

LSPO

Laboratorij za sistemsko
programsko opremo




Univerza v Mariboru

Fakulteta za elektrotehniko,
računalništvo in informatiko



Inštitut za
računalništvo



ROSUS 2015
Računalniška obdelava slik in njena
uporaba v Sloveniji 2015
Zbornik 10. strokovne konference

Urednik
Božidar Potočnik

Maribor, 19. marec 2015

Zbornik prispevkov strokovne konference
ROSUS 2015 Računalniška obdelava slik in njena uporaba v Sloveniji 2015
Maribor, 19. marec 2015.

Elektronska izdaja

CIP - Kataložni zapis o publikaciji
Univerzitetna knjižnica Maribor

004.932(497.4)(082)(0.034.2)

STROKOVNA konferenca ROSUS (10 ; 2015 ; Maribor)

ROSUS 2015 [Elektronski vir] : računalniška
obdelava slik in njena uporaba v Sloveniji 2015 :
zbornik 10. strokovne konference, Maribor, 19.
marec 2015 / urednik Božidar Potočnik. - El.
zbornik. - Maribor : Fakulteta za elektrotehniko,
računalništvo in informatiko, Inštitut za
računalništvo, 2015

ISBN 978-961-248-478-1

1. Potočnik, Božidar

COBISS.SI-ID 81533441

ISBN 978-961-248-478-1



Programski odbor ROSUS 2015:

dr. Božidar Potočnik
dr. Damjan Zazula
dr. Boris Cigale
dr. Nikola Guid
dr. Peter Peer
dr. Tomaž Tomažič
dr. Matjaž Colnarič
dr. Slobodan Ribarič
dr. Veljko Vlasisavljevič
dr. Saša Divjak

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

Organizacijski odbor 2015:

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

Spoštovani!

Po devetih uspešnih konferencah ROSUS 2006–2014 želimo tudi z jubilejno konferenco ROSUS 2015 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.

Naj sklenemo uvodne misli s pristrčno zahvalo Javnemu skladu Republike Slovenije za podjetništvo, ki je v okviru konference ROSUS 2015 predstavil zanimive finančne instrumente za spodbujanje prenosa tehnoloških rešitev v podjetniško sfero.

dr. Božidar Potočnik
predsednik konference
ROSUS 2015



POKROVITELJI



ROSUS 2015
<http://rosus.feri.um.si/rosus2015/>

KAZALO

VABLJENA PREDAVANJA	1
Marta Klanjšek Gunde, Nina Rogelj, KI, Ljubljana, UEF, Joensuu, Finska <i>Digitalni zapis videza optično kompleksnih površin in možnosti njegove uporabe za zaščito izdelkov pred ponarejanjem</i>	3
Iztok Kramberger, FERI, Maribor <i>Miniaturna multispektralna kamera s širokim spektralnim odzivom od vidnega do kratkovalovnega infrardečega področja za misijo TRISAT</i>	16
INDUSTRIJSKE APLIKACIJE.....	33
Boštjan Celan, Matjaž Šraml, Goran Jovanović, Peter Podbreznik, FG, Maribor, Appia, Ljubljana <i>Avtomatsko štetje prometa s pomočjo video-slikovnega materiala v realnem času</i>	35
Rok Petek, Luka Šajin, Peter Peer, Andrej Ikica, FRI, Ljubljana <i>Optična razpoznavna znakov v slikah naravnih scen</i>	44
Martin Šavc, Božidar Potočnik, FERI, Maribor <i>Nadgradnja metode barvne vztrajnosti z vzorci s segmentacijo na osnovi drsečega okna</i>	51
Jože Kraner, Matjaž Divjak, Jurij Rakun, Damjan Zazula, FERI, Maribor, FKBV, Maribor <i>Uspešnost rekonstrukcije scene iz več pogledov med vožnjo poljskega robota</i>	58
MEDICINSKE IN BIOMEDICINSKE APLIKACIJE	71
Jaka Pribošek, Peter Gregorčič, Andrej Vrečko, Janez Diaci, FS, Ljubljana, Optotek, Ljubljana <i>Detekcija in sledenje kavitacijskih mehurčkov pri medicinskih laserskih posegih.....</i>	73
DRUGO.....	79
Blaž Meden, Blaž Jeršan, Gorazd Rajar, Franc Solina, FRI, Ljubljana <i>Virtually enhanced sculpture</i>	81

ŠTUDENTSKE APLIKACIJE	87
Boštjan Buh, Peter Peer, FRI, Ljubljana	
<i>Sistem obogatene resničnosti za simulacijo bolezni človeškega vida na osnovi Oculus Rift očal</i>	<i>89</i>
Tadej Vodopivec, Peter Peer, FRI, Ljubljana, TU, Gradec	
<i>Prekrivanja v kontekstu obogatene resničnosti.....</i>	<i>99</i>

VABLJENA PREDAVANJA

DIGITALNI ZAPIS VIDEZA OPTIČNO KOMPLEKSNIH POVRŠIN IN MOŽNOSTI NJEGOVE UPORABE ZA ZAŠČITO IZDELKOV PRED PONAREJANJEM

Marta Klanjšek Gunde¹, Nina Rogelj²

¹Kemijski inštitut, Ljubljana

²University of Eastern Finland, Institute of Photonics, Joensuu, P.O.Box
111, Finland

E-pošta: marta.k.gunde@ki.si; nina.rogelj@uef.fi ;

URL: <http://www.ki.si/>; <http://www.uef.fi/en/spectral/home>

POVZETEK *Zaščita pred ponarejanjem in prenarejanjem je ena od najpomembnejših aktivnosti sodobne družbe, kamor sodi tudi zaščita različnih izdelkov kot so zdravila, hrana, pijače, kozmetika, izdelki za osebno nego, oblačila in podobno, saj tako lahko preprečimo ogromno gospodarsko škodo. Pri teh aktivnostih je pomemben podroben opis/zapis lastnosti izdelkov, zlasti njihove embalaže. Predstavljen je pregled obstoječih metod za pripravo dobro zaščitene embalaže in možnosti za digitalni zapis njihovega videza. Posebna pozornost je posvečena optično kompleksnim površinam, katerih uporaba je ena od zelo učinkovitih metod za zaščito izdelkov, zlasti na embalaži. Predstavljeno možnost digitalnega zapisa videza takih površin smo poimenovali »prstni odtis videza« in ponuja zelo perspektivno možnost za digitalni zapis videza površin tudi optično najbolj kompleksnih objektov.*

1. UVOD

Zaščita pred ponarejanjem in prenarejanjem izdelkov je ena od najpomembnejših aktivnosti sodobne družbe. Najvišja stopnja zaščite velja denarju, posebljenim dokumentom in vrednostnim papirjem, dovolj velika pa mora biti tudi zaščita drugih dokumentov kot so spričevala, različna potrdila, diplome, srečke in vstopnice. Pričakovati pa je, da bo večina naštetega kaj kmalu postalo virtualno oz. v digitalni obliki. Vendar pa ni mogoče zagotoviti, kaj od naštetega bo preživelo uvedbo informacijske tehnologije v sedanji obliki in kaj le kot nosilec virtualne informacije.

Cilj ponarejanja pa niso le vrednosti papirji in dokumenti, ampak zlasti najrazličnejši izdelki splošnega pomena kot so zdravila, hrana, pijače in prehranska dopolnila, ter modni izdelki kot je kozmetika, izdelki za osebni nego, razna oblačila in podobno. Taki izdelki bodo brez dvoma obstajali tudi pri še tako temeljiti uvedbi informacijske tehnologije. Njihovo ponarejanje je zelo donosno, saj je razmeroma enostavno, težko

izsledljivo in dokazljivo, praviloma pa se ga ne preganja. Dokazljiva gospodarska škoda v svetu znaša vsaj 200 milijard \$ na leto [1, 2]. Direktna gospodarska škoda zadeva zlasti originalne proizvajalce, posredna pa ekonomijo držav in njihov zdravstveni sistem, ki rešuje škodljive posledice ponaredkov zdravil, prehranskih dodatkov in hrane.

Med najpomembnejše dejavnosti za zmanjšanje škode zaradi ponarejanja sodi ugotavljanje oz. prepoznavanje ponaredkov. Ločimo tri stopnje odkrivanja (i) brez pripomočkov (ii) z enostavnejšimi pripomočki ter (iii) s forenzičnimi postopki [3]. Med najpomembnejše sodi nadzor (i), saj ga izvajajo vsi uporabniki s presojo avtentičnosti in sprejemljivosti izdelka. V stopnji (ii) se uporabi različne čitalnike (črtna koda, QR matrična koda, RFID, mikrotisk) in aktivatorje učinkov (npr. aktivacija nevidnih barv, preverjanje vsebnosti optičnih belilcev ipd). Posebni postopki v najvišji stopnji odkrivanja ponaredkov (iii) vključujejo specialne optične, mikroskopske in analizne postopke, ki so lahko tudi destruktivni.

Omejevanje možnosti plasiranja ponaredkov na trg zajema različne dejavnosti, med katerimi pa je gotovo pomembna njihova prepoznavnost (značilen videz), ter razpoznavna in dobro zaščitena embalaža. Večino teh lastnosti ocenjujemo z vidno zaznavo, le malo pa drugih čutil (npr. otip ali vonj). Zato je za embalažo pomembna njena oblika, uporaba ustreznih materialov z značilnim videzom ter zapis informacij, ki jih ni možno brisati, popraviti ali kakorkoli preurediti. Ker mora biti cena embalaže zanemarljiva v primeri s ceno izdelka, so potrebni kompromisi pri izbiri materialov (npr. visokotehnološke in unikatne sestavine) in pri uporabi posebnih zaščitnih elementov, ki preprečujejo ponarejanje, prenašanje (npr. rok trajanja), nepravilno skladiščenje, transport (termična preteklost izdelka) in morebitne posege v izdelke (predhodno odpiranje in spreminjanje vsebine).

