdelovancev in drugih omejitev vplivajo na izluščanje informacij okolja z zajemom in obdelavo videoposnetkov. Za doseganje zelenih rezultatov moramo sprejeti pravilne odločitve v vseh elementih niza okolje-optika-kamera-obdelava.*

---

## 1. UVOD

V sklopu avtomatizacijskega projekta za industrijskega naročnika smo razvili tudi sistem za zajem in formalizacijo znanja operaterjev pri izvajanju ročne manipulacijsko-stekloprihaške operacije, ki predstavlja eno ključnih operacij v pretežno ročnem okolju za formiranje steklenih izdelkov. To specifično steklarsko okolje zajema vse proizvodne procese od odvzema steklene mase iz ene ali več peči do končnega formiranja zelene oblike objekta [1].

Del sistema vključuje tudi protokol video meritev in obdelav ter ustrezno materialno in programsko opremo. Končni rezultat je časovni potek spremembe površine steklene opne pri ročni operaciji formiranja, ta pa je osnova za avtomatsko izvajanje operacije.

Pri razvoju sistema smo srečali in tudi rešili specifične zahteve, ki ne nastopajo v tipičnih laboratorijskih razmerah ali v industrijskih razmerah, kjer je možno v zadostni meri strukturirati okolje in pogoje zajema videoposnetkov. Ker je naš namen nadaljnja avtomatizacija steklarskih procesov, smo sistematično identificirali njihove lastnosti, ki vplivajo na uspešno določanje informacij z uporabo računalniškega vida.

## 2. TIPIČNE NALOGE RAČUNALNIŠKEGA VIDA

Postopki proizvodnje standardnih steklenih izdelkov v masovnih serijah, na primer steklenic običajnih oblik in dimenzij, so danes uspešno avtomatizirani.





Slika 1: Primer pretežno ročnega steklarskega okolja in ilustracija tipov informacij, ki jih želimo za namen avtomatizacije izluščiti z zajemanjem in obdelavo videoposnetkov.

- 1) označeno z rdečo barvo – površina steklenega telesa oziroma izdelka;
- 2) označeno z modro barvo – položaj in pot naprav za prenos stekla in pomožnih orodij
- 3) označeno z zeleno barvo – položaj in premik operaterjev v prostoru


Po drugi strani se proizvodnja lupinastih steklenih objektov (steklenice, vsebovalniki, razsvetljavna telesa in podobno) izvaja pretežno ročno ali polavtomatsko, če imajo ti objekti vsaj eno od naslednjih značilnosti: proizvodne serije so srednje ali manjše, izdelki so večji od običajnih (npr. od običajnih steklenic ali kozarcev za vlaganje), so razvejanih ali izstopajočih oblik, izdelki so iz posebnih stekel ali iz več plasti stekla.

Pri analizi in koncipiranju avtomatskih rešitev za steklarske naloge, ki se izvajajo pretežno ročno, pogosto ugotovimo, da je koristna, če že ne nujna, uporaba računalniškega vida. Druga značilnost je, da so operacije znotraj posameznih proizvodnih enot lahko tako zahtevne, da je največkrat smotna in s finančno tehničnega vidika izvedljiva le avtomatizacija nekaterih procesov. Pri tem pride do sodelovanja ali interakcij operaterjev in avtomatskih naprav ali robotov.

Posledično so tipične naloge za zajem videoposnetkov in njihovo obdelavo različne, v odvisnosti od konkretne izvedbe avtomatizacije, kar ilustriramo na slikah 1, 2 in 3.

Na sliki 1 je primer izseka iz realnega steklarskega okolja, kjer so v proizvodnji vključeni operaterji. Tu lahko nastopijo trije tipični primeri:

1. Želimo zajemati obliko površine steklenega izdelka, morebiti še položaj in orientacijo izdelka v prostoru pri manipulaciji izdelka v prostoru.  
V odvisnosti od procesa lahko stekleni objekt nastopa kot strnjena masa (na sliki 1 v ozadju) ali kot steklena opna oziroma lupina (v ospredju slike 1).
2. Določiti moramo položaj in orientacijo orodij, s katerimi se prenaša steklen objekt, ali položaj pomožnih orodij in specifičnih procesnih naprav.




Slika 2: Drugi primer steklarskega okolja in ilustracija tipov informacij, ki jih želimo za namen avtomatizacije izluščiti z zajemanjem in obdelavo videoposnetkov. Oznake rdeče, modre in zelene barve imajo isti pomen kot na sliki 1. Dodatno: 4) označeno z rožnato barvo – plamen gorilnikov.

3. Z video zajemom in obdelavo moramo določiti položaj operaterjev v delovnem prostoru.

Na slikah 2 in 3 vidimo še dve situaciji iz realnega okolja. Glede na drugi dve sliki nastopa na sliki 2 dodatno četrti primer.

4. Z video zajemom in obdelavo želimo določiti položaj in oceniti velikost oz. moč gorilnikov za vmesno dogrevanje formiranih steklenih objektov.




Slika 3: Tretji primer pretežno ročnega steklarskega okolja in ilustracija tipov informacij, ki jih želimo za namen avtomatizacije izluščiti z zajemanjem in obdelavo videoposnetkov. Oznake rdeče, modre in zelene barve imajo isti pomen kot na sliki 1.

## 2. SPECIFIČNE ZNAČILNOSTI ZAJEMA IN OBDELAV

V tem poglavju bomo identificirali nekaj posebnih značilnosti, zahtev in omejitev, ki so specifične za ciljno steklarsko okolje. Te vplivajo na težavnost določanja površine steklenega objekta in njegovega položaja, večina teh pa tudi na identifikacijo orodij ali operaterjev v okolici.

- **Netogost in časovna spremenljivost steklenega objekta**

Homogena steklena masa se formira v peči pri temperaturah do 1575°C, pri odjemu iz peči je temperatura mase okoli 1090°C, nato se objekt oblikuje v zaporedju operacij do približno 870°C (pri nekaterih tipih stekel najnižje 730°C). V tem času je steklena masa, bodisi če je polna, bodisi če je lupina, netoga in spreminja obliko tako zaradi vpliva premikanja mase kot zaradi gravitacije, kot prikazujemo na sliki 4.



Slika 4: Hitrost spremembe oblike ogrete steklene mase:

- a) prva vrstica: polna kepa, sprememba zaradi težnosti v času 500 ms;
- b) druga vrstica: polna kepa, tip stekla z nižjo viskoznostjo, sprememba v času 500 ms
- c) tretja vrstica: steklena opna, sprememba zaradi težnosti v času 800 ms.

- **Različni vplivi sevanja steklenega materiala v odvisnosti od temperature**

### Žarenje/sevanje


- Žareče steklo deluje kot vir svetlobe, ki osvetljuje okolico steklenega objekta in s spreminja svetlobne pogoje zajema.
- Sevanje žarečega stekla lahko vpliva na naravo podatkov nekaterih senzorjev (ki lahko delujejo v širšem/drugem spektru od vidnega).

### Spremenljivost sevanja s temperaturo


- Ker stekleni objekt stalno menja temperaturo, se pri tem spreminja tudi sevanje oziroma zajeti podatki; na to lahko vpliva tudi sprememba oblike. Na sliki 4 tako vidimo, da je svetlobno sevanje objekta v tretji vrstici bistveno spremenjeno glede na prvi dve vrstici, čeprav gre za isti, le preoblikovan objekt, po približno 8 sekundah. Tak primer vidimo v

zaporedju dveh nizov na sliki 5, kjer si posnetki sledijo z razmakom 3 sekund, in tudi s primerjavo slike 5 in 6, saj druga slika prikazuje isti fizični element po približno 10 sekundah.

- Podatki z različnih točk steklenega objekta so lahko pri istem zajemu zelo različni zaradi različnosti njihovih temperatur.



Slika 5: Sprememba značilnosti zaporednih zajemov steklenega objekta v vidnem spektru. Prikazani sta dve seriji zajemov, ena v vsaki vrstici; na vsaki seriji so posnetki 3 s narazen. Objekt na posnetkih je iz prosojnega stekla, s temperaturo med 800°C in 900 °C.



Slika 6: Sprememba značilnosti zaporednih zajemov steklenega objekta v vidnem spektru. Serija 6 slik je posneta znotraj 1 sekunde, in sledi cca. 11 s seriji s slike 5. Formirani objekt ima temperaturo okoli 700°C.

- **Vpliv različnih prosojnosti stekel**

- Več tipov stekla je pri operacijah formiranja naravno prosojnih, kar močno vpliva na značilnost zajetih podatkov, predvsem na ločljivost objekta od okolice, tudi v odvisnosti od materialne opreme za zajem. Vsi posnetki na sliki 6 prikazujejo isti objekt v kratkem času, vendar so tako odsevi na stekleni opni kot površina steklene opne zelo različni.
- Nivo prosojnosti se lahko spreminja s temperaturo (slika 5).
- Različni tipi stekla izkazujejo različno prosojnost. Na primer, običajno natrijevo steklo (angleško »soda-lime glass«) je pri sobni temperaturi

prosojno, običajno opalno steklo pa belo, neprosojno. Steklени izdelek lahko vsebuje eno ali več vrst stekla.

- **Različna odbojnost**

- Tako kot prosojnosti tudi različna odbojnost posameznih vrst stekel vpliva na značilnost zajetih podatkov, v odvisnosti od materialne opreme zajema.
- Odbojnost se spreminja s temperaturo.

- **Neizrazite oblike steklenih objektov**

Stekleni objekt, posebno v vmesnih fazah formiranja, nima izrazitih robov ali oglišč na površini, razen v stiku z nosilnim orodjem ali podstavkom, kar otežuje prostorsko karakterizacijo površine.

Poleg faktorjev zajema, ki izhajajo predvsem iz narave stekla in lastnosti visoko ogrete steklene mase, v proizvodnih razmerah nastopajo še drugi faktorji, ki otežujejo zajem in obdelavo.

- **Omejena možnost urejanja pogojev zajema posnetkov**

Za steklarsko okolje je značilna prisotnost fiksnih peči in strnjeno okolje strojev, naprav ter operaterjev, zaradi časovnih zahtev in zaporednih faz oblikovanja. Iz tega izhaja več značilnosti.

- Včasih zaradi razporeditev naprav ni možno urediti ozadja posnetkov za povečanje kontrasta.
- Ni možno doseči urejenega ozadja, ker se objekt premika.
- Ni možno postaviti fizične kulise kot ozadje, ker bi s tem vplivali na trajektorijo premikanja in posledično na formo netogega objekta.

Problem je lahko večji, ker je v istem okolju lahko prepleta več elementov z istimi vidnimi značilnostmi oziroma izrazitim aktivnim sevanjem.

- V ozadju opazovanega objekta se lahko nahaja več drugih steklenih objektov.
- Steklarske operacije pogosto vključujejo dogrevanje, ki se izvaja z gorilniki; ti lahko dodatno slabšajo ločljivost zelenega objekta od okolja.

- **Dodatne motnje okolice**

**Nezaželeni vžig**

- Na orodju za prenos steklene mase, na okoliških napravah, pa tudi na steklu, včasih zagori ogenj, ki pokvari kvaliteto zajema. Vzrok ognja je lahko periodično mazanje naprav, ki spontano (čeprav nezaželeno) zagorijo, zato se mu ne moremo izogniti. Nekaj primerov prikazuje slika 7.

## Nečistoče, dim

→ V ozračju je lahko veliko nečistoč, ki motijo in spreminjajo kvaliteto zajema. Te so lahko prah, dim ogretega ali gorečega maziva ali drugo (slika 7). Delci lahko motijo pri zajemu svetlobe objekta ali pa s svojim sekundarnim sevanjem, ki nastane kot refleks okoliških virov svetlobe.



Slika 7: Vpliv vžiga na zajemanje posnetkov za določanje površine steklenega izdelka.

Vidimo, da so moteči faktorji tako ogenj kot dim

- prva vrstica: normalna zaslonka: ogenj ponekod popolnoma zakrije informacijo o objektu;
- druga vrstica: zaprta zaslonka: v primeru ognja bolje ločimo obrise, vendar s tem zmanjšamo kontrast v običajnih situacijah.

### 3. SPECIFIČNI PRISTOP K ZAJEMU IN OBDELAVI GLEDE NA ZNAČILNOSTI OKOLJA

Celotno verigo elementov, ki vplivajo na izluščanje informacij glede oblike in položaja posameznih elementov okolja lahko prikažemo tako:


okolje → optika → kamera → obdelava in analiza slik

V velikem številu primerov največjo pozornost posvetimo urejanju okolja in obdelavi ter analizi slik. V steklarskem proizvodnem okolju, katere specifičnosti smo opisali v prispevku, je možnost urejanja pogojev zajema omejena, poleg tega so slike, zajete brez upoštevanja specifičnih vplivov neprimerne ali celo neuporabne za izluščanje želenih podatkov. Zato moramo pozornost posvetiti tudi vmesnim elementom v verigi zajema. Pristopi, s katerimi bi lahko izboljšali izluščanje informacij so:

- uporaba več kamer (za izogibanje vidnim oviram, za lažjo karakterizacijo površine in podobno),
- aktivni vid,
- sprotno krmiljenje zaslonk kamer,
- uporaba kamer v različnih spektrih: vidnem, infrardečem, bližnjem infrardečem spektralnem območju.



Primer zajema v različnih spektrih je prikazan na sliki 8. Vidimo, da lahko v IR spektru močno povečamo kontrast med ogretim objektom in ozadjem, tudi v primerjavi s kamero s priprto zaslonko. Po drugi strani se zmanjša razlika med objektom in ogretim nosilnim orodjem. Nadalje vidimo, da z uporabo NIR spektra in s krmiljenjem zaslonke lahko kompenziramo številne motnje ozadja, razen močne reflektirane svetlobe, vendar mora imeti kamera pri premikajočih objektih zadostno občutljivost.



Slika 8: Ilustracija nekaj značilnosti video zajema v steklarskem okolju; zgoraj levo vidni spekter, desno IR spekter; spodaj NIR spekter z različnimi zaslonkami;

### 3. ZAKLJUČEK

Analizirali smo značilnosti industrijskega okolja za formiranje steklenih izdelkov, katere vplivajo na postopek določanja informacij z zajemom in obdelavo posnetkov. V velikem številu primerov ne moremo doseči uspešnih rešitev le s postopki obdelave, temveč je potrebno preučiti tudi druge elemente celotnega postopka, na primer spektralno območje kamere. Ker ima uporaba vsake alternative svoje prednosti in pomanjkljivosti, bomo v nadaljevanju našega dela te natančno ovrednotili in formalizirali. Tako bomo pri avtomatizaciji posameznih procesov izbrali ustrezen rešitev na osnovi utemeljenih podatkov in ugotovitev.