Poleg zaščite pred ponarejanjem je za sodobno proizvodnjo velikega pomena tudi čim bolj natančen zapis videza izdelkov in njihove embalaže. Tak zapis služi pri prepoznavanju ponaredkov, pa tudi za preverjanje ustreznosti izdelave pri različnih (pod)izvajalcih. Ta aspekt nedvomno sodi na področje računalniškega zapisa vidnih zaznav ter obdelave slik.

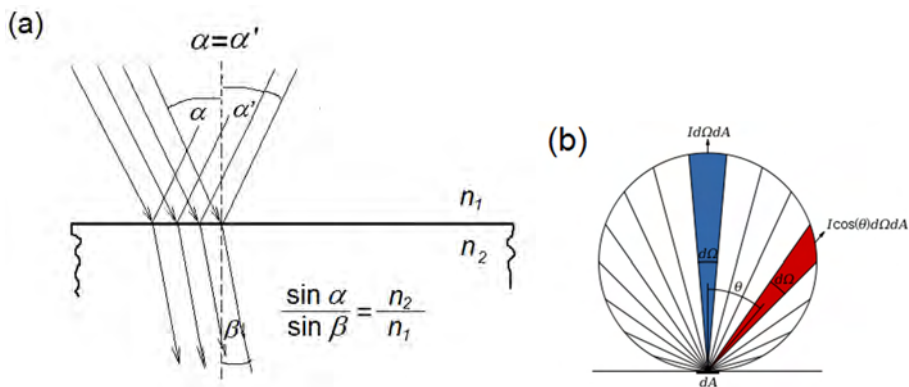
Zapis videza izdelkov je zelo zapleteno opravilo, saj imamo opravka s 3D obliko, grafično podobo površin, zapisanimi informacijami in pri dobro zaščiteneh izdelkih tudi s posebnimi optičnimi učinki. V tem prispevku se osredotočimo na zapis videza optično kompleksnih površin, ki predstavljajo najtrši oreh pri zapisu videza izdelkov. Najprej opredelimo (definiramo) optične lastnosti takih površin, nato postavimo model za učinkovit in enostaven zapis njihovega videza, opišemo nekaj značilnih primerov in opredelimo možnosti za uporabo v praksi.

2. OPTIČNE LASTNOSTI POVRŠIN

2.1 Opredelitev pojmov

Termin »optične lastnosti« opredeljuje videz izdelkov. Ta je odvisen od uporabljenih materialov, njihove morebitne volumske strukturiranosti in oblikovanosti površine. Material je lahko optično homogen ali pa heterogen, torej lahko vsebuje eno snov ali pa več snovi, ki so bolj ali manj naključno/načrtno urejene.

Optično enostavne izdelke opredelimo z uporabo geometrijske optike. Ločimo dve skrajnosti, zrcalne oz. sijajne in difuzne oz. mat objekte. Zrcalni objekti imajo popolnoma ravne površine in so optično homogeni, zato odbijajo usmerjeno svetlobo v skladu z odbojnim zakonom, ali pa jo lomijo po lomnem zakonu (slika 1a). Druga skrajnost so objekti z naključno in drobno strukturirano obliko površine, ki sipljejo svetlobo v vse smeri v skladu z Lambertovim zakonom (slika 1b).




Slika 1. Shematični prikaz optično idealnih površin: na zrcalnih se vzporedni žarki odbijejo in lomijo po odbojnem in lomnem zakonu (a), na idealno difuznih površinah pa se odbijejo v vse smeri po Lambertovem kosinusnem zakonu (b).

Večina praktično pomembnih objektov ima mešane značilnosti, vendar pogosto prevladuje eden od obeh skrajnih tipov. Videz takih objektov podajamo s sijajem in barvo; sijaj izračunamo iz kotno odvisnih zrcalnih meritev, barvo pa iz izmerjene spektralne odbojnosti. Spektralno odbojnost lahko dobro izmerimo s standardnimi merskimi metodami, najbolje z integracijsko sfero, ki zbere vso svetlobo ne gleda na smer odboja. S tako meritvijo lahko določimo barvo vzorca v difuzni osvetlitvi, ne pa tudi kotne porazdelitve odbite svetlobe.

Optično kompleksni izdelki vsebujejo različnih deleže zrcalno in difuzno odbite svetlobe in tudi kombinacije več efektov. Lahko kažejo posebno strukturiranost površine, kot npr. usnje, razni površinsko strukturirani izdelki iz kovine, plastike in lesa ter tekstilni izdelki s posebnimi večinoma drobno tkanimi vzorci in celo hologramski elementi. Veliko

optično kompleksnih izdelkov zaznamuje pojav, ki prihaja iz volumna; primeri so premazi in potiski, ki vsebujejo t.i. efektne pigmente, večplastne prevleke, uklonske elemente in podobno. Njihov videz je pri osvetljevanju z usmerjeno svetlobo močno odvisen od smeri osvetljevanja in opazovanja. Odbojnost ne sledi odbojnemu zakonu niti difuzni odbojnosti, ampak kaže optično mikrostrukturo površine in/ali volumna. Take vzorce poimenujemo tudi goniokromatični. Premaz s kovinskimi luskami daje kovinski videz površine, smer odboja pa je odvisna od usmerjenosti lusk (slika 2 levo). Interferenčne luske dajejo mavrične barve (slika 2 desno), konkretna barva pa je odvisna od usmerjenosti lusk v plasti in od pogojev opazovanja. Optične lastnosti takih objektov merimo z goniospektrometri pri različnih kombinacijah smeri vpadne in odbite svetlobe.




Slika 2. Odboj svetlobe od premazov s kovinskimi luskami je odvisen od usmerjenosti lusk in od njihove porazdelitve v polimernem vezivu (levo). Posebne optične efekte dajejo interferenčne luske s prozorno sredico, ki so oplaščene z eno ali več tankimi plastmi kovinskih oksidov (desno).

2.2 Goniometrični zapis optičnih lastnosti (BRDF)

Najpopolnejša oblika zapisa odbojnosti nekega vzorca je t.i. dvosmerna porazdelitev odbojnosti, *bidirectional reflection distribution function* (BRDF). Ta podaja razmerje odbite radiance, L_r , in vpadne iradiane, E_i , od smeri vpadne (ϑ_i, φ_i) in merjene (ϑ_r, φ_r) svetlobe (enačba 1 in slika 3) [4]:

$$BRDF(\vartheta_i, \varphi_i, \vartheta_r, \varphi_r, \lambda) = \frac{dL_r(\vartheta_i, \varphi_i, \vartheta_r, \varphi_r, \lambda)}{dE_i(\vartheta_i, \varphi_i, \lambda)} = \frac{dL_r(\vartheta_i, \varphi_i, \vartheta_r, \varphi_r, \lambda)}{L_i(\vartheta_i, \varphi_i, \lambda) \cdot \cos \vartheta_i \cdot d\omega_i} \quad (1)$$



Slika 3. Geometrija BRDF, dvosmerne funkcije odbojnosti. Glej tudi enačbo (1).

BRDF izbranega vzorca je funkcija petih spremenljivk: vpadna in odbojna smer sta določeni s po dvema kotoma, polarnim (ϑ) in azimutnim (φ), odvisnost od snovnih lastnosti pa je zajeta v valovni dolžini λ [5]. Podrobna meritev BRDF je zelo zamudna, saj je za vsako smer vpadne svetlobe potrebno izmeriti spektre odbojnosti preko celotne hemisfere, to je za vse dovolj gosto izbrane smeri odbite svetlobe. Za tako meritev potrebujemo spektrogoniometer, aparaturo z izvorom in detektorjem svetlobe, ki ju je mogoče neodvisno pomikati po gornji hemisferi na ustrezni razdalji od vzorca. Poleg nekaterih nacionalnih meroslovnih inštitutov, ki imajo sledljivo umerjene aparature (npr. Nemčija, Francija, Italija, Finska, Španija), obstajajo tudi bolj preproste izvedbe [6-10]. S takimi meritvami so odkrili, da se referenčni standardi pri velikih kotih precej razlikujejo od pričakovanih oz. zahtevanih [11]. V vsakem realnem primeru pa je potrebno omejiti število meritev in določiti smiselna zaporedja in ureditev zapisa BRDF tako, da dobimo uporabno predstavitev oz. upodobitev optičnih lastnosti merjenega vzorca.

V literaturi obstaja veliko analiz kako je smiselno opraviti meritve BRDF. Največ analiz je bilo narejenih za premaze s t.i. efektnimi pigmenti, to je luskami, ki usmerjeno odbijajo ali prepuščajo svetlobo (slika 2). Za optično najbolj zapletene vzorce so pokazali, da je najmanjše število merskih geometrij (kombinacij vpadnega in odbojnega kota) enako 1485 [12]. Seveda je to mnogo preveč za večino praktičnih aplikacij. Za merjenja premazov s kovinskimi luskami zadoščajo tri tipične geometrije [13], za premaze z interferenčnimi luskami pa vsaj šest [14]. Taki BRDF podatki so zelo skopi, zato jih imenujemo »pod-vzorčena« (*under-sampled*) BRDF). Najpogosteje se meri le vpadne in odbojne smeri, ki ležijo v vpadni ravnini, torej le t.i. ravninske kombinacije, ne pa tudi izven-ravninskih, kjer smer odboja ni v vpadni ravnini.

Posebno pozornost se posveča tudi predstavitvi BRDF. Najpogosteje se spektri pretvorijo v barvne vrednosti v izbranem barvnem prostoru, večinoma CIELAB [15,16]. Tako dobimo gonimetrični barvni zapis, ki močno zmanjša število podatkov, saj vsak spekter (ta ima najmanj 31 številke) pretvorimo v tri barvne vrednosti.