### LITERATURA

1. A. Ružič, (2012) Navodila za namestitev in uporabo avtomatizirane celice za predpihanje steklenih izdelkov, *Institut Jožef Stefan – Delovno poročilo 11251*.

# MERJENJE NATANČNOSTI PAMETNIH MOBILNIH NAPRAV V APLIKACIJAH STROJNEGA VIDA

**Danijel Skočaj, Domen Tabernik, Domen Rački,  
Matjaž Hegedič, Alen Vrečko, Matej Kristan**

**Laboratorij za umetne vizualne spoznavne sisteme  
Univerza v Ljubljani, Fakulteta za računalništvo in informatiko**

**E-pošta: danijel.skocaj@fri.uni-lj.si**

**URL: <http://www.vicos.si>**

---

**POVZETEK:** *Pametne mobilne naprave postajajo vse bolj pomembna platforma za aplikacije strojnega in računalniškega vida. Eden izmed problemov, ki se pojavljajo pri razvoju in uporabi takih aplikacij, je velika raznovrstnost pametnih telefonov in tabličnih računalnikov. V tem članku predstavljamo rezultate eksperimentalne študije v kateri smo ocenili primernost 22 naprav za aplikacije strojnega vida. Eksperimentalni rezultati potrjujejo, da lahko s primernim robustnim procesiranjem zajetih slik pametne telefone in tablične računalnike uporabljamo za optično merjenje razdalj v referenčni ravnini s pod-milimetrsko natančnostjo.*

---

## 1. UVOD

Pametne mobilne naprave, kot so pametni telefoni in tablični računalniki, so v zadnjih desetih letih naredili bistven tehnološki preskok. Z večanjem računske moči in napredkom v uporabniških vmesnikih so za mnoge postale osrednja komunikacijska enota. Čeprav je bil osnovni namen mobilnih telefonov komunikacija med uporabniki, so ti z integracijo raznovrstnih senzorjev, kot so pospeškomeri in kamere, presegli zgolj namembnost komuniciranja in porajajo se mnoge aplikacije, ki širijo uporabnost teh naprav. Danes ima tako rekoč vsakdo v »žepu« zmožljiv računalnik ter kamero v obliki pametnega mobilnega telefona. Prisotnost kamere na majhni zmogljivi napravi ponuja vrsto novih in inovativnih rab, ki imajo potencial široke uporabe. Pojavlja se vedno več mobilnih aplikacij strojnega in računalniškega vida, kot so npr. sistemi za pomoč slepim in slabovidnim [1], sistemi za rekonstrukcijo prizorov [2], obogateno resničnost [3], mobilno prevajanje besedil [4] ipd. V prihodnje lahko pričakujemo še več takih aplikacij.

Poudariti je potrebno, da se razvoj mobilnih aplikacij podreja drugačnim zakonitostim kot klasične aplikacije strojnega vida. Področje strojnega vida je zrelo strokovno področje z zgodovino številnih uspešnih industrijskih aplikacij. Ta uspeh lahko vsaj deloma pripišemo nadzorovanim pogojem, v katerih sistemi strojnega vida običajno



delujejo. Med razvojem sistemov strojnega vida igrajo odločilno vlogo trije faktorji: (i) kamera kot tudi ostala strojna in programska oprema, ki jo uporabljamo, (ii) okolje (predvsem osvetlitev predmetov in prizorov) v katerem sistem strojnega vida deluje ter (iii) lega predmeta v tem okolju. V praksi je uspešnost industrijskega strojnega vida pogojena ravno s temi tremi faktorji. Tako lahko običajno izberemo za specifično aplikacijo najbolj primerno kamero ter objektiv, primerne računske zmogljivosti, postavimo primerno osvetlitev prizora, zagotovimo primerno lego predmetov ter minimiziramo vpliv zunanjih nenadzorovanih dejavnikov.

Popolnoma nasprotna pa je situacija pri razvoju mobilnih aplikacij strojnega vida. Tu imamo zelo malo nadzora nad vsemi tremi faktorji. Globalni trg namreč narekuje izbor strojne in programske opreme v obliki pametnih mobilnih naprav, ki se pojavljajo na trgu in kamer, ki so v te naprave vgrajene. Če želimo ponuditi uporabo aplikacij kar najširši množici uporabnikov, moramo zagotoviti, da učinkovito delujejo na zelo različnih platformah z zelo različnimi kamerami in računskimi zmogljivostmi. Prav tako v splošnem nimamo nadzora nad stopnjo tehnične pismenosti potencialno zelo velikega kroga uporabnikov. Tipični uporabniki takšnih aplikacij ne bodo nujno strokovnjaki in ne bodo imeli predznanja o uporabi aplikacije, ki mora zato biti kar se da intuitivna in enostavna za uporabo.


V tem članku bomo naslovi ravno nekaj teh posebnosti, ki se porajajo pri razvoju mobilnih aplikacij strojnega vida. Osredotočili se bomo na aplikacije, ki zahtevajo zelo natančno zajemanje slik in detekcijo ter lokalizacijo predmetov na njih (npr. aplikacije za merjenje velikosti predmetov na slikah). Natančneje, naslavljali bomo naslednje vprašanje: *Kako natančno lahko izmerimo razdalje med točkami na ravnini s pametnimi mobilnimi napravami in kako se uspešnost različnih mobilnih naprav pri tem razlikuje?* Izvedli smo eksperimentalno študijo v kateri smo ocenili skupaj natančnosti 22 različnih mobilnih naprav. Z analizo rezultatov bomo ocenili primernost teh naprav v kontekstu uporabnosti mobilnih aplikacij strojnega vida.

## **2. EKSPERIMENTALNI PROTOKOL**

Tovrstne aplikacije morajo biti prijazne za uporabo, ker naj bi jih uporabljala širša množica uporabnikov. Zato se moramo izogniti predhodni kalibraciji sistema, ki je običajna praksa pri sistemih industrijskega strojnega vida. Za opravljanje meritev v absolutnem metričnem koordinatnem sistemu, dovolimo uporabo referenčnega predmeta, ki omogoča preslikavo iz koordinatnega sistema slike v svetovni koordinatni sistem. Ker mora biti ta predmet široko dostopen, smo v naši evalvaciji uporabili kar prazen list papirja formata A4.

Implementirali smo algoritme, ki avtomatsko detektirajo robove lista ter izračunajo projekтивно preslikavo iz slikovnega koordinatnega sistema izraženega v slikovnih elementih v svetovni koordinatni sistem določen z referenčnim predmetom, ki je izražen v milimetrih. Na ta način smo lahko merili razdalje med poljubnimi točkami, ki ležijo v referenčni ravnini s pod-milimetrsko natančnostjo.

Za referenco smo vsako testno napravo v našem eksperimentu kalibrirali s standardnim postopkom, ki za kaliber uporablja na A4 list natisnjeno šahovnico. Tako smo pridobili referenčno oceno notranjih parametrov kamere in distorzijskih koeficientov. Postopek smo izvedli na 18 slikah posnetih z različnih zornih kotov. Zato, da smo zagotovili približno enake smeri zajemanja pri vseh mobilnih napravah, smo razvili testno aplikacijo za platformo Android, ki je uporabnika usmerjala pri zajemanju slik. Testna aplikacija je prikazana na Sliki 1.



Slika 1: Testna aplikacija

Z vsako napravo smo torej zajeli 18 slik in nato ocenili naslednje napake:

- **Napaka v detekciji kotov.** Kote med kvadrati na šahovnici, ki smo jih dobili v postopku kalibracije z orodjem Camera Calibration Toolbox for Matlab<sup>1</sup>, smo z ocenjeno homografijo preslikali v svetovni koordinatni sistem in izračunali razdaljo (v mm) med tako dobljenimi koordinatami in dejanskimi koordinatami na kalibracijskem vzorcu.
- **Napaka ocenjene širine šahovnice.** Izračunali smo razdaljo med dvema specifičnima točkama na šahovnici, t.j. širino šahovnice (razdaljo med prvim in zadnjim stolpcem kvadratov) ter jo primerjali s pravo širino.

Želeli smo tudi oceniti vpliv radialne distorzije. Zato smo zgoraj omenjeni meri izračunali na tri načine oz. s procesiranjem treh vrst slik:

- **Originalne slike.** Uporabili smo originalno zajete slike; radialne distorzije nismo skušali odpraviti.
- **Slike popravljene s specifičnimi distorzijskimi koeficienti.** Procesiral smo originalne slike, vendar smo vse detektirane točke (preden smo jih preslikali v svetovni koordinatni sistem) popravili z upoštevanjem distorzijskih koeficientov, ki smo jih za specifično kamero pridobili v procesu kalibracije le-te.

---

<sup>1</sup> [http://www.vision.caltech.edu/bouguetj/calib\\_doc/index.html](http://www.vision.caltech.edu/bouguetj/calib_doc/index.html)

- **Slike popravljene z generičnimi distorzijskimi koeficienti.** V splošni uporabi mobilnih aplikacij kalibracija posameznih kamer ne bo mogoča, zato specifični distorzijski koeficienti ne bodo znani. Iz tega razloga smo namesto le-teh uporabili generične distorzijske koeficiente (mediano vseh koeficientov) in sicer na vseh napravah enake.

### 3. EKSPERIMENTALNI REZULTATI

Eksperimentalno evaluacijo smo izvedli na 22 pametnih mobilnih napravah: 12 pametnih telefonih in 6 tabličnih računalnikih z operacijskim sistemom Android ter na 4 napravah z operacijskim sistemom iOS. Seznam naprav je predstavljen v Tabeli 1.

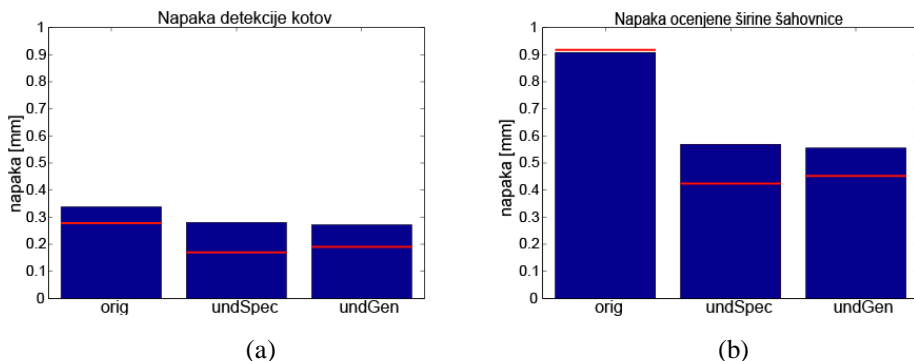
Tabela 1: Naprave uporabljene v eksperimentalni študiji ter verzije operacijskega sistema.

št.	naprava	OS	št.	naprava	OS
1	Samsung Nexus	4.1	13	Samsung Galaxy Tab 10.1	3.2
2	Samsung Galaxy Note 2	4.1	14	Asus TF300T	4.2
3	Samsung Galaxy S4	4.1	15	Samsung Galaxy Tab 10.1	3.1
4	Sony Xperia	2.3	16	ASUS Transformer TF201	4.1
5	Huawei U8850	2.3	17	Samsung Galaxy Note 10	4.1
6	HTC Desire HD	2.3	18	Samsung Galaxy Tab 2 7.0	4.1
7	Samsung Galaxy S3 Mini	4.1	19	Apple iPhone 4	6.1
8	Samsung Galaxy S2	4.1	20	Apple iPhone 4S	6.1
9	Sony Xperia ST27i	2.3	21	Apple iPhone 5	6.0
10	HTC Sensation	4.0	22	Apple iPad 2	6.1
11	HTC Wildfire	2.3			
12	Samsung Galaxy Mini	2.3			

Z vsako izmed naštetih naprav smo zajeli 18 slik in jih obdelali, kot je opisano v prejšnjem poglavju. V nadaljevanju podajamo analizo dobljenih eksperimentalnih rezultatov.

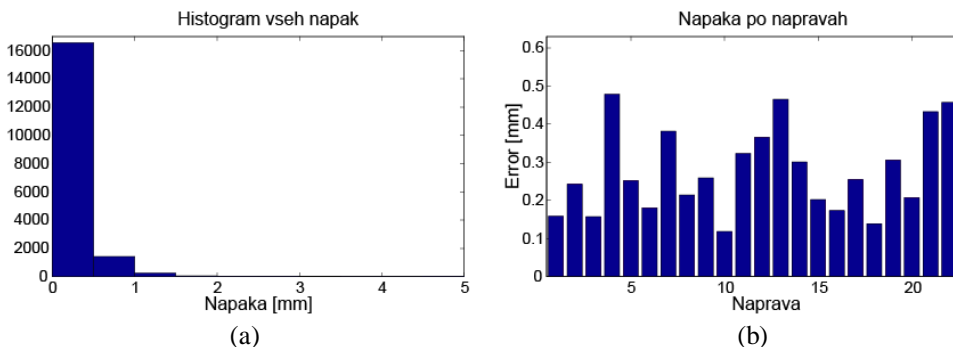
Slika 2 prikazuje skupne rezultate za posamezne tipe slik, ki smo jih opisali v prejšnjem poglavju. Rezultati so povprečni po vseh slikah, ki smo jih zajeli z naštetimi napravami. Modri stolpci predstavljajo srednjo vrednost napake, rdeče črte pa mediano. Pri procesiranju originalnih slik je bila srednja vrednost napake detekcije kotov 0,34 mm (s standardno deviacijo 0,35 mm), mediana pa 0,28 mm. Sistem je torej zelo natančno detektiral kote na šahovnici in s pomočjo robov lista pravilno ocenil homografijo. Če koordinate detektiranih točk popravimo tako, da upoštevamo distorzijske koeficiente, rezultate še nekoliko izboljšamo. Odpravljanje radialne distorzije še veliko bolj izboljša rezultate meritev širine šahovnice. V tem primeru se povprečna absolutna napaka zmanjša z 0,91 mm pri originalnih slikah na 0,55 mm pri slikah, ki smo jih popravili z generičnimi distorzijskimi koeficienti. Pri tem velja poudariti, da dobimo zelo podobne rezultate, če vpliv distorzije zmanjšujemo s specifičnimi ali z generičnimi distorzijskimi koeficienti. Ta ugotovitev je zelo ugodna za splošno uporabnost mobilnih aplikacij strojnega vida, saj pomeni, da lahko na

različnih napravah uporabljamo enake distorzijske koeficiente (s čemer se izognemo potrebi po kalibraciji posameznih naprav) in s tem v povprečju zmanjšamo napako.