Večina goniospektrometričnih meritev uporablja t.i. aspekularni kot φ_a , ki je določen kot razlika med zrcalnim kotom ($-\vartheta_i$) in kotom dejanskega odboja (ϑ_r):


$$\varphi_a = \vartheta_i + \vartheta_r \quad (2)$$

2.3 Goniometrične prostorske krivulje – alternativni zapis BRDF

Množico podatkov v BRDF za izbrano λ lahko prikažemo tudi kot nabor vektorjev v odbitih smereh in z velikostjo pripadajoče odbojnosti. Če te vektorje vektorsko seštejemo, dobimo za vsako λ svojo točko (slika 4). Ko tako sumacijo izvedemo za vse λ , dobimo krivuljo v goniometričnem prostoru, ki vsebuje podatke o kotno odvisnem videzu vzorca. Računski postopek zapišemo kot:

$$\mathbf{xDNA} = \mathbf{R} \cdot \boldsymbol{\mu} \quad (3)$$

kjer je \mathbf{R} matrika $n \times m$, ki vsebuje spektre odbojnosti (pod-vzorčena BRDF), $\boldsymbol{\mu}$ pa je matrika $m \times 3$, ki vsebuje vektorje merskih geometrij, n je število točk v spektrih (število λ), m pa je število merskih geometrij. Vsaka vrstica v matriki $\boldsymbol{\mu}$ pomeni vektor, ki določa mersko geometrijo, v kateri je bil izmerjen spekter odbojnosti – pripadajoči stolpec matrike \mathbf{R} . Rezultat računa je matrika \mathbf{xDNA} velikosti $n \times 3$, kjer vsaka vrstica določa točko v goniometričnem prostoru, vseh n točk pa določa krivuljo. Metoda pomeni transformacijo goniometrično izmerjenih spektrov odbojnosti v 3D krivuljo, imenovano \mathbf{xDNA} . Avtorji so metodo poimenovali digitalna numerična analiza (DNA), dobljeno krivuljo pa \mathbf{xDNA} graf [17, 18].



Slika 4. Shematični prikaz DNA transformacije za določeno λ za osvetljevanje pri 45° in šest merskih geometrij v vpadni ravnini. Meritve so prikazane z vektorji ustrezne smeri in z velikostjo, ki ustreza merjeni odbojnosti (levo). Vsota vektorjev odbojnosti določa točko v goniometričnem prostoru, ki ima z-os v zrcalni smeri, y pa leži v vpadni ravnini [19].

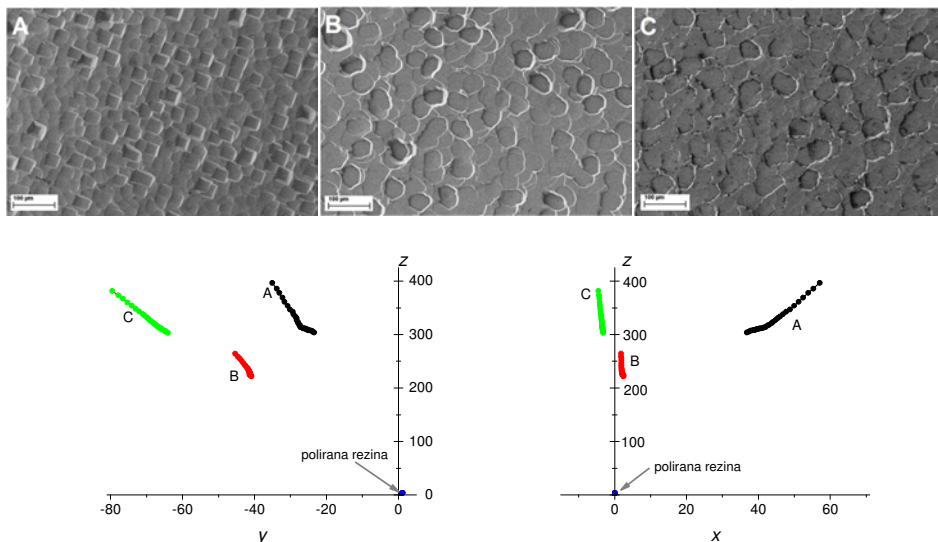
DNA metoda je uporabljena v programski opremi večkotnega spektrometra MA98 podjetja X-Rite [20], ki je namenjen merjenju kotno odvisnih barv tudi na ukrivljenih površinah, ki so pomembne zlasti v avtomobilski industriji. Ta omogoča merjenje pri osvetljevanju 45° in 15° v 11 ravninskih in 8 izven-ravninskih smereh (po 4 za vsako smer osvetljevanja), kar je največji nabor merskih geometrij, ki jih omogoča katerikoli komercialni instrument. Vse meritve se izvedejo na istem položaju vzorca v 2 sekundah.

2.4 Prstni odtis videza izbranih vzorcev

Čeprav je DNA metoda sestavni del programske opreme večkotnega spektrometra MA98 ki je razmeroma široko v rabi, pa ni bilo narejene nobene neodvisne raziskave, ki bi pojasnila podrobnosti \mathbf{xDNA} grafov in pojasnila njihovo analizo vrednost. Tega izziva smo se lotili postopoma. Najprej smo podali fenomenološke rezultate. S sistematično analizo \mathbf{xDNA} grafov, ki smo jih izmerili z goniospektrometrom MA98 na vzorcih z različno stopnjo optične kompleksnosti smo ugotovili, da te grafe lahko poimenujemo »prstni odtis« njihovega videza [19]. Nato smo se problema lotili tudi teoretično, z izračunom BRDF za uklonske mrežice z vzporednimi režami sinusne oblike s periodo 1–3,5 μm in globino do 0,2 μm . Take uklonske mrežice sestavljajo holograme in hologramske folije, ki se uporabljajo za zaščito pred ponarejanjem. S pomočjo teh izračunov smo ugotovili, ali merske geometrije merilnika MA98 omogočajo dovolj

dober opis xDNA grafov in kako dobro ti ustrezajo prstnim odtisom videza takih vzorcev [21].

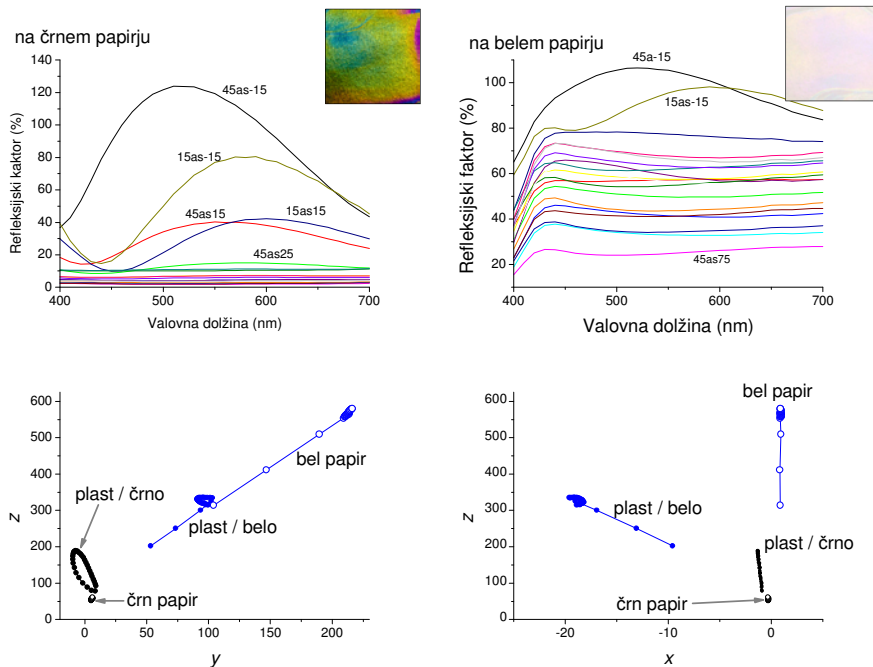
Prvi primer prikazuje, kako se v xDNA grafu odraža različna oblika površine. V ta namen smo izbrali silicijeve rezine s polirano eno stranjo in z različno hrapavostjo na zadnje strani. Polirana stran je popolnoma ravno zrcalo, kjer se vsa svetloba zrcalno odbije. Napolirana stran ima značilne mikro-oblike, ki so rezultat preferenčnega jedkanja in kristalne orientacije, v kateri je odrezana rezina (slika 5). xDNA graf polirane rezine je točka praktično v koordinatnem izhodišču – goniometrična odbojnost takega vzorca je enaka 0. Odbojnost hrapavih površin je bistveno večja in ima značilno porazdelitev po zgornji hemisferi. xDNA grafi so črte, ki so različno porazdeljene po x, y, z prostoru. Vrednost y je povezana z odmikom površinskega profila od srednje vrednosti, vrednost x pa kaže prisotnost izven-ravninskih odbojev. (slika 5)



Slika 5. xDNA grafi različno hrapavih silicijevih rezin (vzorci A, B, C, zgornja vrsta) so različne dolge črte v različnih y - z (ravninski odboji) in x - z (izven-ravninski odboji) smereh. Zrcalno polirani vzorec daje točko praktično v koordinatnem izhodišču.


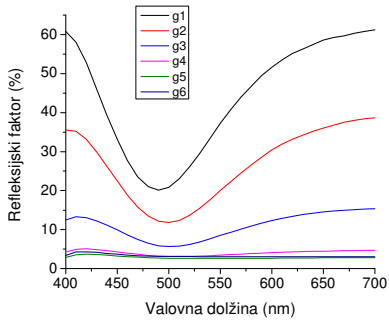
Drugi primer prikazuje DNA analizo belega in črnega papirja, na katerega smo nanесли tanko plast prozornega laka z debelino $0,21 \mu\text{m}$. Ker ta debelina zadošča interferenčnemu pogoju, se barva plasti preliva med zlato in modro, kar je najboljše vidno na črni podlagi (slika 6). Spektri odbojnosti vsebujejo interferenčne efekte zlasti na črni podlagi, na beli pa le v geometrijah, ki so blizu zrcalnim. V xDNA grafih se črna podlaga transformira v točko, bela pa v črto z zanemarljivom x (ni izven-ravninskih

odbojev). Interferenčna plast se v y - z ravnini pokaže kot zanka, ki je na črni podlagi samostojna, na beli pa kot podaljšek črte. V x - z ravnini efekt praktično ni viden (slika 6).