Slika 2: Rezultati procesiranja različnih tipov slik; *orig*: originalne slike, *undSpec*: slike popravljene s specifičnimi distorzijskimi koeficienti, *undGen*: slike, popravljene z generičnimi distorzijskimi koeficienti. (a) Napaka v detekciji kotov. (b) Napaka ocenjene širine šahovnice.

Slika 3 prikazuje podrobnejše rezultate detekcije kotov na slikah, ki smo jih popravili z generičnimi distorzijskimi koeficienti. Iz histograma napak lahko razberemo, da so skoraj vse napake pri detekciji kotov manjše od 1 mm, pri čemer jih je velika večina manjših od 0,5 mm. Slika 3(b) prikazuje napake za posamezne naprave (naprave so oštevilčene enako kot v Tabeli 1). Vse naprave se odrežejo precej dobro, saj je povprečna napaka pri vseh napravah manjša od 0,5 mm, pri nekaterih pa zgolj 0,1 mm. Če bi te rezultate primerjali z rezultati doseženimi na originalnih slikah, bi ugotovili, da se napaka pri nekaterih napravah sicer rahlo poveča, v povprečju pa se napaka vendarle zmanjša. Napaka se poveča pri napravah, pri katerih se optika in s tem radialna distorzija bistveno razlikujeta od splošnega trenda (predvsem so to naprave proizvajalca Apple, ki jih lahko obravnavamo ločeno).



Slika 3: Rezultati detekcije kotov na slikah popravljenih z generičnimi distorzijskimi koeficienti: (a) histogram napak, (b) napake po posameznih napravah.

## 4. ZAKLJUČEK

V tem članku smo predstavili del rezultatov eksperimentalne študije, v kateri smo analizirali primernost pametnih mobilnih naprav za aplikacije strojnega vida, oz. natančneje za brezkontaktno optično merjenje.

Analizirali smo zmogljivosti 22 naprav. Doseženi rezultati so precej dobri, saj je bila povprečna napaka pri detekciji kotov med polji na šahovnici na vseh napravah manjša od 0,5 mm. Upošteva je velikost referenčnega predmeta (list formata A4) to predstavlja relativno napako, ki je manjša od 0,2%. Ugotovili smo tudi, da velja zajete slike popraviti z distorzijskimi koeficienti, pri čemer v večini primerov zadostuje že uporaba generičnih koeficientov, ki so za vse naprave enaki. Poleg rezultatov, ki smo jih predstavili v tem članku, smo v eksperimentalni študiji analizirali še vrsto drugih kazalnikov. Tako smo med drugim ugotovili, da lahko iz podatkov pridobljenih iz mobilne naprave ter z avtomatsko detekcijo referenčnega lista dokaj dobro ocenimo notranje in zunanje parametre kamere.

Ugotavljamo torej, da je mogoče s primernim robustnim procesiranjem zajetih slik pametne mobilne naprave uporabljati za optično merjenje razdalj v referenčni ravnini s pod-milimetrsko natančnostjo. Glede na to, da se tako procesorska moč mobilnih naprav, kot tudi zmogljivost vgrajenih kamer neprestano izboljšujeta, lahko pričakujemo, da bodo pametne mobilne naprave postajale vse bolj priljubljena platforma za aplikacije računalniškega vida. Rezultati, ki smo jih predstavili v tem članku, potrjujejo, da so lahko te aplikacije, ob upoštevanju določenih zakonitosti, zelo natančne in uporabne.

## LITERATURA

1. R. Manduchi, S. Kurniawan, and H. Bagherinia (2010), Blind guidance using mobile computer vision: A usability study, *Proceedings of the 12th International ACM SIGACCESS Conference on Computers and Accessibility, ASSETS '10*, str. 241–242.
2. Q. Pan, C. Arth, G. Reitmayr, E. Rosten, and T. Drummond (2011), Rapid scene reconstruction on mobile phones from panoramic images, *10th IEEE International Symposium on Mixed and Augmented Reality (ISMAR)*, str. 55–64.
3. Y. Xin and C. Kwang-Ting (2012), LDB: An ultra fast feature for scalable augmented reality on mobile devices, *Mixed and Augmented Reality (ISMAR)*, str. 49–57.
4. M. Petter, V. Fragoso, M. Turk, and Charles Baur (2011), Automatic text detection for mobile augmented reality translation, *IEEE International Conference on Computer Vision Workshops (ICCV Workshops)*, pages 48–55.

# PRIMERJAVA POSTOPKOV ZA 3D-REKONSTRUKCIJO SCENE IZ PARA SLIK

Matjaž Divjak, Damjan Zazula

Univerza v Mariboru

Fakulteta za elektrotehniko, računalništvo in informatiko

E-pošta: [matjaz.divjak@uni-mb.si](mailto:matjaz.divjak@uni-mb.si)

URL: <http://storm.uni-mb.si>

---

**POVZETEK:** *Zadnji dve desetletji so bile opravljene obsežne raziskave za neposredno rekonstrukcijo scenske strukture in gibanja kamere iz majhnega števila posnetkov te scene. Raziskali smo nekaj znanih postopkov, ki vodijo od iskanja korespondenc med slikami, pred epipolarne geometrije do prostorske rekonstrukcije, izhajajoč samo iz dve pogledov. V ta namen smo potrebovali zanesljivo vnaprejšnjo kalibracijo kamere. Pozornost smo posvetili rekonstrukcijama s triangulacijo in z izravnavo slik ter upoštevanjem stereo disparitet. Sestavili smo ustrezna postopka, tako da smo uporabili le konvencionalne korake, ki so vgrajeni v splošno dostopnih programskih knjižnicah. Preverjanje z dvema različnima scenama je pokazalo, da lahko z epipolarno omejitvijo in triangulacijo določamo oddaljenost objektov od kamere s povprečno napako 4,16 %, medtem ko se ocene globin za koplanarne točke razlikujejo za 2,16 %. Isti sceni sta bili rekonstruirani s pomočjo izravnave slik in stereo disparitetami precej slabše: povprečna napaka pri oddaljenostih je bila 36,68 %, napaka pri koplanarnih točkah pa 6,3 %.*

---

## 1. UVOD

Računalniški vid temelji na strojni opremi, ki jo danes premore vsak mobilni telefon. Povezuje digitalno kamero in mikroračunalnik, ki z vgrajenimi algoritmi obdeluje posnete slike. Postopki so odvisni od aplikacije in so postajali vse zmogljivejši z izpopolnjevanjem tehnologije in širšim spoznavanjem splošnih konceptov. Nepogrešljivi postajajo pri letalskem in robotskem kartiranju, forenziki na scenah zločinov ali prometnih nesreč, meritvah odkopov v rudarstvu, spremljanju gradnje, navigaciji robotov in avtomatiziranih vozil, izogibanju trkom, nadzoru procesov v proizvodnji, rekonstrukciji organov v medicini in tudi brezkontaktnih meritvah s splošno fotogrametrijo.

Če se osredotočimo na rekonstrukcijo scene, ki jo posnamemo iz več zornih kotov, se moramo pri vseh aplikacijah znati otresti večličnosti, ki se pojavi, kadar nimamo dovolj robnih podatkov, s katerimi omejimo prostostne stopnje pri rekonstrukciji. Najdlje časa

je raziskan problem stereovizijskega pogleda, ki je značilen za mnoga živa bitja in neposredno posnema človekov binokularni ustroj. Dve kameri z enakimi optičnimi lastnostmi in popolnoma poravnanimi optičnima osema omogočata določanje globinske oddaljenosti točk v prostoru [1]. Globinska ločljivost se z razdaljo slabša tem bolj, čim slabša je ploskovna ločljivost optičnih elementov v kamerah in čim večja je razdalja med objektivoma kamer. Ustvarjanje globinske slike zahteva iskanje korespondenčnih točk in ta korak je skupen vsem postopkom, ki rekonstruirajo prostorske strukture. Pri stereoviziji je poenostavljen, ker velja, da ima par korespondenčnih točk enako vertikalno koordinato na obeh slikah, tako da ujemanje lahko iščemo le po izbrani slikovni vrstici.

Natančnega stereo pogleda ni brez enakih kamer, kar v praksi zahteva kalibracijo oz. postopkovno izenačenje parametrov obeh kamer. To pravzaprav pomeni, da ni več potrebe po dveh kamerah, ki bi bili mehansko povezani in poravnani. S kalibracijo, ki zajema vse notranje in zunanje parametre kamer, lahko prav tako pridemo do stereo pogleda. Dva posnetka iste scene sta povezana z epipolarno omejitvijo, ki jo zrcali temeljna matrika (ang. *fundamental matrix*). V njej so združeni vsi parametri kamere. Če poznamo kalibracijsko matriko z notranjimi parametri kamere, lahko iz temeljne konstruiramo osnovno matriko (ang. *essential matrix*). Ta povezuje le zunanje parametre, torej položaj in usmeritev kamere v svetovnem koordinatnem sistemu [2].

Epipolarna geometrija vodi do dobro raziskanih postopkov, s katerimi je mogoče zadovoljivo določiti premike kamere in strukturo scene, če jo opazujemo z več pogledi (ang. *multiview constraint*). Kot rečeno, pri vseh izhajamo iz korespondenčnih točk, ki označujejo isto značilnico oz. piksel na vseh slikah scene. Ena od možnih rekonstrukcijskih rešitev izračuna s pomočjo korespondenčnih točk temeljno matriko, iz nje nato izlušči parametre kamere, ti pa določajo projekcijske matrike za obravnavane poglede [3]. Drugo možnost za določanje scenske strukture prinaša izravnava (ang. *rectification*) slik. Gre za homografsko spreminjanje usmeritve dveh pogledov na sceno, tako da potisnemo epipola v neskončnost in s tem izravnamo epipolarne premice obeh pogledov, nato pa poravnamo še njuna koordinatna sistema [4].

Čeprav so v zadnjih letih najaktualnejše raziskave nekalibriranih razmer, pri katerih se povezuje med svetovnim koordinatnim sistemom in sistemom kamere vzpostavi dinamično s t. i. samokalibracijo (ang. *self-calibration*) [5], smo se odločili preveriti primernost rekonstrukcijskih posnetkov, ki temeljijo na epipolarni geometriji v kalibrirani shemi. Želimo se namreč omejiti na primere, kjer lahko uporabimo preprosto kamero z nespremenljivimi notranjimi parametri, recimo pri navigaciji robota, ki se počasi sprehaja po neznanem prostoru. Notranje parametre kamere lahko s standardnim kalibracijskim postopkom določimo vnaprej.

V 2. poglavju razložimo ozadja znanih rekonstrukcijskih postopkov, ki smo jih preučevali, 3. poglavje pa opisuje testno okolje in rekonstrukcijske rezultate. Zadnje, 4. poglavje razpravlja o eksperimentalnih ugotovitvah in zaključuje prispevek.

## 2. REKONSTRUKCIJA 3D-SCENE IZ DVEH POGLEDOV

Postopki za 3D-rekonstrukcijo, ki smo jih preverjali, izkoriščajo omejitve epipolarne geometrije. Izhajali smo iz dveh pogledov, do katerih smo prišli z neznanima premikom in zasukom kamere. Kamero smo kalibrirali, tako da smo poznali njene notranje parametre. Vsem uporabljenim postopkom je skupno iskanje parov korespondenčnih točk. Poskušali smo doseči čim večjo gostoto teh točk, vendar nismo težili k zelo gostemu pokrivanju, ki bi zagotavljalo dobro rekonstrukcijo tudi bolj razgibanih površin. Naš namen je bil usmerjen bolj v preverjanje zanesljivosti posamezne 3D-rekonstrukcije, torej v ugotavljanje, ali so ocenjene globine rekonstruiranih prostorskih točk dovolj dobro ujemajo z realnimi razmerami, ki smo jih ob poskusih poznali.

Preizkusili smo večino pristopov, ki so vgrajeni v programskih orodjarnah oziroma knjižnicah OpenCV in MATLAB, in sestavili zaporedje operacij, opisanih v nadaljevanju. Pri izbiri so bile pomembne učinkovitost, robustnost in uspešnost rekonstrukcije pri manjših premikih in zasukih kamere.

### 2.1 Kalibracija kamere in iskanje korespondenčnih parov

Kamero smo kalibrirali s postopki, ki so vključeni v knjižnico OpenCV [6] (Camera Calibration Toolbox [7]). Omogočajo računanje kalibracijske matrike s pomočjo referenčnega objekta v obliki šahovnice. Posredujejo interne parametre kamere, pri čemer upoštevajo tudi radialna in tangencialna popačenja na slikah. Izhajali smo iz 10 slik referenčne scene, ki smo jih posneli tako, da so bili uravnoreženo prikazani vsi segmenti slik, in s tem dosegli končno optimizacijo parametrov.

S kamero smo posneli dve sliki iste statične scene. Na teh dveh slikah je bilo najprej treba najti zanesljive korespondenčne pare točk. Izkazalo se je, da je postopek SIFT (ang. *scale-invariant feature transform*) [8] manj občutljiv na večje razlike med pogledoma kot drugi preverjeni algoritmi, recimo SURF, FREAK, BRISK ali Harrisov operator za iskanje oglišč. Zato smo se odločili ugotavljati ujemanja med območji na slikah s SIFT tako, da smo uporabili deskriptorje dolžine 128 in tri ločljivostne nivoje. Določili smo množico kandidatnih točk ter poiskali pare, ki imajo najboljše ujemanje.

### 2.2 Postopek z določanjem projekcijskih matrik

Z osnovnim naborom zanesljivih korespondenčnih točk smo najprej izračunali temeljno matriko  $\mathbf{F}$ . Preverjanja različnih pristopov iz knjižnic OpenCV in MATLAB so pokazala, da je za pravilno oceno matrike nujno izločiti točke osamelce (ang. *outliers*). Izbrali smo nelinearno ocenjevanje matrike  $\mathbf{F}$  z dodanim postopkom RANSAC, tj. algoritem LMEDS [6], kakršno je na razpolago v OpenCV.

Dobljena temeljna matrika ima zagotovljen rang 2 in iz nje lahko s pomočjo kalibracijske matrike  $\mathbf{K}$  opredelimo osnovno matriko  $\mathbf{E}$ :

$$\mathbf{E} = \mathbf{K}^T \mathbf{F} \mathbf{K} . \quad (1)$$



Osnova matrika vsebuje samo zunanje parametre kamere, zato lahko iz nje izračunamo projekcijsko matriko  $\mathbf{P}_2$  za neznan položaj in usmeritev kamere, s katero je bila posneta druga slika. Postopek temelji na razcepu na singularne vrednosti in ponudi štiri različne rešitve. Med njimi je tudi prava, pri kateri ležijo vse rekonstruirane prostorske točke pred kamero. Za izračun projekcijske matrike in izbiro prave rešitve smo uporabili Hornov postopek [3]. Ker smo  $\mathbf{P}_2$  izrazili glede na projekcijsko matriko prve kamere, slednjo definiramo kot  $\mathbf{P}_1 = [\mathbf{I} \mid 0]$ .

Zadnji korak pri rekonstrukciji smo izvedli z linearno triangulacijo [3]. Z reprojektijo izračunanih prostorskih koordinat na slikovni ravnini obeh kamer smo ugotavljali razhajanja med korespondenčnimi točkami in njihovimi reprojektijami iz rekonstruiranih prostorskih točk.

### 2.3 Postopek z izravnavo slik

Projekcijski matriki  $\mathbf{P}_1$  in  $\mathbf{P}_2$ , ki smo ju izračunali v podpoglavju 2.2, določata položaj, zasuk in lastnosti dveh kamer v prostoru. Ti dve kameri sicer opazujeta isto sceno, vendar v splošnem nista poravnani: njuni slikovni ravnini nista koplanarni in njune epipolarne premice niso vzporedne. Ideja izravnave temelji na tem, da definiramo dve virtualni kameri  $\mathbf{P}_{1R}$  in  $\mathbf{P}_{2R}$ , ki imata enak položaj kot kameri  $\mathbf{P}_1$  in  $\mathbf{P}_2$ , a sta tako zasukani okoli njunih projekcijskih središč, da postaneta njuni slikovni ravnini koplanarni. Postopek izravnave izkorišča dejstvo, da imata kameri isto kalibracijsko matriko  $\mathbf{K}$  in da se matriki  $\mathbf{P}_{1R}$  in  $\mathbf{P}_{2R}$  razlikujeta le v vektorju premika. Da doseže takšne razmere, izračuna ustrezno rotacijsko matriko [9]. Transformacija, ki poravna kamero  $\mathbf{P}_1$  z novo kamero  $\mathbf{P}_{1R}$ , pomeni homografijo  $\mathbf{H}_1$  z dimenzijami  $3 \times 3$ :

$$\mathbf{H}_1 = \mathbf{P}_{1R(1:3)} \mathbf{P}_{1(1:3)}^{-1}, \quad (2)$$

pri čemer indeksi 1:3 označujejo uporabljene matrične stolpce. Na podoben način je definirana tudi transformacija  $\mathbf{H}_2$  za drugo kamero. S transformacijskima matrikama lahko sedaj preslikamo točke vhodnega para slik, pri čemer moramo zaradi neceloštevilskih indeksov uporabiti interpolacijo.

Dobimo izravnani sliki, ki imata vzporedne in ujemajoče se epipolarne premice – tako kot v primeru klasičnega stereo pogleda. Iz takšnih slik lahko globino določimo s splošno znanimi algoritmi za iskanje stereo disparitet ali pa jo izračunamo iz posameznih korespondenčnih točk kot:

$$z = \frac{t \cdot f}{d}, \quad (3)$$

pri čemer je  $z$  oddaljenost točke od projekcijskega središča kamere,  $t$  razdalja med projekcijskima središčema kamer,  $f$  je goriščna razdalja,  $d$  pa razlika med korespondenčnima točkama na izravnanih slikah.


### 3. EKSPERIMENTALNO OKOLJE IN REZULTATI

S poskusi smo želeli preveriti, kako uspešna sta izbrana postopka za rekonstrukcijo 3D-scen, če vzamemo pare posnetkov, med katerimi smo kamero premaknili in zasukali za neznano razdaljo in kot. Uporabili smo kamero Logitech QuickCam Pro 5000 [10].

Kamero smo kalibrirali po postopku, opisanem v podpoglavju 2.1, in dobili naslednje parametre:

$$K = \begin{bmatrix} 659,98 & 0 & 312,75 \\ 0 & 660,31 & 216,23 \\ 0 & 0 & 1 \end{bmatrix}.$$

V prostoru smo razmestili dve postavitvi referenčnih objektov, kakor kaže slika 1, in sceno poslikali iz različnih zornih kotov. Na sliki 1 levo vidimo tri škatle in steno v ozadju. Osredotočili smo se na dejanske globine (koordinate  $z$ ) teh objektov, ki so v svetovnem koordinatnem sistemu: 90 cm za škatlo na levi, 50 cm za škatlo v sredini, 70 cm za škatlo na desni in 120 cm za steno v ozadju. Desna podslika na sliki 1 kaže drugo sceno s 5 skodelicami in steno v ozadju. Njihove dejanske globine v svetovnem koordinatnem sistemu so za skodelice, gledano z leve proti desni: 70 cm, 120 cm, 52 cm, 87 cm in 105 cm. Stena v ozadju je od središča koordinatnega sistema oddaljena za 127 cm. V preglednicah so škatle in skodelice označene s številkami tako, da te pomenijo zaporedno številko, če objekte na sceni štejemo od leve proti desni, ozadje (stena) pa se vzame kot objekt z najvišjo številko.

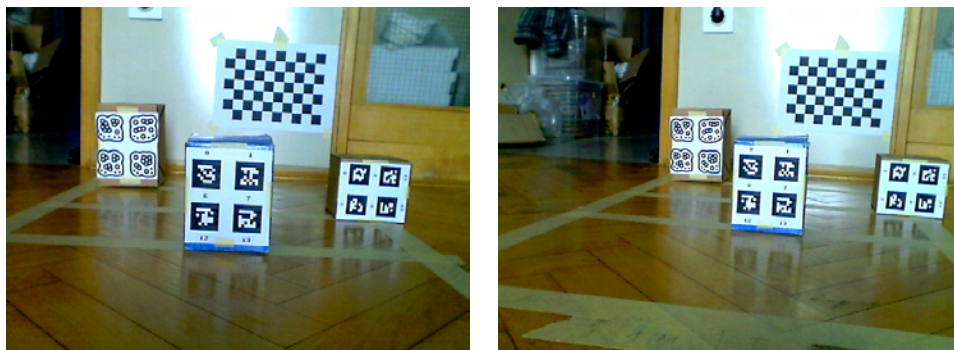


Slika 1: Referenčni postavitvi objektov za preverjanje postopkov, s katerimi smo ocenjevali njihovo globino (koordinato  $z$ ) v svetovnem koordinatnem sistemu: leva scena vsebuje 3 škatle s sprednjimi stranicami, ki ležijo v ravnini  $x$ - $y$ , desna scena pa 5 skodelic, ki so vertikalno poravnane z osjo  $x$ .

Svetovni koordinatni sistem smo poravnali s koordinatnim sistemom kamere pri prvem posnetku (začetna lega kamere).

### 3.1 Rezultati 3D-rekonstrukcije s pomočjo ocenjenih projekcijskih matrik

Za levo sceno s slike 1 smo naredili več posnetkov. Par začetnega in tretjega naslednjega kaže slika 2. Po postopku, opisanem v podpoglavju 2.2 smo ocenili povprečno globino do korespondenčnih točk, ki ležijo na sprednjih ravninah vseh treh škatel, in stene v ozadju. Rezultate za tri pare slik kaže preglednica 1. Pri prvem paru slik smo uspeli odkriti 443, pri drugem paru 404 in pri tretjem paru 367 korespondenčnih točk.



Slika 2: Dva zaporedna posnetka scene, prikazane na sliki 1 levo: prvi, levi posnetek je bil narejen pri koordinatnem sistemu kamere, poravnanem s svetovnim koordinatnim sistemom, drugi pa pri neznanih premiku in zasuku kamere.

Preglednica 1: Rekonstruirane oddaljenosti objektov za sceno s slike 1 levo

	Škatla 1	Škatla 2	Škatla 3	Ozadje
Dejanske oddaljenosti [cm]	90	50	70	120
Dejanska razmerja oddaljenosti glede na škatlo 1	1	0,56	0,78	1,33
Ocenjene oddaljenosti (prvi par)	15,5±0,1	9,2±0,1	12,8±0,2	19,5±2,2
Razmerja ocenjenih oddaljenosti	1	0,59	0,82	1,26
Ocenjene oddaljenosti (drugi par)	10,1±0,2	5,9±0,03	9,1±0,03	13,0±0,1
Razmerja ocenjenih oddaljenosti	1	0,58	0,90	1,29
Ocenjene oddaljenosti (tretji par)	5,5±0,1	3,3±0,03	4,7±0,1	7,5±0,2
Razmerja ocenjenih oddaljenosti	1	0,6	0,85	1,36

Za sceno s slike 1 desno smo prav tako naredili več posnetkov, od katerih začetni par kaže slika 3. Po postopku, opisanem v podpoglavju 2.2, smo ocenili povprečno globino do korespondenčnih točk, ki ležijo na najmanj oddaljenih vertikalnih okroglinah vseh petih skodelic in stene v ozadju. Rezultate kaže preglednica 2. Pri prvem paru slik smo uspeli odkriti 453, pri drugem paru pa 408 korespondenčnih točk.




Slika 3: Dva zaporedna posnetka scene, prikazane na sliki 1 desno: prvi, levi posnetek je bil narejen pri koordinatnem sistemu kamere, poravnanim s svetovnim koordinatnim sistemom, drugi pa pri neznanih premiku in zasuku kamere.

Preglednica 2: Rekonstruirane oddaljenosti objektov za sceno s slike 1 desno

	Skodeli- ca 1	Skodeli- ca 2	Skodeli- ca 3	Skodeli- ca 4	Skodeli- ca 5	Ozadje
Dejanske oddaljenosti [cm]	70	120	52	87	105	127
Razmerja oddaljenosti glede na skodelico 1	1	1,71	0,74	1,24	1,5	1,81
Ocenjene oddaljenosti (prvi par)	13,9±0,3	24,6±0,6	10,1±0,1	17,4±0,3	20,4±0,4	26,4±0,4
Razmerja ocenjenih oddaljenosti	1	1,77	0,73	1,25	1,47	1,89
Ocenjene oddaljenosti (drugi par)	4,6±0,05	7,7±0,4	3,8±0,5	5,9±0,1	6,7±0,1	8,6±0,2
Razmerja ocenjenih oddaljenosti	1	1,67	0,83	1,28	1,45	1,87

Za zgled prikazujemo rekonstruirano 3D-sceno za oba preverjana primera na sliki 4. Rekonstruirane prostorske točke, ki jih je toliko kot korespondenčnih točk, smo izrisali v MATLAB-u. Čeprav so točke redko razporejene, vendarle kažejo skladnost rekonstruirane scene z dejanskimi razmerami, ilustriranimi na sliki 1.



Slika 4: Prostorski rekonstrukciji za sceni s slike 1: upoštevana sta bila prva para slik iz preglednic 1 in 2, škatle levo, skodelice desno.

### 3.2 Rezultati 3D-rekonstrukcije z izravnavanjem slik

Sceno s slike 1 smo ovrednotili še s postopkom, ki izravna par posnetkov te scene. Rezultati so zbrani v preglednicah 3 in 4, primer rekonstruiranih točk v 3D prostoru pa je prikazan na sliki 5.

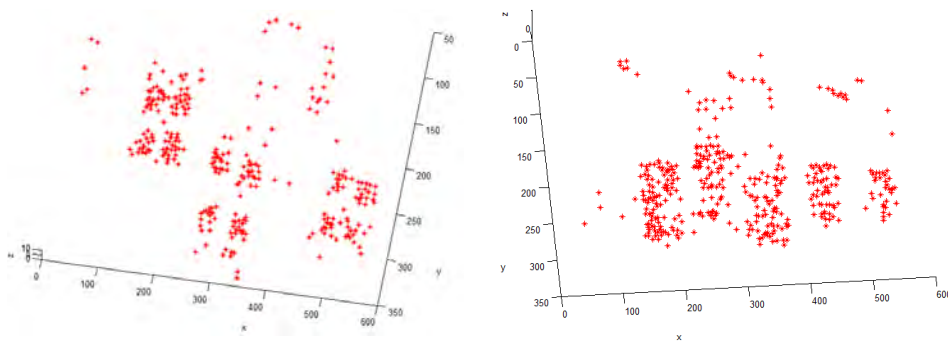
Preglednica 3: Rekonstruirane oddaljenosti objektov za sceno s slike 1 levo

	Škatla 1	Škatla 2	Škatla 3	Ozadje
Dejanske oddaljenosti [cm]	90	50	70	120
Dejanska razmerja oddaljenosti glede na škatlo 1	1	0,56	0,78	1,33
Ocenjene oddaljenosti (prvi par)	46,8±0,4	18,2±0,6	36,9±0,6	53,4±9,4
Razmerja ocenjenih oddaljenosti	1	0,39	0,79	1,14
Ocenjene oddaljenosti (drugi par)	42,1±0,6	5,4±1,9	73,8±6,8	83±11,4
Razmerja ocenjenih oddaljenosti	1	0,13	1,75	1,97
Ocenjene oddaljenosti (tretji par)	107±0,4	84,2±0,7	140±7,5	143±11,6
Razmerja ocenjenih oddaljenosti	1	0,78	1,3	1,34

Preglednica 4: Rekonstruirane oddaljenosti objektov za sceno s slike 1 desno

	Skodeli- ca 1	Skodeli- ca 2	Skodeli- ca 3	Skodeli- ca 4	Skodeli- ca 5	Ozadje
Dejanske oddaljenosti [cm]	70	120	52	87	105	127
Razmerja oddaljenosti glede na skodelico 1	1	1,71	0,74	1,24	1,5	1,81
Ocenjene oddaljenosti (prvi par)	31,3±1,0	66,9±3,2	23,0±0,2	24,8±2,1	31,4±0,5	62,1±2,0

Razmerja ocenjenih oddaljenosti	1	2,13	0,73	0,79	1	1,98
Ocenjene oddaljenosti (drugi par)	$55,1 \pm 7,9$	$71,0 \pm 6,2$	$27,4 \pm 2,5$	$27,1 \pm 4,4$	$39 \pm 23,1$	$74,6 \pm 3,3$
Razmerja ocenjenih oddaljenosti	1	1,29	0,5	0,49	0,71	1,35



Slika 5: Prostorski rekonstrukciji za sceni s slike 1: upoštevana sta bila prva para slik iz preglednic 1 in 2, škatle levo, skodelice desno.

#### 4. RAZPRAVA IN SKLEPI

Naš poskus, ki je sicer omejen na kalibrirane razmere in opravljen le s preprosto eksperimentalno postavitvijo, je pokazal, da je lahko rekonstrukcija strukture za 3D-sceno, dosežena z elementi epipolarne geometrije in s triangulacijo, uspešna tudi izhajajoč samo iz dveh posnetkov scene. Ustreznost rekonstruiranih projekcijskih matrik smo ocenili z reprojekcijo dobljenih prostorskih točk na slikovni ravnini pri obeh legah kamere. Povprečna reprojekcijska napaka znaša pri vseh 10 obravnavanih slikah  $0,26 \pm 0,13$  slikovnih elementov.