Slika 6. Enako debela tanka plast prozornega laka daje različni videz ter različne goniometrične odbojnosti na črni in beli podlagi (zgoraj). Pripadajoči xDNA grafi so zelo različni v y - z (ravninski odboji) in x - z (izven-ravninski odboji) smereh (spodaj).

Zanimiv primer so tudi premazi, ki vsebujejo interferenčne luske in imajo močno kotno odvisen videz. Tak primer je prikazan na sliki 7. Premaz vsebuje luske Iridin® 211 Rutile Fine Red. Te imajo sredico iz sljude, ki je oplaščena z dvema plastema, TiO_2 in SnO_2 . xDNA graf takega vzorca je zanka, ki je pravokotna na ravnino z - x (slika 7).




Slika 7. Goniometrično izmerjeni spektri odbojnosti premaza z interferenčnimi luskami (levo) se transformirajo v xDNA graf, z obliko zanke, ki leži pravokotno na ravnino z - x (desno). Z barvnimi črtami so prikazane projekcije na posamezne ravnine xDNA prostora.

Pomemben primer optične zaščite izdelkov so hologrami. Najpogosteje gre za DOVID (diffractive optically variable image device), ki so sestavljeni iz različnih ploskovnih dizajnov. Vsaka ploskev je uklonska mrežica sinusne oblike z vzporednimi režami, med seboj pa se razlikujejo večinoma le po mrežni razdalji, lahko pa tudi po smeri rež. Če take vzorce opazujemo v usmerjeni svetlobi pri goniometričnih pogojih, opazimo mavrične barve, ki izvirajo iz uklonov prvega reda [3,22]. Nekatere primerke je mogoče identificirati tudi s preprostimi optičnimi mikroskopi [23]. Bolj zapletena je uporaba hiperspektralnih upodobitev (hyperspectral imaging), s katerimi je mogoče razlikovati originale od ponaredkov [24,25]. Taki vzorci so zelo ugodni, saj je mogoče teoretično izračunati spektralne odbojnosti za poljubno mersko geometrijo z uporabo uklonskih teorij. V naših izračunih smo uporabili Fraunhoferjev uklonski integral [26], s čimer smo izračunali BRDF z različno prostorsko gostoto (okrnjenostjo) za sinusne uklonske mrežice s periodo $1 - 3,5 \mu\text{m}$ in globino/amplitudo do $0,2 \mu\text{m}$. Vsi računi in meritve so bili opravljeni tako, da je vpadna ravnina pravokotna na reže, saj se vsa svetloba odbije v tej ravnini. Spektri odbojnosti v izbranih smereh BRDF vsebujejo uklonske vrhove na značilnih mestih, ki ustrezajo uklonski enačbi

$$\sin \vartheta_d + \sin \vartheta_i = m \cdot \frac{\lambda}{p} \quad (4)$$


kjer sta ϑ_d in ϑ_i uklonski in vpadni kot, m je red uklona p pa perioda uklonske mrežice. Pri majhni amplitudi uklonske mrežice vidimo le uklone prvega reda, ki se z večanjem p pomikajo k višjim valovnim dolžinam (slika 8). Vsak uklonski vrh se v xDNA grafu transformira v ravno črto, ki izhaja iz koordinatnega izhodišča. Vsi ukloni z enako vsoto uklonskega in vpadnega kota imajo enak naklon črte v xDNA grafu (slika 8 levo).



Slika 8. xDNA grafi za uklonske mrežice z amplitudo $0,03 \mu\text{m}$ in periodami p (glej legendo) pri 6 (G6) in 17 (G17) merskih geometrijah. xDNA grafi na levi sliki so prikazani za G6 in so navpično zamaknjeni. Označene so vrednosti aspekularnega kota φ_a (enačba 2).

Pri večjem številu merskih geometrij zajamemo več uklonov, kar sledi tudi iz uklonske enačbe (4) in uklonske teorije. Zato xDNA graf vsebuje več črt in tudi take z drugimi nakloni. Primer je prikazan na sliki 8 desno. Nekateri deli premic so enaki kot pri manjšemu številu geometrij, kar potrjuje, da so premice v xDNA grafih značilne za posamezne uklonske vrhove. Poleg premic pri prostorsko gostih meritvah dobimo tudi povezave med posameznimi premicami. Te povezave pomenijo spektralno prekrivanje uklonskih vrhov, ki jih dobimo v različnih smereh.

Značilna lastnost xDNA grafov uklonskih mrežic je torej naklon črt. Ta je povezan s φ_a , aspekularnim kotom (slika 9).



Slika 9. Odvisnost naklona premic v xDNA grafu uklonskih mrežic od aspekularnega kota φ_a (enačba 2).

3. ZAKLJUČEK

Prikazali smo, da xDNA grafi vseh analiziranih vzorcev vsebujejo vse podrobnosti kotno odvisnih optičnih efektov. To potrjuje, da te grafe lahko poimenujemo »prstni odtis

videza« merjenih vzorcev. Ker so med analiziranimi primeri optično enostavni in optično kompleksni vzorci lahko trdimo, da je metoda dobra za digitalni zapis videza površin s poljubno stopnjo kompleksnosti.

Če tak zapis videza površin uporabimo za zapis originala nekega optično kompleksnega izdelka, smo dobili metodo za dokumentacijo njegovih optičnih posebnosti. Ker je to lastnost prstnega odtisa, smo 3D podobe, ki jih dobimo z DNA metodo poimenovali prstni odtis videza. Njegovo univerzalnost smo že pokazali empirično [19] in računsko na uklonskih mrežicah, ki simulirajo posamezne ploskve v hologramski zaščiti (DOVID) izdelkov pred ponarejanjem [21]. Raziskave v smeri uporabnosti metode za premaze s kotno odvisnimi efekti so v teku.

Z uporabo opisane metode dobimo možnost za podroben digitalni zapis optičnih lastnosti izdelkov s poljubno stopnjo optične kompleksnosti.

LITERATURA

1. OECD Observer: Counterfeiting and piracy, Fakes, facts and figures, http://www.oecdobserver.org/news/archivestory.php/aid/2278/Counterfeiting_and_piracy_.html
2. The Economic Impact of Counterfeiting and Piracy, <http://www.oecd.org/sti/38707619.pdf>
3. R. L. van Renesse (2005), *Optical Document Security*, 3rd ed., Artech House, Boston/London.
4. A. S. Glassner (1995), *Principles of digital image synthesis*, Morgan Kaufmann Publishers, San Francisco
5. T. A. Germer, J. C. Stover, S. Schröder, Angle-resolved diffuse reflectance and transmittance, *Experimental Methods in the Physical Sciences. Spectrophotometry: Accurate Measurement of Optical Properties of Materials*, Ed. T. A. Germer, J. C. Zwinkels, B. K. Tsai, AP Elsevier Amsterdam pp. 291-331 (2014).
6. G. Obein, R. Bousquet, and M. E. Nadal, New NIST reference goniospectrometer, *Proc. SPIE* 5880, T-1–T-10 (2005).
7. J. Suomalainen, T. Hakala, J. Peltoniemi, and E. Puttonen, Polarised multiangular reflectance measurements using the Finnish geodetic institute field goniospectrometer, *Sensors* 9, 3891–3907 (2009).
8. L. Simonot and G. Obein, Geometrical considerations in analyzing isotropic or anisotropic surface reflections, *Appl. Opt.* 46, 2615–2623 (2007).

9. V. B. Podobedov, M. E. Nadal, and C. C. Miller, Improving the performance of NIST five axis goniospectrometer for measurements of bidirectional reflectance distribution function, *Proc. SPIE* 8065, 806511 (2011).
10. A. M. Rabal, A. Ferrero, J. Campos, J. L. Fontecha, A. Pons, A., M. Rubiño, and A. Corróns, Automatic gonio-spectrophotometer for the absolute measurement of the spectral BRDF at in and out-of-plane and retroreflection geometries, *Metrologia* 49, 213–223 (2012).
11. A. Höpe and K.-O. Hauer, Three-dimensional appearance characterization of diffuse standard reflection materials, *Metrologia* 47, 295–304 (2010).
12. A. Takagi, A. Watanabe, and G. Baba, Prediction of spectral reflectance factor distribution of color-shift paint finishes, *Color Res. Appl.* 32, 378–387 (2007).
13. Standard practice for specifying the geometry of multiangle spectrophotometers, Tech. Rep. ASTM E2194.01 (2001).
14. Tolerances for automotive paint—part 2: goniochromatic paints, Tech. Rep. DIN-6175–2 (1999).
15. E. Perales, E. Chorro, W. R. Cramer, and F. M. Martínez-Verdú, Analysis of the colorimetric properties of goniochromatic colors using the MacAdam limits under different light sources, *Appl. Opt.* 50, 5271–5278 (2011).
16. E. Kirchner and W. Cramer, Making sense of measurement geometries for multi-angle spectrophotometers, *Color Res. Appl.* 37, 186–198 (2012).
17. J. K. Nisper, P. S. Rood, B. A. Pawlanta, T. M. Richardson, B. D. Teunis, Measuring an appearance property of a surface using a bidirectional reflectance distribution function, U.S. patent 0291993 A1 (20 December 2007).
18. J. K. Nisper, T. M. Richardson, M. S. Ellens, and C. Huang, Method and system for enhanced formulation and visualization rendering, U.S. patent 0213120 A1 (27 August 2009).
19. M. Klanjšek Gunde, N. Rogelj, Suitability of goniospectrophotometric space curves as appearance fingerprints, *Appl. Opt.* 52, 2718–2728 (2013).
20. MA98 Portable Multi-Angle Spectrophotometer, <http://www.xrite.com/ma98-portable-spectrophotometer>

21. N. Rogelj, I. Poberaj, M. Klanjšek Gunde, Goniospectrophotometric space curves of diffraction gratings and their applicability as appearance fingerprints, *Appl. Opt.* 52, 8355-8362 (2013).
22. L. Kotačka, T. Têthal, and V. Kolařík, Top-quality security optical elements: from holography towards 500.000 dpi, *Proc. SPIE 5954*, 59540K (2005).
23. A. Argoitia and S. Chu, Diffractive pigments help document security, *Eur. Coat. J.* 32, 32–35 (2004).
24. S. Sumriddetchkajorn and Y. Intaravanne, Hyperspectral imaging-based credit card verifier structure with adaptive learning, *Appl. Opt.* 47, 6594–6600 (2008).
25. S. Sumriddetchkajorn and Y. Intaravanne, Data-nonintrusive photonics-based credit card verifier with a low false rejection rate, *Appl. Opt.* 49, 764–771 (2010).
26. J. W. Goodman, *Introduction to Fourier Optics*, 2nd ed. (McGraw-Hill, 1996).