Preglednici 1 in 2 nakazujeta, da smo v izbranih primerih globine objektov določili s povprečnima odstopanjema 5,03 % za prvo in 3,29 % za drugo sceno glede na dejanske razdalje. Seveda primerjamo pri tem razmerja glede na oddaljenost prvega objekta, saj uporabljeni postopki pripeljejo le do metrične rekonstrukcije. Poleg tega lahko ugotovimo, da so oddaljenosti koplanarnih točk prepoznane z zelo majhno varianco. Primer s prvo sceno in ploskvami škatel rekonstruira koplanarne globine z odstopanjem 2,14 %.

Poskusi z drugim pristopom, ki temelji na izravnavi slik in stereo disparitetah, so dali precej slabše rezultate. Preglednici 3 in 4 potrjujeta, da smo oddaljenost objektov ocenili s povprečnima odstopanjema 43,37 % za prvo in 30 % za drugo sceno glede na dejanske

oddaljenosti. Tudi koplanarne točke so bile ocenjene z veliko večjim odstopanjem, in sicer v velikosti 6,3 %.

Postopek iz podpoglavja 2.2 smo nadgradili še s prilagajanjem naborov točk (ang. *bundle adjustment* [11]). Izkazalo se je, da so se pri rekonstruiranih scenah ocene oddaljenosti in stabilnost koplanarnih točk izboljšale za manj kot pol odstotka.

Primerljivo robustnost ocen smo dosegli pri zelo različnih parih pogledov na sceno, in sicer od začetnih, kjer je bila kamera med pogledoma premaknjena le za nekaj centimetrov, do končnih, pri katerih je bila razdalja med pogledoma več kot četrtna scenske širine. Treba pa je dodati, da globine na preučevanih scenah niso presegale 127 cm, kar zagotavlja večje disparitete in manjše globinske napake. Če bi opazovali bolj oddaljene objekte, bi morali računati z večjo rekonstrukcijsko negotovostjo.

Naši poskusi kažejo, da večina splošno razpoložljivih postopkov, vgrajenih v programske knjižnice za kalibracijo slik, epipolarno geometrijo in triangulacijo deluje zanesljivo, robustno in s primerljivo točnostjo. Drugače je z implementiranimi postopki za izravnavo slik in iskanje stereo disparitet. Praviloma ob izravnavi objekte elastično deformirajo tako zelo, da se podrejo proporci znotraj slikovnih območij in med njimi. Poleg tega tudi iskanje disparitet na izravnanih slikah zaradi tega večinoma ni uspešno. Če se omejimo na posamezne točke in med izravnavo sledimo premikom njihovih koordinat, lahko pridemo do smiselnih disparitet, s splošnim iskanjem ujemanj med izravnanimi slikama pa po naših izkušnjah ne dosežemo uporabnih rezultatov.

## ZAHVALA

Raziskava je bila delno podprta z reintegracijskim projektom 7. evropskega okvirnega programa qFATIGUE (pogodba št. FP7-PEOPLE-2010-RG-269438).

## LITERATURA

- [1] D. A. Forsyth, J. Ponce (2011), *Computer vision: a modern approach*, 2. izdaja, Prentice Hall.
- [2] E. Trucco, A. Verri (1998), *Introductory Techniques for 3-D Computer Vision*, Prentice-Hall.
- [3] R. I. Hartley, A. Zisserman (2000), *Multiple View Geometry in Computer Vision*, Cambridge University Press.
- [4] O. Faugeras, Q. T. Luong (2001), *The geometry of multiple images*, MIT Press.
- [5] D. Q. Huynh, A. Heyden (2005), Scene point constraints in camera auto-calibration: an implementational perspective, *Image and vision computing*, vol. 23, str. 747-760.

- [6] Open source computer vision library, <http://opencv.org/>.
- [7] Camera calibration toolbox for Matlab, [http://www.vision.caltech.edu/bouguetj/calib\\_doc/](http://www.vision.caltech.edu/bouguetj/calib_doc/).
- [8] D. G. Lowe (2004), Distinctive Image Features from Scale-Invariant Keypoints, *International Journal of Computer Vision*, vol. 60-2, str. 91-110.
- [9] A. Fusiello, E. Trucco, A. Verri (2000), A compact algorithm for rectification of stereo pairs, *Machine Vision and Applications*, vol. 12, str. 16-22
- [10] Spletna kamera Logitech QuickCam Pro 5000, <http://www.logitech.com/en-us/support/243>.
- [11] M. I. A. Lourakis, A. A. Argyros (2009), SBA: A Software Package for Generic Sparse Bundle Adjustment, *ACM Trans. Math. Software*, vol. 36, št. 1, str. 1-30.



## **MEDICINSKE IN BIOMEDICINSKE APLIKACIJE**

---



# PROSTORSKO DOLOČANJE KRIVULJ HRBTENICE NA OSNOVI 3D LASERSKE PROFILOMETRIJE

Primož Poredoš<sup>1</sup>, Dušan Čelan<sup>2</sup>, Janez Možina<sup>1</sup>, Matija Jezeršek<sup>1</sup>

<sup>1</sup>Fakulteta za strojništvo, Univerza v Ljubljani

<sup>2</sup>Univerzitetni klinični center Maribor

---

**POVZETEK:** *V prispevku je predstavljen razvoj programske opreme za polavtomatsko določitev prostorske krivulje hrbtenice na podlagi izmerjene 3D oblike hrbta bolnika z laserskim profilometrom. Merilnik temelji na linijski laserski triangulaciji ter pomikanju laserske ravnine vzdolž hrbta. Njegovo merilno območje na razdalji enega metra je 300×700×500 mm, meritev opravi v 10 sekundah, natančnost meritve posamezne točke je 0,1 mm. Program omogoča primerjavo avtomatsko določene prostorske krivulje s prostorsko krivuljo, določeno s strani zdravnika, z metodo standardnega odklona razlik v sagitalni in frontalni ravnini. Rezultati meritev kažejo, da tipično odstopanje v sagitalni ravnini znaša 0,5 mm in v frontalni ravnini 4,0 mm. Vzrok za slabše ujemanje v frontalni ravnini pripisujemo specifičnim lastnosti bolnika, telesni konstituciji bolnika ter neponovljivosti drže bolnika med in po ročni označbi poteka hrbtenice.*

---

## 1. UVOD

Uporaba laserskih merilnih sistemov postaja vse bolj razširjena v industriji ter medicini. Predvsem v medicini se ob pojavljanju naprednih oblik zdravljenja povečuje potreba po brezdotičnih, prenosnih, robustnih, natančnih, učinkovitih in neinvazivnih merilnih sistemih, ki za bolnika predstavljajo minimalno stopnjo psihofizičnega stresa [1,2]. Metrologija te vrste predstavlja obetavno možnost za izognitev izpostavljenosti slikovnim preiskavam z ionizirajočim sevanjem (rentgenski posnetki, CT). Trenutno se namreč v medicini še vedno uporabljajo številne invazivne ter zahtevne psihofizične diagnostike [3-5].


Osnovni namen predstavljene merilne metode je možnost brezdotičnega, natančnega, in za bolnika popolnoma neinvazivnega 3D posnetka hrbta ter objektivnega vrednotenja ustreznosti drže bolnikovega telesa z namensko razvito programsko opremo. Ustreznost drže telesa je eden od problemov, ki spremlja številne gibalne težave bolnikov [6]. Tekom evolucije človeka je pokončna drža človeka zahtevala prilagoditev hrbtenice, zaradi česar so se oblikovale prožne sagitalne krivine v obliki dvojne črke S. Izraženost krivin je le eno izmed meril dobre drže človeškega telesa. To poskušajo zdravniki ugotoviti s kliničnimi pregledi, kar pa ne zadošča pogoj po objektivni presoji zdravnika. Poleg kliničnega opisa je pomembna tudi kvantitativna ocena z eno od merilnih metod. Slikovna RTG metoda je sicer najnatančnejša, vendar za bolnika tudi zelo obremenjujoča, saj je pri tej metodi prisotno ionizirajoče sevanje. Zaradi tega so zaželeno številne alternativne merilne metode, ki merijo krivine hrbtenice na površini telesa. Na tem mestu je potrebno razložiti razliko med krivuljo in krivino. Krivulja je prema ali kriva črta, bodisi v ravnini – ravninska krivulja, bodisi v prostoru – prostorska krivulja. Krivina pa predstavlja stopnjo ukrivljenosti krivulje. V nadaljevanju bomo uporabljali izključno izraz krivulja.

Pri kliničnem delu in v raziskavah so uporabljene številne metode, najpogosteje mehanske (DeBrunnerjev kifometer, »Flexicurve ruler«, Gravitacijski goniometer, Myrinov inklinometer), elektronske (kurviskop, ultrazvočna meritev) ter optične [6]. Ena izmed optičnih metod je tudi laserska triangulacija, ki predstavlja za bolnika neobremenjujoč način 2D in 3D posnetka hrbta ter nadaljnjo analizo 3D površine telesa.

Tako smo na Fakulteti za strojništvo v Ljubljani za že obstoječe 2D in 3D posnetke hrbta razvili programsko opremo, ki hitro, natančno in polavtomatsko zaznava prostorske krivulje hrbtenice. V tem prispevku je predstavljen razvoj programske opreme ter postopek analize izmerjenih 2D in 3D posnetkov hrbta za prostorsko določanje krivulj hrbtenice pri ljudeh z gibalnimi težavami na osnovi 3D laserske profilometrije. Pričujoči prispevek je nadgradnja prispevka, ki opisuje meritve sagitalnih krivin hrbtenice z uporabo metod laserske triangulacije [7].

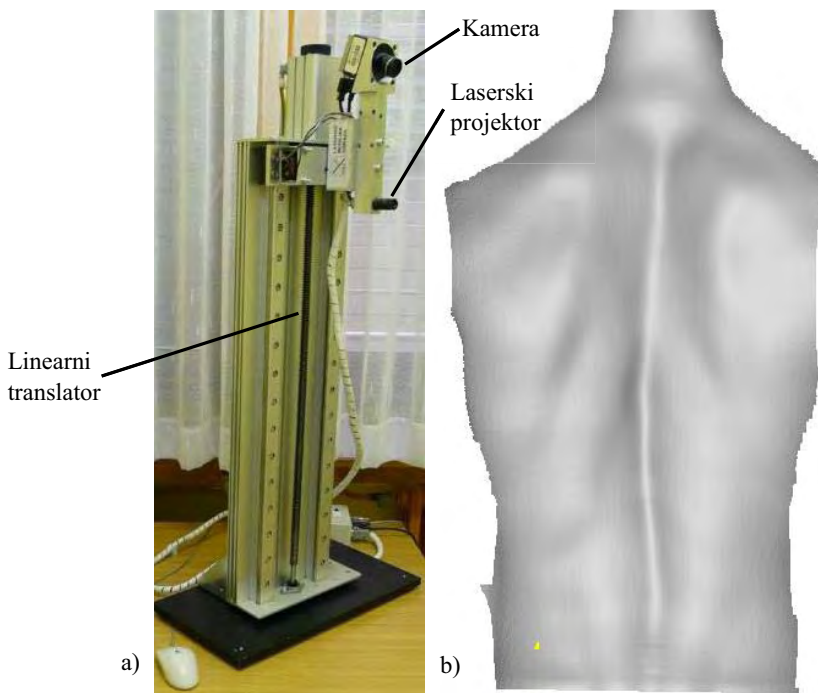
## 2. MERILNI SISTEM

Meritve so potekale s 3D laserskim profilometrom, razvitim na Fakulteti za strojništvo v Ljubljani. Temelji na translacijskem premikanju laserske ravnine vzdolž merjene površine, pri čemer merilnik deluje po principu linijske laserske triangulacije [1,8]. Merjeno površino osvetlimo s svetlobnim izvorom – laserjem, ki na površino projicira eno lasersko ravnino. Na mestu, kjer svetlobna ravnina seka merjeno površino, nastane presečna krivulja, ki jo pod drugim zornim kotom opazujemo s kamero. Ker poznamo razdaljo med kamero in laserskim izvorom ter njun medsebojni kot, lahko po metodi triangulacije določimo položaj presečne krivulje, kar nam omogoča izračun položaja točk v 3D prostoru. Tako pridobimo oblak točk, ki služi za nadaljnjo obdelavo podatkov. Princip linijske laserske triangulacije prikazuje slika 1.



Slika 1: Princip linijske laserske triangulacije in glavne anatomske ravnine.

Temeljna elementa merilnika sta črno-bela kamera in laserski linijski projektor, kar prikazuje slika 2a. Kamera podjetja Basler z oznako A301f vsebuje CCD slikovno zaznavalo velikosti 1/2". Ločljivost kamere znaša 658 x 494 slikovnih elementov, največja frekvenca zajema slik znaša 80 Hz. Z računalnikom je povezana preko FireWire vodila. Laserski linijski projektor podjetja Lasiris z močjo 5mW in valovno dolžino  $\lambda = 670$  nm (rdeča barva) na merjeno telo preko optičnih elementov projicira eno lasersko ravnino.



Slika 2: Laserski profilometer (a) za izmero 3D oblike celotnega hrbta (b).

Ker želimo zajeti obliko celotnega hrbta, je potrebno togo povezan sklop laserskega projektorja in kamere pomikati vzdolž hrbta ter ob tem z določenim korakom meriti profile površine. Tovrstno pomikanje se izvaja s pomočjo računalniško krmiljenega linearnega translatorja.

Hitrost merjenja presečnih krivulj vzdolž hrbta je 80 profilov na sekundo. Meritev tako traja okoli 10 sekund pri 700 mm vzdolžnega pomika. Najmanjša razdalja med dvema izmerjenima profiloma (ločljivost meritve) zavisi od translacijske hitrosti in frekvence meritve in je okoli 0,87 mm. Celotno merilno območje je odvisno od kamerine optike in dolžine vzdolžnega pomika ter znaša 300×700×500 mm (širina×višina×globina). Natančnost meritve posamezne točke je 0,1 mm. Primer 3D meritve hrbta je prikazan na sliki 2b.


Sestavni del merilnega sistema poleg merilnika je tudi računalnik. S posebej razvito programsko opremo omogoča v prvem koraku določitev presečnih krivulj s podtočkovno ločljivostjo, ki se izvaja v realnem času med pomikanjem merilnika vzdolž hrbta. Po končani meritvi se izvrši shranjevanje izmerjene površine, ki je popisana z urejenim oblakom točk. Za vsako točko se shranijo njene prostorske (X, Y in Z) koordinate ter svetlost. Sledi prostorsko določanje krivulj hrbtenice, kar je predstavljeno v naslednjem poglavju.