MINIATURNA MULTISPEKTRALNA KAMERA S ŠIROKIM SPEKTRALNIM ODZIVOM OD VIDNEGA DO KRATKOVALOVNEGA INFRARDEČEGA PODROČJA ZA MISIJO TRISAT

Iztok Kramberger

Laboratorij za elektronske in informacijske sisteme
Fakulteta za elektrotehniko, računalništvo in informatiko

E-pošta: iztok.kramberger@um.si

URL: <http://www.leis.um.si>

POVZETEK: *V prispevku je predstavljen splošen pregled vesoljske misije TRISAT in podrobnejši pregled primarnega optičnega inštrumenta v obliki miniaturne multispektralne kamere s širokim spektralnim odzivom za oddaljeno zaznavanje z namenom opazovanja vegetativnih in okoljskih procesov na Zemlji. Predstavljena je zasnova kamere za multispektralni linijski zajem slikovnega materiala na osnovi pravokotnega slikovnega senzorja in uporabe optičnih pasovno propustnih filtrov.*

1. UVOD

Aktualen razvoj novih tehnologij je v zadnjih šestih desetletjih izboljšal sposobnost razumevanja in napovedovanja dinamike zemeljskih procesov [1]. Globalno geofizikalno opazovanje, ki obsega mnoge discipline, je zagotovilo neprecenljiv vpogled v fizikalno obnašanje zemeljskih sistemov. Dandanes je naša sposobnost napovedovanja vremena, klimatskih sprememb in naravnih nevarnosti kritično odvisna od oddaljenega opazovanja planeta s pomočjo satelitov. Ena izmed pglavitnih komponent na satelitu za tovrstna opazovanja je optični inštrument.

V prispevku je predstavljena zasnova tovrstnega optičnega inštrumenta za nano satelit TRISAT v obliki miniaturne multispektralne kamere na osnovi slikovnega senzorja s širokim spektralnim odzivom od vidnega do kratkovalovnega infrardečega področja. Veliko povečanje stopnje integracije elektronskih komponent v zadnjih dveh desetletjih omogoča opazno zmanjšanje velikosti in teže elektronskih naprav pri opaznem povečanju njihove storilnosti, pri tem pa takšno dogajanje posega tudi na področje satelitskih sistemov [3]. Kljub dejstvu, da je storilnost optičnih inštrumentov omejena s fizikalnimi lastnostmi svetlobe in posledično vplivom na velikost in težo satelitov, lahko z uporabo novodobnih tehnologij zmanjšamo velikost in težo preostalih sistemov za rokovanje s podatki in s tem v nizkih Zemljinih orbitah dosežemo primerljive rezultate z mnogo večjimi, težjimi in dražjimi satelitskimi sistemi. Posledično nano sateliti

omogočajo pospešen razvoj satelitskih sistemov in spodbujajo raziskave in razvoj na področju inovativnih tehnik tehnološke miniaturizacije.

2. SPLOŠEN PREGLED MISIJE TRISAT

Misija TRISAT predstavlja izgradnjo celovitega sistema za oddaljeno zaznavanje na osnovi slikanja Zemljine površine v vidnem in kratkovalovnem področju brez poudarka na procesiranju pridobljenih rezultatov, ki zajema tako izgradnjo vesoljskega segmenta v obliki nano satelita kot tudi zemeljskega segmenta za prenos slikovnega materiala. V širšem pogledu misija TRISAT predstavlja pomemben korak internacionalizacije slovenske vesoljske industrije z ovrednotenjem njene tehnologije, promocijo vesoljskega inženirstva in spodbujanja mednarodnega sodelovanja. Pri tem so v projekt vključeni trije najpomembnejši vidiki za zagotavljanje celovitega razvojnega cikla: *raziskovalno izobraževalni vidik* na osnovi spodbujanja vesoljskega inženirstva in usposabljanja strokovnega kadra; *tehnološki vidik* na osnovi inovativne miniaturizacije sistemov satelita in njihove tehnološke demonstracije v vesolju z namenom zagotavljanja kompetenc na trgu; in *znanstveni vidik*, ki temelji na pridobivanju znanstvenih rezultatov iz pridobljenega multispektralnega slikovnega materiala na osnovi oddaljenega opazovanja Zemlje.

2.1 Zemeljski segment

Zemeljski segment predstavlja programsko definirana zemeljska postaja na sliki 1, ki jo odlikuje visoka prilagodljivost in minimalna uporaba različne strojne opreme s premikom splošnih sistemskih komponent v programski nivo.




Slika 1: Antenski sistem programsko definirane zemeljske postaje za frekvenčna področja VHF, UHF in S (levo), in pripadajoči ojačevalni elementi (desno).

S tem se doseže opazno povečanje možnosti oddaljenega nadzora in avtomatizacije celotnega zemeljskega procesa, hkrati pa omogoča enostavnejše nadgradnje za podporo novim komunikacijskim tehnologijam brez potrebe po modifikacijah strojne opreme. Zemeljski segment se bo uporabljal za upravljanje vesoljskega segmenta in pridobivanje ter procesiranje telemetrijskih podatkov, ki so ključnega pomena za spremljanje

pravilnosti delovanja satelita. Hkrati se bo uporabljal za prenos podatkov oziroma slikovnega materiala iz primarnega inštrumenta na krovu satelita, pri tem pa bo študentom ponujal možnost preizkušanja in preverjanja komunikacijskih podsistemov na osnovi novih modulacijskih tehnik tako na Zemlji kot v vesolju.

2.2 Vesoljski segment

Vesoljski segment predstavlja nano satelit na sliki 2 v *standardizirani* obliki treh enot (3U) velikostnega razreda 10 x 10 x 10 cm po posamezni enoti. Satelit sestavljajo primarni inštrument v obliki miniaturne multispektralne kamere s širokim spektralnim odzivom in ostali podsistemi, ki zagotavljajo nemoteno delovanje in uporabo vesoljskega segmenta.



Slika 2: Prikaz aktualnega modela satelita TRISAT s strani anten za širokopasovno komunikacijo (levo), s strani primarnih sončnih celic (na sredini), in v prerezu (desno)..

Življenjska doba satelita je odvisna od mnogih faktorjev, predvsem pa od stopnje aktualnega sevanja v orbiti v času delovanja in od izbire elektronskih komponent za izgradnjo podsistemov. V splošnem je v veljavi kompromis med življenjsko dobo in izbiro elektronskih komponent, pri tem pa je izbira elektronskih komponent povezana z razpoložljivimi finančnimi sredstvi, saj dosegajo namenske elektronske komponente za dolgotrajno delovanje v vesolju izjemno visoko ceno. Izgradnja nano satelitov je tipično povezana z nizko cenovno politiko, saj so predvsem namenjeni delovanju v nizkih Zemljinih orbitah od 350 do 1000 km. Glede na dejstvo, da je primarni cilj misije TRISAT tehnološka demonstracija v orbiti, so se pri načrtovanju podsistemov izbirale splošno dostopne elektronske komponente COTS¹ z ustreznim temperaturnim področjem delovanja, pri tem pa so se pri postopku izbire posameznih komponent upoštevali že pridobljeni sevalni testi na osnovi meritev ali uspešne demonstracije delovanja v orbiti. V kolikor teh podatkov za določeno potrebno komponento ni bilo mogoče pridobiti ali

¹ COTS – Comercial off-the-shelf

pa komponenta ni zadoščala zahtevam izbrane stopnje radiacije, se je izvedla dodatna zaščita takšne komponente po eni izmed vpeljanih metod za blaženje napak [2]. Ob splošni ionizaciji polprevodniških struktur oziroma umetnemu staranju elektronskih komponent zaradi blagega sevanja, se med vplivnejše učinke sevanja iz vesolja uvrščajo posamezni sevalni dogodki, kot posledica interakcije polprevodniških struktur z visoko energijskimi delci. Posamezne sevalne dogodke uvrščamo v tri skupine glede na vrsto oziroma posledico interakcije, pri tem pa vplivajo predvsem na storilnost sistema v smislu razpoložljivosti ali pa tudi dokončno končajo misijo. V namene blaženja posledic tovrstnih učinkov posameznih sevalnih dogodkov na elektronske sklope podsistemov satelita so vključene metode trojnega glasovanja, redundance komponent in tokovne zaščite ter kodiranje pomnilnikov [4].

Pričakovana letna doza sevanja oziroma skupna ionizacijska doza za pričakovane nizke Zemljine orbite med 400 in 800 km znaša do 10 kRad. Minimalna načrtovana življenjska doba satelita je 2 leti, pri tem najšibkejše komponente podsistemov zagotavljajo delovanje do 30 kRad. Kljub temu predvidevamo življenjsko dobo večjo od 6 let, kar je predvsem odvisno od aktualne stopnje sevanja (primarno odvisno od aktualne aktivnosti sonca) in višine orbite delovanja.

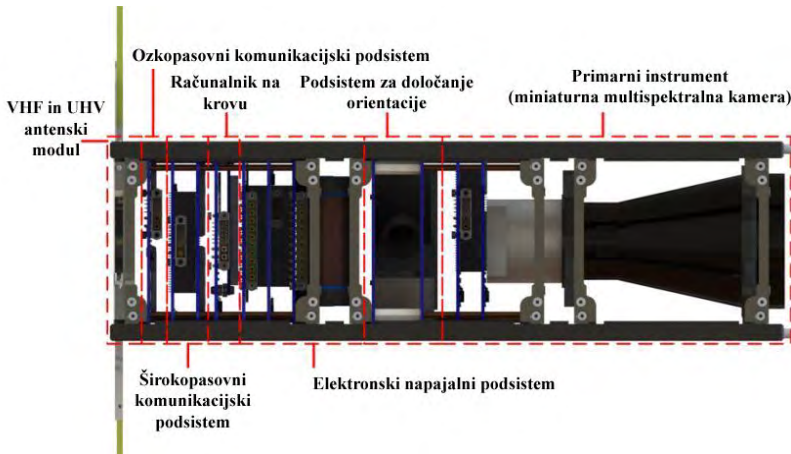
Vesoljski segment TRISAT je zasnovan tako, da ga je mogoče utiriti z večino razpoložljivih nosilnih raket brez dodatnega razvoja adapterjev. Zaradi namena slikanja Zemljine površine oziroma oddaljenega zaznavanja se zahteva sočno sinhrona orbita oziroma tej zahtevi primerna inklinacija orbite, ki omogoča prelete vsak dan ob istem času. Glede višine orbite so smiselne vse nizke Zemljine orbite, saj ima tehnološka demonstracija sistema prednost pred dosegljivo kvaliteto slikanja oziroma zemeljsko razločljivostjo. Višina orbite namreč neposredno vpliva na razločljivost slik na zemeljski površini, pri tem pa so ostali podsistemi zasnovani tako, da lahko delujejo tudi v višjih orbitah. Pri ostalih podsistemih višina orbite vpliva predvsem na stopnjo sevanja in na razpoložljivo jakost radijskega signala med vesoljskim in zemeljskim segmentom.

2.3 Pregled podsistemov in načinov delovanja satelita

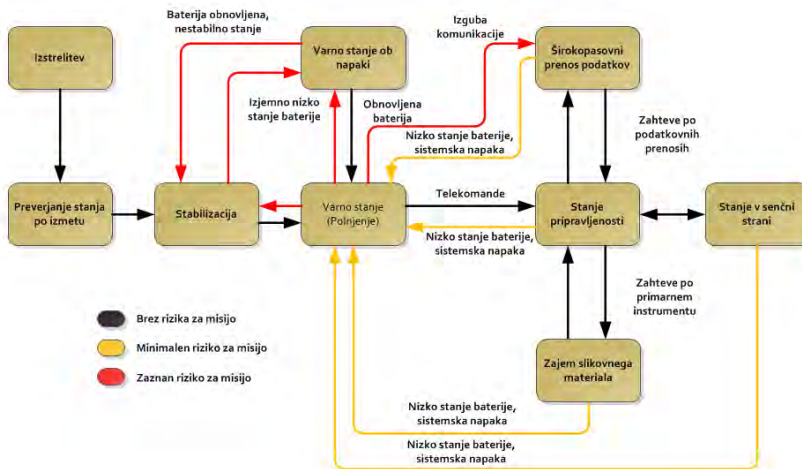
Poglavitni podsistemi vesoljskega segmenta oziroma satelita TRISAT so: *elektronski napajalni podsistem* s sočnimi celicami za zagotavljanje napajanja in upravljanja politike zaznave, izolacije in odprave napak na sistemskem nivoju; *ozkopasovni komunikacijski podsistem* s pripadajočim antenskim modulom v VHF (143,65 MHz) in UHF (435,15 MHz) frekvenčnem področju skladen s standardom CCSDS² za oddajo telemetrijskih podatkov v namene nadzora satelita ter sprejem telekomand za upravljanje satelita z zemeljskega segmenta; *programsko definiran širokopasovni komunikacijski podsistem* s pripadajočim antenskim modulom v S frekvenčnem področju (od 2,2 do 2,3 GHz) skladen s standardom CCSDS za hitre podatkovne prenose z namenom pretoka slikovnega materiala s primarnega instrumenta in programske nadgradnje sistema, ki omogoča strojno rekonfiguracijo v orbiti za namene preizkušanja novih modulacijskih

² CCSDS – Consultative Committee for Space Data Systems

shem in posledičnim doseganjem večjih bitnih hitrosti; *podsystem računalnika na krovu* s pripadajočim antenskim modulom za sprejem GNSS³ signalov z namenom upravljanja podatkov na krovu; in *podsystem za določanje in uravnavanje orientacije* satelita z namenom zagotavljanja pravilne usmeritve satelita glede na trenutni način delovanja.



Slika 3: Razporeditev podsistemov znotraj satelita TRISAT.



Slika 4: Diagram poteka med posameznimi načini delovanja.

Večina funkcij na sistemskem nivoju, kot so časovno usklajeno izvajanje urnika, distribucija sporočil, usmerjanje satelita, beleženje, shranjevanje zajetih podatkov, zaznavanje in izolacija napak, spremljanje delovanja podsistemov, itd., se izvaja na računalniku. Računalnik na krovu ima ob delovnih pomnilnikih in komunikacijskih


³ GNSS – Global Navigation Satellite System

vmesnikih vgrajen tudi podvojen masovni pomnilnik kapacitete 32 GB in GNSS sprejemnik za določanje položaja v orbiti in časovno sinhronizacijo. GNSS sprejemnik je združljiv s satelitskimi navigacijskimi sistemi *GPS*, *GLONASS*, *Galileo* in *Beidou*. Položaj v orbiti je eden izmed ključnih podatkov telemetrije, ki se na zemeljskem segmentu uporablja za korekcijo usmerjanja antenskega sistema. Na sliki 4 so prikazani posamezni načini delovanja satelita in načrtani prehodi med njimi. V primeru napake se sistem postavi v varno stanje z usmeritvijo sončnih celic proti soncu z namenom pridobivanja električne energije. Glede na zasnovo same zgradbe satelita je potrebna drugačna usmeritev v načinu slikanja in širokopasovne komunikacije.



Slika 5: Primer usmerjanja satelita za zajem slikovnega materiala z več prehodi.

V načinu zajema slikovnega materiala se optična os objektivna usmeri proti zemlji z možnostjo natančnega usmerjanja primarnega inštrumenta s točnostjo 0,1 kotne stopinje in možnostjo izvajanja slikanja z več hkratnimi prehodi, kot je prikazano na sliki 5. Podobno je v načinu širokopasovne komunikacije potrebno usmeriti antenski sistem proti Zemlji z namenom zagotavljanja ustrezne signalne jakosti radijskega signala. Za usmerjanje satelita so v vseh treh prostorskih oseh vgrajene tuljave za ustvarjanje magnetnega vrtilnega momenta in kolesa za ustvarjanje vztrajnostnega vrtilnega momenta. Določanje orientacije je izvedeno s triosnimi linearnimi pospeškometri, preciznimi giroskopi, fotodiodami in magnetometri. Za natančno določanje orientacije skrbi dodatno vgrajena miniaturna kamera visoke razločljivosti z možnostjo razpoznavanja zvezdnih vzorcev. Posamezni prehodi med načini delovanja lahko predstavljajo večji ali manjši riziko za misijo, pri tem pa enota za zaznavo, izolacijo in odpravljanje napak neprestano spremlja posamezne podsisteme, vključno z nadzorom porabe električne energije in temperaturno stabilizacijo. Med najbolj rizične prehode spada okrevanje po napaki v primeru nizkega stanja baterije in nestabilne orientacije strukture. V ta namen smo razvili posebne module za optimizacijo pridobivanja električne energije v obliki analogno izvedenega algoritma za določanje točke največje moči sončnih celic, ki omogoča polnjenje baterij tudi v primeru hitrega nestabilnega obračanja strukture do 1 Hz pri točnosti sledenja 80 odstotkov.



Slika 6: Prikaz komunikacijskih povezav med posameznimi podsistemi z distribucijo napajanja.

Vsi podsistemi satelita so med seboj povezani z redundantnim komunikacijskim vodilom CAN⁴, kot je prikazano na sliki 6. Vodilo CAN omogoča uniformno komunikacijo med posameznimi podsistemi v vseh načinih delovanja. Kljub morebitnemu izpadu računalnika na krovu, je možno delovanje satelita uravnavati preko zemeljskega segmenta. Za neposreden nadzor v najbolj kritičnih situacijah in nedelujočem vodilu CAN je možno satelit upravljati preko vmesnika za neposredne komande in telemetrijo. Za zagotavljanje hitrih podatkovnih tokov med primarnim inštrumentom, računalnikom na krovu in širokopasovno komunikacijo so dodani hitri zaporedni diferenčni vmesniki LVDS⁵, pri tem so bitni tokovi kodirani z *8b10b* kodno shemo.