### 3. ANALIZA MERITEV

Osnovni cilj analize meritev je pridobiti prostorske krivulje prsnega in ledvenega dela hrbtenice na podlagi izmerjene 3D oblike hrbta. V nadaljevanju bomo to krivuljo imenovali samodejna krivulja. Do sedaj smo namreč lahko pridobili krivulje v sredinski – sagitalni ravnini. Novo razviti algoritmi pa omogočajo analizo krivulj v vseh treh glavnih orientacijskih ravninah, torej v sredinski – sagitalni, čelni – frontalni ter prečni – transverzalni ravnini (slika 1). Za zdravnike so najbolj zanimive krivulje v sagitalni in frontalni ravnini.

Algoritem smo verificirali tako, da smo rezultate primerjali z ročno določeno krivuljo poteka hrbtenice (v nadaljevanju ročna krivulja), ki jo je s temnim alkoholnim flomastrom označil zdravnik. Ročna označba poteka prsne in ledvene hrbtenice je bila izvršena s palpacijo trnastih odrastkov pod kožo in zarisom poteka le teh v celotnem poteku opazovanega dela hrbtenice. Posebej so bili zarisani tudi prehodi med vratnim in prsnim, prsnim in ledvenim ter ledvenim in križničnim delom hrbtenice s kratko vodoravno črto. Odstopanje med obema potekoma smo merili s standardnim odklonom. V nadaljevanju so opisani posamezni koraki algoritmov.

**a) Detekcija ročne krivulje.** Najprej smo ročno določili območje interesa, znotraj katerega se je iskalo ročno in tudi samodejno krivuljo. Znotraj določenega območja interesa se je detekcija ročne krivulja vršila izključno na sivinski sliki, ki predstavlja svetlost izmerjenih 3D točk. Sivinsko sliko smo najprej filtrirali z Gaussovimi konvolucijskim filtrom (velikost jedra znaša  $7 \times 7$  točk), s čimer smo zgladili ostre prehode vrednosti slikovnih elementov na tistih mestih, kjer je bil prisoten velik kontrast. Detekcija označbe je potekala po vrsticah, tako da smo iskali intenzitetni minimum s tehniko aproksimacije parabole na okoliške točke. S primernimi nastavitvami (intenzitetni prag zaznave je znašal od 0,08 do 0,15) smo tako pridobili prekinjeno črto, ki je potekala po sredini temnih črt na hrbtu. Vrzeli med posameznimi črtami smo zapolnili z eno-dimenzionalno interpolacijo. Tako smo pridobili kontinuirno 2D krivuljo, ki ponazarja ročno krivuljo, kar prikazuje slika 3.




*Slika 3: Primer ročno določene krivulje poteka hrbtenice. Sivinska slika prikazuje oznako, ki jo je na hrbet bolnika narisal zdravnik ortoped, rumena krivulja pa je rezultat računalniške detekcije. Vodoravne oznake razmejujejo posamezna območja hrbtenice.*

**b) Detekcija samodejne krivulje na osnovi 3D oblike hrbta.** V tem koraku smo uporabili izključno globinsko sliko 3D posnetka hrbta. Če opazujemo ukrivljenost površine človeškega hrbta, lahko vidimo, da je na nekaterih mestih pozitivno ukrivljena (kanali oziroma doline) in drugje negativno ukrivljena. Zato smo za detekcijo krivulje hrbtenice uporabili izračun ukrivljenosti površine hrbta prečno na smer hrbtenice. Ta je namreč invariantna na orientacijo bolnika. Enačba za izračun ukrivljenosti površine v smeri  $y$ , zapisane v eksplisitivni obliki je [9]:

$$K = \frac{\frac{d^2z}{dy^2}}{\left[1 + \left(\frac{dz}{dy}\right)^2\right]^{3/2}}$$


Krožnica s polmerom  $a$  ima v vseh svojih točkah ukrivljenost enako  $K = 1/a$ . Premica ima ukrivljenost enako  $K = 0$ .

Rezultat izračuna ukrivljenosti površine je prikazan na sliki 4. Pozitivno ukrivljena površina hrbta se nahaja na belo obarvanih območjih, negativno ukrivljena pa na temnih.



*Slika 4: Primer ukrivljenosti hrbta, izračunane iz 3D izmere hrbta. Svetla področja predstavljajo pozitivno ukrivljenost, temna področja predstavljajo negativno ukrivljenost površine hrbta.*

Enako kot pri drugem koraku analize meritev, smo tudi tukaj uporabili detekcijo ekstremov vzdolž posamezne slikovne vrstice s tehniko aproksimacije parabole na okoliške točke. Pri vsaki meritvi posebej je tudi tukaj potrebno določiti prag zaznave ekstremov (intenzitetni prag zaznave je znašal od 0,1 do 0,3). S primernimi nastavitvami smo tako pridobili kontinuirno 2D krivuljo, ki ponazarja samodejno krivuljo, kar prikazuje slika 5.



Slika 5: Primer krivulje poteka hrbtenice določene na podlagi 3D posnetka hrbta (tako imenovana samodejna krivulja).

**c) Izračun prostorskih krivulj.** V tem koraku smo na osnovi slikovnih koordinat detektiranih krivulj ekstrahirali prostorski krivulji, ki ponazarjata ročno in samodejno krivuljo. Obe prostorski krivulji sta prikazani v X-Y oziroma frontalni (slika 6a) in X-Z oziroma sagitalni ravnini (slika 6c).

**d) Polinomska aproksimacija obeh prostorskih krivulj.** Na osnovi poskusov pri vsaki meritvi posebej smo določili stopnjo polinoma, ki je izkazovala najboljše prileganje obema krivuljama. Tipične stopnje obeh polinomov so tako bile od 3 do 5 stopnje pri vseh meritvah.


**e) Izračun medsebojnega ujemanja obeh krivulj.** Primerjava prostorskih krivulj se je izvedla z izračunom standardnega odklona razlik soležnih točk obeh krivulj po enačbah:

$$\sigma_{X-Y} = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_{R,i} - Y_{S,i})^2}$$

$$\sigma_{X-Z} = \sqrt{\frac{1}{N} \sum_{i=1}^N (Z_{R,i} - Z_{S,i})^2}$$

pri čemer indeks  $R$  označuje ročno krivuljo,  $S$  pa samodejno krivuljo.



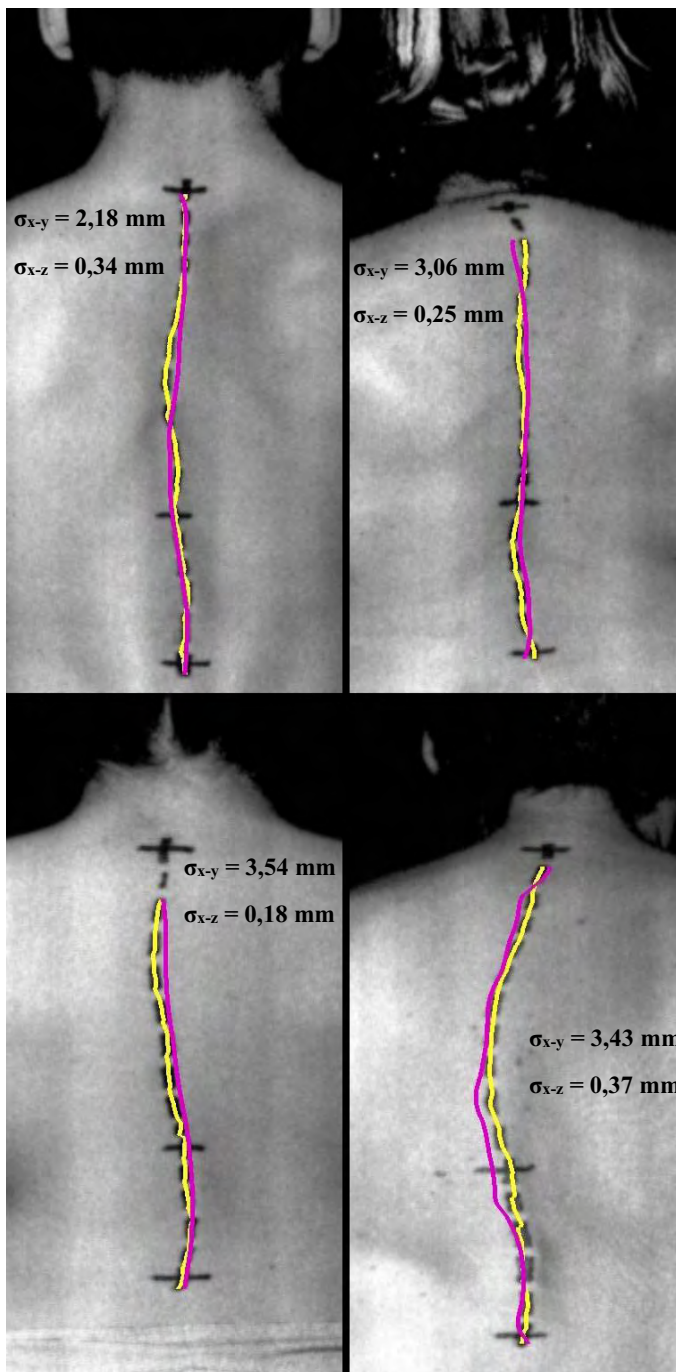


Slika 6: Prostorska ročna krivulja (črne barve) in prostorska samodejna krivulja (vijolične barve) v  $X$ - $Y$  oziroma frontalni (a) in  $X$ - $Z$  oziroma sagitalni ravnini (c). Polinomsko aproksimirani prostorski krivulji v frontalni (b) in sagitalni (d) ravnini.

## 4. PRIMERI

Meritve bolnikov so potekale v Univerzitetnem kliničnem centru Maribor. Opravljene so bile meritve na šestnajstih bolnikih, pri čemer so bile pri vsakem bolniku opravljene po tri meritve. Primeri štirih meritev so prikazani na sliki 7. Za vsako izmed meritev je dodan podatek o standardnih odklonih razlik ročne in samodejne krivulje v frontalni in sagitalni ravnini.

Vidimo, da je prekrivanje ročne in samodejne krivulje v  $X$ - $Z$  (sagitalni) ravnini zelo dobro, saj pri vseh štirih primerih  $\sigma_{x-z}$  ni večja od 0,5 mm. Na drugi strani pa je standardni odklon razlik obeh krivulj v  $X$ - $Y$  (frontalni) ravnini nekajkrat večji ( $\sigma_{x-y} \approx 4,0$  mm). Slabše prekrivanje obeh krivulj se opazi tudi iz slike 7, ki prikazuje štiri primere meritev v  $X$ - $Y$  ravnini. Med izvajanjem analize meritev smo ugotavljali vzroke za slabše prekrivanje krivulj v frontalni ravnini. Eden izmed njih je najverjetneje specifična lastnost bolnikov, saj imajo ti med seboj različno debelino kožne gube, telesno konstitucijo ter različno izražen potek hrbtenice s pozitivno in/ali negativno ukrivljenostjo površine hrpta. Drug vzrok bi lahko bil posledica prečnega premika kože glede na vretenca med in po ročni označbi poteka hrbtenice. Na sliki 7 se vidi tudi krajši ekstrahirani krivulji v vseh štirih primerih. To je predvsem posledica slabše detekcije samodejne krivulje proti vratu, saj se nad lopaticami reliefnost površine postopoma zmanjšuje, kar je lepo vidno tudi na sliki 2b. Zaradi tega z zmanjšanim območjem interesa v  $X$  smeri omejimo tudi detekcijo ročne krivulje, saj za izračun obeh standardnih odklonov razlik potrebujemo krivulji enakih dolžin.



Slika 7: Prostorske krivulje – ročna (rumena) in samodejna (vijolična) ter standardna odklona razlik obeh krivulj v X-Y (frontalni) in X-Z (sagitalni) ravnini na primeru štirih bolnikov.

## 5. ZAKLJUČEK

V pričujočem prispevku je predstavljen razvoj programske opreme za polavtomatsko zaznavo prostorske krivulje prsne in ledvene hrbtenice na podlagi izmerjene 3D oblike hrbta bolnika. Površino hrbta smo merili z laserskim 3D profilometrom, z natančnostjo 0,1 mm. Čas meritve znaša 10 sekund.

Rezultate smo primerjali s prostorskimi krivuljami, ki smo jih določili iz ročno označenega poteka hrbtenice s palpacijo trnastih odrastkov pod kožo. Tipično odstopanje med samodejno in ročno krivuljo znaša v sagitalni ravnini 0,5 mm in v frontalni ravnini 4,0 mm. Vzrok za večja odstopanja v frontalni ravnini pripisujemo predvsem debelini kožne gube, telesni konstituciji bolnika ter neponovljivosti drže bolnika med in po ročni označbi poteka hrbtenice.

Raziskavo bomo nadaljevali na večjem številu preiskovancev in poskušali najti izvore merilne negotovosti, ki lahko na eni strani izvira iz nenatančnosti ročne označbe trnastih odrastkov, po drugi strani pa iz merilnih algoritmov programske opreme.

## 6. LITERATURA

1. Jezeršek, M.: Laserski sistem za tridimenzionalno merjenje hitro spreminjajoče se oblike teles, Doktorsko delo, Fakulteta za strojništvo, 2004.
2. Povšič, K.: 3D Lasersko merjenje oblike prsnega koša med dihanjem, Diplomsko naloga univerzitetnega študija, Fakulteta za strojništvo, 2011.
3. Wang, Y., et al. (2013). "Metal artifacts reduction using monochromatic images from spectral CT: Evaluation of pedicle screws in patients with scoliosis." *European Journal of Radiology* 82(8): e360-e366.
4. Musa, A. A. (1999). "Methods of assessing spinal radiographs in scoliosis are functions of its geometry." *Computerized Medical Imaging and Graphics* 23(4): 201-203.
5. Alves de Araújo, M. E., et al. (2012). "The effectiveness of the Pilates method: Reducing the degree of non-structural scoliosis, and improving flexibility and pain in female college students." *Journal of Bodywork and Movement Therapies* 16(2): 191-198.
6. Čelan, D.: Meritev krivin prsne in ledvene hrbtenice z metodo laserske triangulacije, Doktorsko delo, Medicinska fakulteta Univerze v Mariboru, 2011.
7. Čelan, D., M. Palfy, et al. (2012). "Measurement of Spinal Sagittal Curvatures using the Laser Triangulation Method." *Collegium Antropologicum* 36.
8. Bračun, D.: Meritev oblike teles na osnovi laserske triangulacije, Doktorsko delo, Fakulteta za strojništvo, 2002.
9. Bronstein, I. N., Semendjajew K. A., et al.: Matematični priročnik, Tehniška založba Slovenije, 1997.