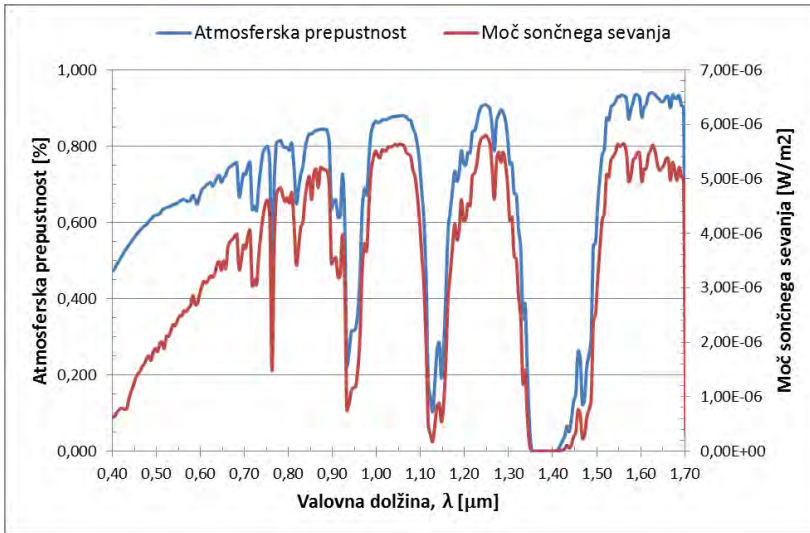
2. ODDALJENO ZAZNAVANJE

Oddaljeno zaznavanje je proces zbiranja podatkov o objektih ali lastnostih površja brez neposrednega kontakta. Večinoma se oddaljeno zaznavanje izvaja iz letal ali satelitov z uporabo inštrumentov, ki merijo elektromagnetno valovanje, ki se odbija ali oddaja od terena. V splošnem slikanje za oddaljeno zaznavanje sestavljajo štiri dimenzije: prostorska, spektralna, radiometrična in časovna. Zaradi fizikalnih omejitev nano satelitov se le-te med seboj nekako izključujejo in posledično ne moremo doseči največjih vrednosti v vseh dimenzijah hkrati, lahko pa optimiziramo nekatere od njih. Načrtan primarni inštrument satelita izkorišča odboj sončnega elektromagnetnega sevanja od zemeljske površine. Uporablja energijo od vidnega do kratkovalovnega infrardečega dela spektra, pri tem je prednost slednjega v možnosti penetracije skozi tanke oblake, kar poveča uporabnost. Zemljina atmosfera vključuje tri vplivne faktorje, ki omejujejo sončno elektromagnetno valovanje na poti do Zemljine površine in nazaj do optičnega inštrumenta (senzorja): absorpcija, razpršenost in turbulenca [6]. Ti faktorji predstavljajo oviro za širjenje elektromagnetnega valovanja in imajo posledično velik vpliv na razmerje med signalom in šumom sistema. Atmosfera vpliva na elektromagnetno valovanje proti senzorju inštrumenta na dva načina. Lahko oslabi energijo osvetljenosti zemeljskega objekta oziroma sevnost odboja ali sama deluje odbojno z dodajanjem sevnosti proti senzorju inštrumenta [7]. Na sliki 7 so predstavljena atmosferska okna in moč sončnega sevanja od vidnega do kratkovalovnega infrardečega

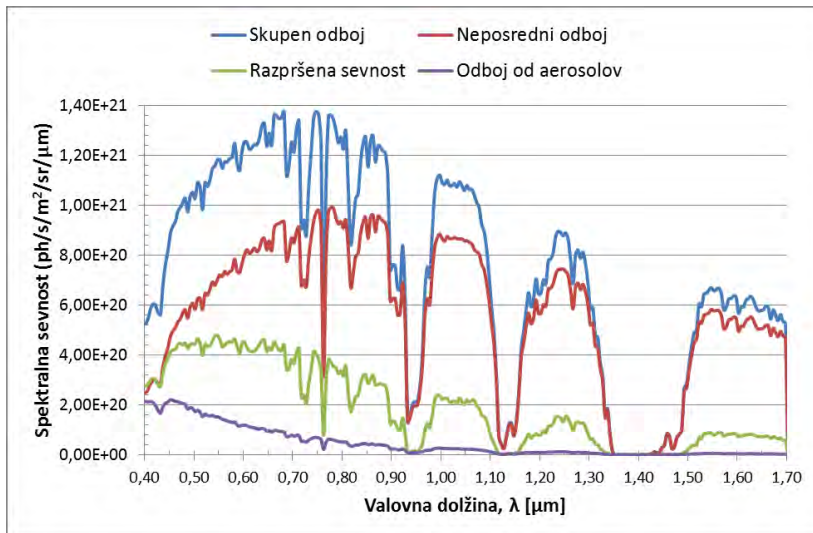
⁴ CAN – Controller Area Network

⁵ LVDS – Low Voltage Differential Signaling

področja na osnovi modela atmosferske propustnosti sevanja [8]. Slika jasno prikazuje, da v področju med $1,36 \mu\text{m}$ in $1,4 \mu\text{m}$ ni nobenega atmosferskega prenosa zaradi močne absorpcije vodnih hlapov. Slika 8 prikazuje spektralno odvisnost sevnosti odbojev na vrhu atmosfere, ki sledi vzorcu atmosferskih oken. Sevnost kot posledica odbojev aerosolov v atmosferi je mnogo manjša (do 100 krat) od skupne sevnosti odboja.



Slika 7: Atmosferska okna od vidnega do kratkovalovnega infrardečega področja svetlobnega spektra.



Slika 8: Sevnosti odbojev na vrhu Zemljine atmosfere.


Spektralno odvisna sevnost kot odboj sončnega sevanja na vrhu Zemljine atmosfere v smeri senzorja je bila izračunana s pomočjo modela atmosferske propustnosti sevanja za področje spektra od 400 nm do 1700 nm pri kotu sonca 60° na zenit in kotu kamere 0° na zenit (nadir). Za modeliranje področja atmosfere so bile uporabljene srednje zemljepisne širine (položaj Slovenije) z vidnostjo 23 km. Pri tem je bil model aerosolov v atmosferi nastavljen na ruralno področje in model terena na globalno povprečje.

2.1 Multispektralno filtriranje

Multispektralno filtriranje dosežemo z namestitvijo fiksnih optičnih filtrov pred pravokotni optični senzor. Za doseganje multispektralne karakteristike v opazovanem področju spektra se na nosilni substrat senzorja izvede nanos večjega števila ozkih pasovno propustnih filtrov. Na ta način pravokotni senzor deluje kot linijski senzor s skupino slikovnih vrstic v različnih spektrih. Pri uporabi fiksnih optičnih filtrov je potrebno področja pasovno propustnih filtrov predhodno definirati že v času proizvodnje. Posamezna uporabna področja skupnega spektra so odvisna od treh faktorjev: atmosferske propustnosti, občutljivosti detektorja v smislu kvantne storilnosti in profila spektralno odvisne obsevanosti s strani sonca. Pri tem so ocenjene centralne valovne dolžine posameznih pasovno propustnih optičnih filtrov odvisne od namena zaznavanja.

3. PRIMARNI OPTIČNI INŠTRUMENT

Primarni optični inštrument misije TRISAT predstavlja miniaturna multispektralna kamera s širokim spektralnim odzivom od vidnega do kratkovalovnega infrardečega področja spektra elektromagnetnega valovanja. Miniaturna kamera ponuja zmerno storilnost pri nizki ceni in je specifično zasnovana za nano satelite. Podsystem kamere na sliki 9 sestavljajo objektiv, polje robnih filtrov, pravokotni slikovni senzor in miniaturni procesni elektronski sistem.

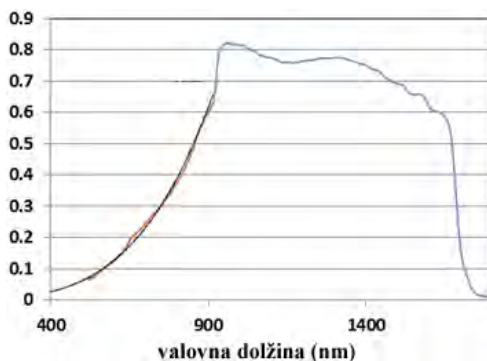


Slika 9: Tridimenzionalen model primarnega optičnega inštrumenta.

Osnovni cilj optičnega inštrumenta je zbiranje slik namenjenih oddaljenemu zaznavanju vegetativnih in okoljskih procesov na Zemljini površini, kot so: meje zemeljskih voda, meje talnih pridelkov, ocenjevanje uničenja pridelka, zaznavanje požarov in njihovih posledic, obseg poplav, detekcija vulkanskega prahu, itd. Vgrajen slikovni senzor zaznava odboj sončnega sevanja od površine Zemlje v vidnem, bližnjem in kratkovalovnem infrardečem delu spektra. Podsystem primarnega inštrumenta vsebuje lasten vgrajen sistem na osnovi do napak strpne arhitekture, ki vsebuje lastno procesorsko jedro, kodirane delovne pomnilnike, kodiran podvojen masovni pomnilnik za začasno shranjevanje slikovnega materiala, podvojen vmesnik CAN za telekomande in telemetrijo ter vmesnik LVDS za hitre podatkovne prenose z ostalimi podsistemi satelita.

3.1 Optika, senzor in polje filtrov


Optični inštrument je zasnovan kot linijska kamera, pri tem pa se pravokotna lastnost optičnega senzorja velikosti 640 x 512 slikovnih točk uporablja za multispektralni zajem na osnovi 25 optičnih filtrov. Velikost slikovne točke trenutno izbranega slikovnega senzorja znaša 20 μm , pri tem pa detektor na osnovi več spojne polprevodniške strukture InGaAs omogoča širok spektralni odziv znotraj uporabne kvantne storilnosti, prikazane na sliki 10. Razločljivost linije kamere tako znaša 640 slikovnih točk, pri tem pa so vrstice slikovnega senzorja porazdeljene čez polje optičnih filtrov, s čimer se doseže multispektralni zajem ene vrstice opazovanega področja v 25 različnih svetlobnih spektrih. Pri tem 15 vrstic slikovnega senzorja pripada posameznemu spektralnemu področju oziroma optičnemu filtru, od tega se 5 vrstic porablja za prekrivanje med zaporednimi linijskimi posnetki za zmanjševanje linijskega sprehajanja (nestabilnost usmerjanja satelita med slikovnim zajemom) na osnovi nadaljnjega procesiranja. Del oziroma pas slikovnega senzorja ostane nepokrit z namenom *pankromatičnega* zajema (zajem celotnega spektra).