# ANALIZA MODULARNOSTI OBJEKTOV V BIOLOGIJI

Tina Klenovšek

Oddelek za biologijo

Fakulteta za naravoslovje in matematiko, Univerza v Mariboru

E-pošta: tina.klenovsek@uni-mb.si

---

**POVZETEK:** *Za organizme in njihove strukture je značilna modularna zgradba. To pomeni, da so nekateri deli celote zaradi skupne funkcije, razvoja ali genetskega izvora tesneje povezani in relativno neodvisni od drugih delov. V prispevku je predstavljena analiza modularnosti objektov z uporabo geometrijske morfometrije na primeru lobanje. Metoda temelji na oslonilnih točkah, s katerimi opišemo obliko dvo- ali trirazsežnega objekta. Hipotezo o modularni zgradbi objekta testiramo s primerjavo stopnje kovariabilnosti med hipotetičnimi moduli in vsemi ostalimi delitvami točk na enako število in velikost skupin točk kot pri hipotetičnih moduli. Analiza modularnosti objektov je pomembna, saj nizka kovariabilnost med deli objektov omogoča njihov relativno neodvisen razvoj in spremembe oblike objekta kot celote.*

---

## 1. UVOD

Poznavanje oblike in zgradbe organizmov je v biologiji zelo pomembno. Organizme glede na zgradbo uvrščamo v sistem, sklepamo na medsebojno sorodnost, način življenja in evolucijski razvoj. Obliko organizmov ter njihovih struktur lahko opišemo ali merimo. Z merjenjem velikosti in oblike organizmov se ukvarja morfometrija.

Večina organizmov ima zelo kompleksno zgradbo, kar je v morfometriji od nekdaj predstavljalo problem. Še pred dvema desetletjema so znali meriti samo velikost organizmov in njihovih struktur (npr. maso in dolžino). Z metodo določanja oslonilnih točk, t. i. geometrijsko morfometrijo, lahko danes velikost in obliko organizmov analiziramo povsem ločeno, geometrijo morfoloških struktur pa ohranimo skozi celotno analizo [1]. Zelo pomemben napredek v morfometriji predstavlja tudi 3D tehnologija, ki postaja vse bolj učinkovita in dostopna. Kljub temu je najenostavnejši in najbolj priljubljen način geometrijsko morfometrične analize še zmeraj analiza dvorazsežnih posnetkov objektov (npr. fotografij površine, mikroskopskih rezin, rentgenskih posnetkov).

Morfologija organizmov se spreminja tako v osebnem (od oploditve do smrti) kot evolucijskem razvoju, a te spremembe so v veliki meri v naprej določene in omejene z genetskim zapisom in naravno selekcijo. Eden izmed omejujočih dejavnikov morfoloških

sprememb je funkcionalna, razvojna ali genetska povezanost posameznih delov objekta. Na primeru človeške lobanje to pomeni, da se spodnja čeljust ne more razvijati neodvisno od zgornje, saj zgornja in spodnja čeljust tvorita funkcionalno celoto. Vsi deli objekta niso nikdar enakomerno povezani. Nekateri deli so tesneje povezani in relativno neodvisni od ostalih delov. Takšne razmeroma samostojne dele celote imenujemo moduli [2]. Znano je, da je spodnja čeljustnica sesalcev razdeljena na dva modula, na sprednji ali ustni del z zobmi in zadnji del ali čeljustno vejo. Tudi lobanja sesalcev je razdeljena na dva modula, na obrazni in možganski del.

Modularnost je še posebej pomembna za razumevanje evolucije struktur. Večja modularnost pomeni manjšo povezanost delov strukture v celoto in s tem možnost neodvisnega razvoja posameznih modulov [2]. Višja stopnja modularnosti torej poenostavljeno pomeni večjo evolucijsko fleksibilnost.

Geometrijska morfometrija omogoča zajemanje geometrije struktur v dvo- in trirazsežnem prostoru, multivariatne statistične analize in vizualizacijo rezultatov ter hkrati brezplačne in uporabnikom prijazne programe za analizo modularnosti. Namen prispevka je predstaviti analizo modularnosti z geometrijsko morfometrijo v programu MorphoJ [3]. Analiza deluje po principu testiranja hipoteze o obstoju v naprej določenih modulov [4]. Kot vzorčni objekt bom uporabila lobanjo, vendar je metoda univerzalna in njena uporaba ni omejena na biološke objekte.

## 2. MATERIAL IN METODE

Uporabila sem vzorec 140 lobanj talne veeverice. Za analizo sem uporabila samo spodnjo stran lobanje (brez spodnje čeljusti), ki je razmeroma ploska (večina vidnih struktur je v eni ravnini) in jo lahko analiziramo v dvorazsežnem prostoru. Lobanje sem fotografirala z digitalnim fotoaparatom Cannon EOS 450D. Vse lobanje sem fotografirala pri enaki ločljivosti ter razdalji lobanja – fotoaparata. Pazila sem, da sta bili spodnja stran lobanje in leča objektivna vzporedni.


Na vsaki fotografiji spodnje strani lobanje sem določila 22 oslonilnih točk (slika 1) v programu TpsDig2 [5]. Z oslonilnimi točkami sem zajela geometrijo spodnje strani lobanje in jo opisala z nizom kartezijskih ( $x$  in  $y$ ) koordinat. Ker je lobanja simetrična struktura, sem točke določila samo na levi polovici. S tem sem se izognila podvajanju in prevelikemu številu točk. Za zanesljivost statističnih analiz je namreč pomembno, da število spremenljivk (v našem primeru število točk) ne presega števila opazovanj (v našem primeru števila lobanj). Število opazovanj naj bi bilo vsaj dva do trikrat večje od števila spremenljivk. Točke sem postavljala na homologne strukture, torej pri vsaki lobanji na točno določeno mesto, v zmeraj istem vrstnem redu.



Slika 1: 22 oslonilnih točk, ki opisujejo obliko spodnjega dela lobanje.


Konfiguracije koordinat vseh 140 lobanj sem pred analizo poravnala s posplošeno Procrustovo analizo (GPA) [6] v programu MorphoJ. GPA konfiguracije koordinat premakne, zavrti in skalira, tako da je vsota kvadratov razlik na koncu v vzorcu minimalna. Po GPA predstavlja vsak objekt točko v ukrivljenem Kendallovem prostoru. Objekte se iz ukrivljenega prostora projicira na tangentni Evklidski prostor. Rezultat projekcije so oblikovne spremenljivke in centroidna velikost objektov. Za analizo morfološke variabilnosti program izračuna kovariančno matriko celotnega vzorca.

Naslednji korak je opredelitev hipotetičnih modulov. Program MorphoJ modulov ne poišče sam, ampak jih moramo določiti v naprej. Z delitvijo oslonilnih točk na dve ali več podskupin postavimo hipotezo o modularni zgradbi objekta. Hipotezo testiramo s izračunom stopnje kovariabilnosti med hipotetičnimi moduli, ki jo nato primerjamo z vsemi alternativnimi delitvami točk na podskupine z enakim številom točk, kot jih imajo hipotetični moduli. Če se delitev na hipotetične module ujema s pravimi moduli (slika 2, modra črta na grafu), je stopnja kovariabilnosti med skupinami točk nizka. Če se delitev na hipotetične module ne ujema s pravimi moduli (slika 2, rdeča črta), je kovariabilnost med skupinami točk visoka. Hipoteza o modularnosti drži, če je kovariabilnost med hipotetičnimi moduli izrazito nižja kot med vsemi ostalimi alternativnimi delitvami točk na module [4].



Slika 2: Prikaz delitve konfiguracije točk na dve podskupini. Prava modula sta okvirjena s črtkano črto. Puščice prikazujejo kovariabilnost med točkami. Modra črta deli točke na podskupini, ki sovpadata s pravima moduloma. Rdeča črta seka prava modula in deli točke na dve podskupini, med katerima so številne povezave. Vir: [3]

Oslonilne točke na spodnji strani lobanje sem razdelila na dve podskupini na dva načina (slika 3). Najprej sem definirala podskupini, ki sovpadata z delitvijo lobanje na obrazni in možganski del (modra črta na sliki 3) in predstavljata prava modula. Nato sem točke razdelila na podskupini, ki predstavljata obrobni in osrednji del lobanje (rdeča črta na sliki 3), a ne sovpadata s pravima moduloma.



Slika 3: Dva načina delitve točk na spodnji strani lobanje na dve podskupini. Modra črta: delitev na obrazni in možganski del lobanje (prava modula). Rdeča črta: delitev na obrobni in osrednji del lobanje (neprava modula).

Razen delitve točk na podskupine, lahko pred analizo definiramo tudi hipotetične povezave med točkami, katerih moč program nato analizira. Program samodejno poveže točke z Delaunay-evimi trikotniki. Povezave med točkami lahko nato izbrišemo ali dodamo. Sama sem dodala nekaj povezav med bolj oddaljenimi točkami (slika 4). Program omogoča tudi izbiro med analizo povezav med prostorsko stičnimi ali vsemi (tudi nestičnimi) točkami. Podskupina točk je stična, če so vse njene točke povezane. Sama sem uporabila primerjavo hipotetičnih modulov z vsemi možnimi (tudi nestičnimi) alternativnimi delitvami na module z enakim številom točk kot pri hipotetičnih modulih. Število točk v hipotetičnih modulih je bilo pri delitvi na prava modula 10 in 12 (slika 4, levo) in na neprava modula dva krat po 11 (slika 4, desno).



Slika 4: Delitev (na rdeče in modre točke) in povezave (sive črte) med točkami, med katerimi se računa kovariabilnost. Levo: prava modula. Desno: neprava modula.

Program MorphoJ kot merilo kovariabilnosti med podskupinami točk uporablja RV koeficient [7]. RV koeficient predstavlja merilo stopnje povezanosti ali soodvisnosti *med* podskupinami točk skalirano s stopnjo povezanosti ali soodvisnosti *znotraj* teh istih podskupin točk (za formulo glej [4]). RV koeficient lahko zavzame vrednosti od nič do

ena. Vrednost nič pomeni, da so podskupine točk povsem neodvisne, in vrednost ena, da so povsem odvisne.

Samo nizka stopnja kovariabilnosti med hipotetičnimi moduli ni dovolj za potrditev hipoteze o modularnosti. Hipotezo lahko potrdimo, če je stopnja kovariabilnosti med hipotetičnimi moduli izrazito manjša kot pri vseh (ali večini) alternativnih delitvah na module z enakim številom točk. Program primerja RV koeficient hipotetičnih modulov z razponom RV koeficientov vseh alternativnih delitev na module. Če imamo veliko število točk in več kot dva modula, je lahko vseh alternativnih delitev zelo veliko. V takem primeru je bolje, da število naključnih alternativnih delitev na module omejimo (npr. na 10000). Razmerje med številom alternativnih delitev z manjšim RV koeficientom od hipotetičnih modulov in številom vseh alternativnih delitev predstavlja P-vrednost. Če je razmerje manjše od 0,05, lahko potrdimo hipotezo o modularnosti, saj nizka stopnja kovariabilnosti med hipotetičnimi moduli v primerjavi z vsemi alternativnimi moduli najverjetneje ni naključna.

### 3. REZULTATI


Analiza modularnosti spodnje strani lobanje je potrdila hipotezo o delitvi lobanje na obrazni in možganski del ter ovrgla hipotezo o delitvi na obrobni in osrednji del (Tabela 1). RV koeficient med pravima moduloma je bil enkrat nižji (0,259) kot med nepravima (0,488). Le devet od 6646646 alternativnih delitev na module je imelo nižji RV koeficient kot delitev na prava modula, kar predstavlja razmerje 9 : 6646646 ( $P < 0,001$ ). Pri hipotetični delitvi na obrobni in osrednji del lobanje je imelo 73,2% alternativnih delitev nižji RV koeficient kot hipotetična module. Najnižja RV koeficienta izmed vseh alternativnih delitev sta bila pri obeh hipotetičnih delitvah lobanje primerih zelo podobna, saj smo enkrat primerjali skupini 10 in 12 točk in drugič dveh skupin z 11 točkami.

Tabela 1: Rezultati analize modularnosti spodnjega dela lobanje z dvema hipotetičnima delitvama.

<i>Hipotetična modula</i>	<i>RV koef. med hipt. moduloma</i>	<i>Število vseh altr. delitev na module</i>	<i>Število delitev z nižjim RV koef. od RV koef. hipt. delitve</i>	<i>P-vrednost</i>	<i>Najnižji RV koef. vseh altr. delitev</i>
Obrazni vs. možganski del lobanje	0,259	646646	9	< 0,001	0,240
Obrobni vs. osrednji del lobanje	0,488	352716	258220	0,732	0,256



Razmerje med RV koeficienti hipotetičnih in vseh alternativnih delitev lahko predstavimo tudi grafično (slika 5). RV koeficient hipotetične delitve na module označuje rdeča puščica, stolpci pa razpon in frekvenco RV koeficientov vseh ostalih alternativnih delitev na module z enakim številom točk kot pri hipotetičnih modulih. Nižji kot je RV koeficient hipotetične delitve na module v primerjavi z vsemi ostalimi alternativnimi delitvami, večja je verjetnost, da gre za prava modula. Za potrditev hipoteze o modularnosti mora biti rdeča puščica v skrajnem levem koncu razpona vrednosti vseh RV koeficientov (slika 5, levo), sicer hipotezo ovržemo (slika 5, desno).



Slika 5: Prikaz razmerja med RV koeficientom hipotetične delitve (rdeča puščica) z razporeditvijo RV koeficientov vseh alternativnih delitev. Levo: prava modula,  $RV = 0,259$ . Desno: nepravna modula,  $RV = 0,488$ .

## 4. ZAKLJUČEK

Namen prispevka je bil predstaviti analizo modularnosti objektov s pomočjo metod geometrijske morfometrije. V svetu je geometrijska morfometrija uveljavljena metoda, ki pa v Sloveniji še nima veliko 'navdušencev'. Četudi je metoda nastala za uporabo v biologiji, se vse pogosteje uporablja v medicini, forenziki, arheologiji, psihologiji in drugih vedah. Ker je analiza modularnosti v biologiji zanimiva predvsem z evolucijskega vidika, bi prenos uporabe v druge vede lahko pomenil analizo razvoja oblike poljubnega objekta od preteklosti do prihodnosti. Na primer v industrijskem oblikovanju vladajo podobne zakonitosti kot v naravi, saj oblika izdelkov služi funkciji, materiali pa imajo podobno kot tkiva svoje zakonitosti. Če v naravi modularna zgradba struktur pomeni večjo fleksibilnost v razvoju oblike, lahko morebiti delitev na module tudi pri industrijskem izdelku nakaže smernice razvoja sprememb v obliki brez izgube funkcionalnosti.

## LITERATURA

1. D. C. Adams, F. J. Rohlf, D. E. Slice (2013), A field comes of age: geometric morphometrics in the 21st century, *Hystrix, the Italian Journal of Mammalogy*, vol. 24(1), str. 1–8.

2. C. P. Klingenberg (2013), Cranial integration and modularity: insights into evolution and development from morphometric data, *Hystrix, the Italian Journal of Mammalogy*, vol. 24(1), str. 43–58.
3. C. P. Klingenberg (2011), MorphoJ: an integrated software package for geometric morphometrics, *Mol. Ecol. Res.*, vol. 11, str. 353–357.
4. C. P. Klingenberg (2009), Morphometric integration and modularity in configurations of landmarks: Tools for evaluating a-priori hypotheses, *Evolution & Development* vol. 11, str. 405–421.
5. F. J. Rohlf (2010), *TpsDig Version 2.15*, Department of Ecology and Evolution, State University of New York.
6. F. J. Rohlf, D. E. Slice (1990), Extensions of the Procrustes method for the optimal superimposition of landmarks, *Syst. Zool.*, vol. 39, str. 40–59.
7. Y. Escoufier (1973), Le traitement des variables vectorielles, *Biometrics*, vol. 29, str. 751–760.

## **DRUGO**

---



# UPORABA INFRA RDEČE TERMOGRAFSKE METODE V PROCESU ŠPORTNEGA TRENINGA

Milan Čoh<sup>1</sup>, Vedran Hadžić<sup>1</sup>, Brane Širok<sup>2</sup>, Aleš Malneršič<sup>2</sup>

<sup>1</sup> Fakulteta za šport, Univerza v Ljubljani

<sup>2</sup> Fakulteta za strojništvo, Univerza v Ljubljani

E – pošta: milan.coh@fsp.uni-lj.si

---

**POVZETEK:** *V prispevku je predstavljena metoda infra rdeče termografije, ki je eno od pomembnejših diagnostičnih orodij za spremljanja obremenitev športnikov pri njihovih treningih. Prednost metode je v kvantitativnem pristopu, hitri analizi in neinvazivnem postopku merjenja. Metoda temelji na registraciji toplotnih polj v telesu športnika, ki se spreminjajo zaradi različnih tipom motoričnih obremenitev ali zaradi posledic poškodb lokomotornega sistema. Namen pričujoče študije ju bil ugotoviti stopnjo mišične utrujenosti pri cikličnem naprežanju na izokinetičnem dinamometru z metodo infra rdeče termografije.*

---

## 1. UVOD

Infra rdeča termografija je brez-kontaktna metoda merjenja toplotnega sevanja na površini telesa, ki temelji na infrardečem delu elektromagnetnega spektra. Pogosto se uporablja kot neinvazivna metoda v medicini pri diagnostiki vnetnih obolenj – revmatizmov, poškodb mehkega tkiva, omrzlin tkiv ali prekrvavljenosti udov in trupa para in tetraplegikov. V športni praksi so začeli to metodo uporabljati že pred več kot tridesetimi leti (Veghte, Adams in Bernauer, 1979; Buckhout in Warner, 1980, Nakayama, Ohnuki in Kanosue, 1981; Sherman, Karstetter 1996; Komi, 2002; Zaïdi, Taiar, Fohanno in Polidori, 2006). Osnovni cilj večine raziskav v športu je bil izmeriti padec ali povišanja temperature na koži med specifično športno obremenitvijo, med spreminjanjem temperature zraka (tek, kolesarjenje, plavanje) in pri pojavu poškodb in lezij.

Pričujoči prispevek je usmerjen v aplikacijo infra rdeče termografije kot diagnostične – monitoring metode na področju spremljanja mišičnih obremenitev spodnjih ekstremitet treniranih športnikov. Cilj raziskave je podati oceno o signifikantnih spremembah temperaturnega polja izmerjenega na površini kože - mišice quadriceps femoris pri ponavljajočih cikličnih obremenitvah. Študija je nastala kod plod sodelovanja Laboratorija za gibalni nadzor Fakultete za šport in Laboratorija za energetsko strojništvo Fakultete za strojništvo v Ljubljani.

## 2. METODE


V eksperimentu so sodelovali štiri trenirani športniki (starost  $23 \pm 2$  let, telesna teža  $81.5 \pm 6.1$  kg, telesna višina  $183.4 \pm 7.3$  cm). Testiranje ciklične koncentrične mišične obremenitve štiriglave stegenske mišice (m. quadriceps) je bilo izvedeno na izokinetičnem dinamometru RCSCX - Slika 1.



Slika 1: Protokol meritev maksimalne koncentrične kontrakcije m. quadricepsa

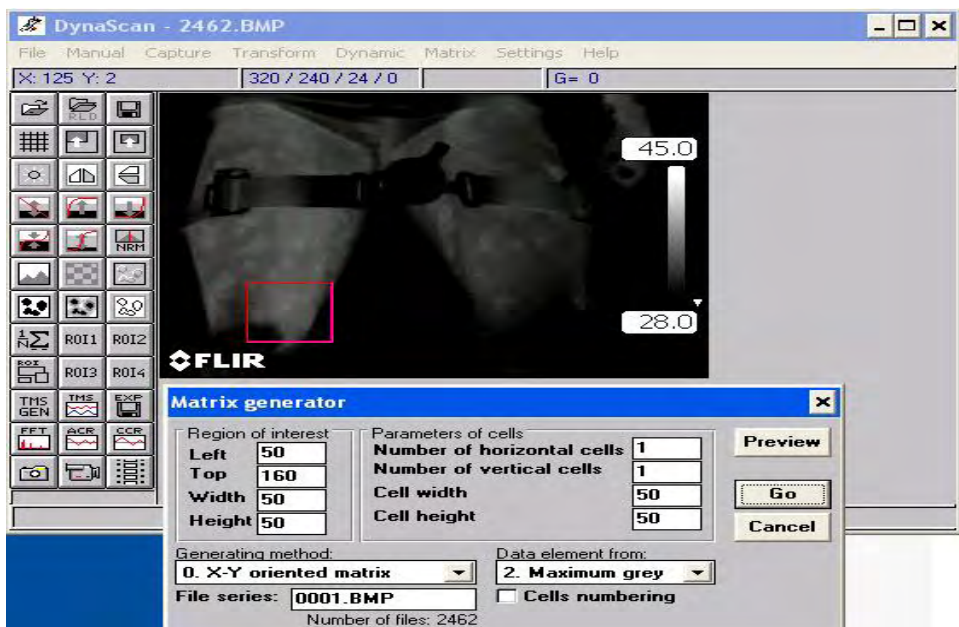


Slika 2: Termovizijska kamera FLIR



Slika 3: Registracija toplotnih polj m. quadricepsa med ciklično obremenitvijo na izokinetičnem dinamometru.

S termovizijsko kamero FLIR smo snemali s hitrostjo 8 slik na sekundo. Izbrali smo vsako 150 sliko, kar pomeni, da je med dvema slikama minilo 18,75 sekunde. (Slika 3 in 4).

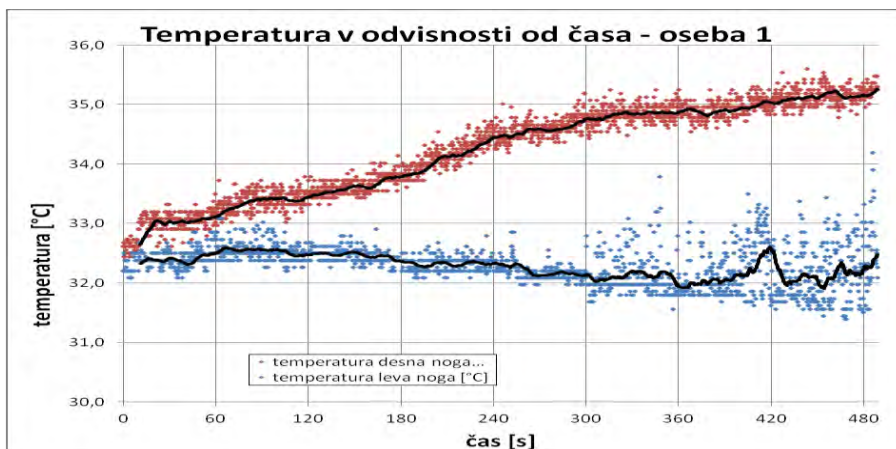


Slika 4: Postopek selekcije slik termografije toplotnih polja m. quadricepsa


### 3. REZULTATI ŠTUDIJE

Cilj eksperimenta je bil ugotoviti dinamiko sprememb toplotnih polj, ki nastanejo po koncentričnih obremenitvah štiri glave stegenjske mišice pri 10 minutnem maksimalnem

naporu. Hitrost ročice dinamometra je bila  $120^0/s$ . Aktivna je bila dominantna noga, pri čemer smo spremljali spremembe toplotnih polj tako na aktivni kot neaktivni nogi. Temperatura se v odvisnosti od časa povečuje z obremenitvijo (Slika 5). Delne spremembe temperature so razvidne na neaktivni nogi. To dokazuje na kontralateralni učinek vadbe, ki očitno poteka po nevaralni poti mišičnega sistema.



Slika 5: Odvisnost temperaturnega polja od funkcije časa obremenitve



Slika 6: Razmerje dinamometrijske moči in temperature štiri glave stegenjske mišice.

Druga pomembna ugotovitev naše študije je razmerje med močjo štiriglave stegenjske mišice in drsečega povprečja njene temperature. To razmerje se spreminja obratno



sorazmerno. Z povečanjem temperature se zmanjšuje koncentrična moč m. quadricepsa. Očiten padec moči se prične po 180 sekundah koncentričnih kontrakcij. Po 240 sekundah se moč stabilizira z manjšimi nihanji.

#### 4. ZAKLJUČEK

Infra rdeča termografska metoda je brezkontaktni postopek merjenja toplotnega sevanja na površini telesa in jo je mogoče učinkovito uporabiti tudi v športni praksi. Metoda temelji na registraciji spremembe temperaturnega polja, ki nastane zaradi povečane telesne obremenitve. V študiji, smo izvedli eksperiment v katerem smo iskali odvisnost izmerjenega temperaturnega polja na površini izbranega segmenta (štiri glave stegenske mišice) pri 10 minutni maksimalni obremenitvi v pogojih koncentričnih kontrakcij. Meritve smo izvedli na računalniško vodenem dinamometru RCSCX. Toplotna polja smo registrirali z termovizijsko kamero FLIR. Predstavljena je metodologija analize temperaturnega polja v izbranem oknu na površini stegenske mišice, kjer je bilo analizirano krajevno povprečna normirana temperatura na površini kože v izbranem časovnem intervalu. Ugotovili smo obratno sorazmerje mišične temperature in moči ter efekt učinkovanja kontralateralnosti. Na osnovi rezultatov lahko ugotovimo, da predstavlja infra rdeča termografija pomembno ekspertno orodje pri spremljanju obremenitvenih stanj, ki so posledica različnih sredstev in metod treniranja.

#### 5. LITERATURA

1. Buckhout, B.C., & Warner, M.A. (1980). Digital perfusion of handball players. Effects of repeated ball impact on structures of the hand. *American Journal of Sport Medicine*, 8(3), 206-207.
2. Keyl, W., & Lenhart, P. (1975). Thermography in sport injuries and lesions of the locomotor system due sport. *Fortschr. Med.*, 93(3), 124-126.
3. Komi, P. V. (2002). Strength and Power in Sport (*Encyclopaedia of Sports Medicine*, Vol. 3) (Vol. III, p. 544). Wiley-Blackwell.
4. Sherman R.A., Woerman, A.L., & Karstetter K.W. (1996). Comparative effectiveness of videothermography, contact thermography, and infrared beam thermography for scanning relative skin temperature. *J Rehabil Dev.*, 33(4), 377-386.
5. Torii, M., Yamasaki, M., Sasaki, T., & Nakayama, H. (1992). Fall in skin temperature of exercising man. *Br J Sports Med.*, 26(1), 29-32.
6. Zaidi, H., Taiar, S., Fohanno, G., & Polidori, G. (2006). New approach by infrared thermography to measure the skin temperature of a male competitive swimmer. *Journal of Biomechanics*, 39(1), 629.
7. <http://www.intechopen.com/download/get/type/pdfs/id/32034>
8. [http://link.springer.com/chapter/10.1007/978-1-4684-7697-2\\_61#page-1](http://link.springer.com/chapter/10.1007/978-1-4684-7697-2_61#page-1)



Slovenski podjetniški sklad (v nadaljevanju Sklad) finančni partner mikro, malih in srednje velikih podjetij (MSP) v Sloveniji, ki direktno ali v povezavi z ostalimi finančnimi institucijami sofinancira investicije in ostale poslovne projekte v podjetniškem sektorju.

Sklad vsako leto ponuja ugodne instrumente za MSP, s pomočjo katerih lahko podjetja financirajo lastno poslovanje in investicije vse od zagona do uspešnega konkurenčnega nastopanja na razvitem trgu.

Finančni instrumenti bodo v obdobju **2014 – 2020** na razpolago v okviru dveh programov:

### PROGRAM MLADI

Program namenjen podjetjem mlajšim od 5 let, ki imajo zagotovljen trg in izkazujejo potencial povečanja dodane vrednosti na zaposlenega.

V okviru programa ponujamo:

- garancije za zavarovanje bančnih investicijskih kreditov za obratna sredstva s subvencijo obrestnih mer,
- direktne kredite za poslovanje in investicije,
- kapitalske in navidezne kapitalske vloške za zagon (semenski kapital) in hitro rast (tvegan kapital) podjetij s potencialom hitre rasti,
- nepovratna sredstva za zagon inovativnih podjetij.

### PROGRAM MSP 5+

Program namenjen podjetjem, starejšim od 5 let, ki donosno poslujejo, nimajo pa potenciala hitre rasti.

V okviru programa ponujamo:

- garancije za zavarovanje bančnih investicijskih kreditov za obratna sredstva s subvencijo obrestnih mer,
- direktne kredite za poslovanje in investicije.

**Kako do pomoči Sklada?** Državen pomoči se dodeljujejo preko javnih razpisov. Ti so objavljeni v Uradnem listu RS, v javnih občilih in na spletni strani SPS-a

[www.podjetniskisklad.si](http://www.podjetniskisklad.si)

**Bodite obveščeni:** Prijavite se na e-novice in bodite pravočasno obveščeni o razpisih Sklada

**SLOVENSKI PODJETNIŠKI SKLAD**

**Ul. kneza Koclja 22**

**2000 Maribor**

**Tel.: 02/234 12 60**