Slika 10: Kvantna storilnost uporabljenega slikovnega senzorja.

Optiko sestavlja 6 leč z žariščno razdaljo 100 mm pri splošni razdalji 145 mm med sprednjimi lečami in slikovno ravnino. Optika je zasnovana za hitro delovanje z dvojnimi razmerjem med žariščno razdaljo in premerom vstopne leče oziroma številom $F2.0$ za

visoko osvetlitev in kratke integracijske čase. Hitrost objektiv je izjemno pomembna zaradi linijske narave delovanja kamere. Na sliki 11 je prikazana optična pot skozi objektiv in optične filtre do slikovnega sensorja.



Slika 11: Prerez optične strukture in namestitev optičnih filtrov ter slikovnega sensorja.

Propustnost objektiv v vidnem in kratkovalovnem infrardečem spektru je nad 95 odstotkov, pri tem znaša kot pogleda $7,3^\circ$. Velikost slikovne ravnine za zasnovan objektiv znaša 16,4 mm za podporo slikovnega sensorja z velikostjo slikovne točke 20 μm . Radialno popačenje objektiv je manjše od 0,4 odstotka. Premer leče znaša 50 mm, pri tem pa teža objektiv dosega 600 g. Zadnje modifikacije strukture satelita kažejo na to, da bi bilo možno žariščno razdaljo predstavljenega objektiv povečati za dodatnih 40 mm na skupnih 140 mm, pri tem pa bi se izboljšala razločljivost zajetega slikovnega materiala na površini Zemlje. Material objektiv na osnovi invar zlitine zagotavlja ustrezne pogoje temperaturnega razširjanja.

3.2 Slikanje in integracijski časi

Izračuni za slikanje so izvedeni za nizko Zemljino orbito pri 600 km in slikovni senzor z velikostjo slikovne točke 20 μm . Kočno razločljivost optičnega instrumenta predstavlja vzorčna razdalja na Zemljini površini GSD⁶, ki se nanaša na področje površine zajete z eno slikovno točko. Poenostavljeno jo lahko zapišemo kot:

$$GSD = r \cdot \frac{p}{f} \cdot \frac{1}{\sqrt{\cos \Psi}} \quad (1)$$

⁶ GSD – Ground Sampling Distance

Kot zenita ψ predstavlja kot med normalo na opazovano ravnino in normalo na ravnino pogleda. Pri pravokotnem pogledu (nadir) dobimo največjo vzorčno razdaljo, vendar je v določenih primerih bolje izvajati zajem s strani (globina slike). Parameter r predstavlja orbito satelita in f žariščno razdaljo optike. Glede na naravo delovanja optičnega inštrumenta predstavlja zajem ene slike iz slikovnega senzorja dejanskih 15 vrstic opazovanega področja v multispektralni obliki. Med preletom satelita čez opazovano področje se tako vrstice v multispektralni obliki sestavljajo multispektralne slike. Pri višini orbite 600 km znaša vzorčna razdalja 120 m, preslikana hitrost gibanja na površini Zemlje 6,9 km/s in širina opazovanega področja oziroma ena slikovna vrstica na Zemljini površini 76,8 km. Iz danega sledi, da je čas za prehod ene vzorčne razdalje 17,37 ms. Da zagotovimo ustrezen kontrast oziroma preprečimo zameglitev zajetega slikovnega materiala, je potrebno slikovni senzor vzorčiti v časovnih intervalih manjših od danega časa. Ker se pankromatične slike zajemajo pri različnih nastavitvah ojačenja slikovnega senzorja, je potrebno izvesti vzorčenje dveh slikovnih okvirjev v času prehoda ene vzorčne razdalje na Zemlji. Iz omenjenega sledi, da je lahko največji razpoložljiv čas za integracijo in vzorčenje senzorja manjši od 8,5 ms. Potreben integracijski čas je odvisen od spektralno odvisne količine svetlobe v posameznem pasu, ki vpada na posamezen element slikovnega senzorja, velikosti slikovne točke, prepustnosti posameznega filtra, spektralno odvisne kvantne storilnosti senzorja v posameznem pasu, spektralno odvisne prepustnosti optike v posameznem pasu in ojačenja senzorja. Zadovoljive integracijske čase je tako potrebno izračunati za vsako posamezno spektralno področje, ki ga določajo pasovno propustni filtri nameščeni na slikovnem senzorju. Skupen fotonski tok R v izbranem področju valovnih dolžin lahko zapišemo kot [10]:

$$R = \int_{\lambda_1}^{\lambda_2} L_{\lambda}^{ph} d\lambda . \quad (1)$$

Pri tem ima skupna spektralno odvisna sevnost L_{λ} kot posledica sončnega sevanja na vrhu atmosfere v smeri proti senzorju optičnega inštrumenta tri osnovne komponente [7]: spektralno odvisno sevnost neposrednega odboja sončnih žarkov L_N , spektralno odvisno difuzno sevnost razpršenega odboja sončnih žarkov izven opazovane scene L_D in spektralno odvisno sevnost odbojev aerosolov v atmosferi v smeri senzorja L_A .

$$L_{\lambda} = L_N + L_D + L_A . \quad (2)$$

Glede na podano zasnovo lahko spektralno odvisno kvantno storilnost celotnega inštrumenta K izrazimo kot:

$$K = \frac{\pi}{4} \cdot \left(\frac{p}{F} \right)^2 \cdot \eta_F \cdot \eta_S(\lambda_C) \cdot \tau_O(\lambda_C) . \quad (3)$$

Pri tem je p velikost slikovne točke, F število objektiv, η_f izkoristek filtra za posamezno področje spektra, $\eta_S(\lambda)$ kvantna storilnost oziroma izkoristek senzorja in $\tau_O(\lambda)$ propustnost optike pri centralni valovni dolžini λ_C posameznega spektralnega področja.

Iz danega lahko zapišemo skupen elektronski tok ϕ za izbrano področje valovnih dolžin posameznega spektralnega področja:

$$\Phi = K \cdot (R_S + R_N). \quad (4)$$

Pri tem R_S predstavlja koristen elektronski signal na osnovi sevnosti L_N in L_D , medtem ko R_N predstavlja šumni signal na osnovi sevnosti L_A . Z uporabo Planckovega zakona lahko koristen in šumni signal za izbrano področje valovnih dolžin posameznega spektralnega področja določimo iz vrednosti posameznih sevnosti pridobljenih na osnovi modela atmosferske propustnosti sevanja:

$$R_S = \int_{\lambda_1}^{\lambda_2} \left(\frac{\lambda}{h \cdot c} \cdot (L_1(\lambda) + L_2(\lambda)) \right) d\lambda. \quad (5)$$

$$R_N = \int_{\lambda_1}^{\lambda_2} \left(\frac{\lambda}{h \cdot c} \cdot L_3(\lambda) \right) d\lambda. \quad (6)$$

Izračun koristnega R_S in šumnega R_N signala za vidno in kratkovalovno infrardeče področje na osnovi atmosferskega modela je podan v tabeli 1.

Tabela 1: Izračun koristnega in šumnega signala za vidno in kratkovalovno infrardeče področje.

	Spektralna sevnost [10^{18} ps/s/m ² /μm]	
Spektralni pas	R_S	R_N
Kratkovalovni IR	305,5	41,1
Vidni	179,7	5,1

Na osnovi izračuna koristnega signala R_S in kapacitivnosti oziroma največjega naboja celice slikovne točke ter ojačenja sensorja lahko določimo predvidene integracijske čase T_I za posamezno spektralno področje. Nadalje lahko izračunamo predvideno razmerje med signalom in šumom kot:

$$SNR = \frac{\Delta\rho \cdot K \cdot R_S \cdot T_I}{\sqrt{[K \cdot (\rho \cdot R_S + R_N) + \Phi_D] \cdot T_I + N_R + N_Q}}. \quad (6)$$

Za izračun razmerja med signalom in šumom smo za ciljni signal upoštevali spremembo odbojnosti $\Delta\rho = 0,08$ in za izračun naključnega šuma zaradi ciljnega signala odbojnost $\rho = 0,15$ [11]. Pri tem je uporabljen temni tok sensorja ϕ_D , šum analognega branja naboja slikovne točke sensorja N_R in šum kvantizacije 12-bitne analogno digitalne pretvorbe N_Q . Tabela 2 prikazuje primer izračuna integracijskih časov in razmerja med signalom in šumom za nekatere pasovno propustne filtre v vidnem, bližnjem in kratkovalovnem infrardečem spektru.

Tabela 2: Izračun največjega integracijskega časa in razmerja med signalom in šumom za določena področja valovnih dolžin.

<i>Spektralni pas</i>	$\lambda_c[nm]$	<i>Širina filtra [nm]</i>	$T_i[ms]$	<i>SNR[dB]</i>
Rdeč	650	80	0,419	37,9
Zelen	550	100	0,573	35,9
Moder	490	120	0,698	34,2
Bližnji IR	800	100	0,204	39,6
Kratkovalovni IR	1250	700	0,594	52,1
Vidni	700	500	0,515	48,6


3.3 Podatkovna hitrost

Podatkovna hitrost zajetega multispektralnega slikovnega materiala je odvisna od višine orbite delovanja optičnega inštrumenta. Glede na geometrijo pravokotnega slikovnega senzorja oziroma namestitve 25 optičnih pasovno propustnih filtrov se po vrsticah ustvari hkraten multispektralni zajem, pri tem se za vsak spektralni pas zajame 15 vrstic opazovanega področja. Od tega je 5 vrstic namenjeno prekrivanju med posameznimi linijskimi posnetki za opravljanje nestabilnosti satelita, pri tem se vrstice prekrivanja koristijo za kasnejšo poravnavo linijskih posnetkov. Posledično vsak linijski posnetek v posameznem spektralnem pasu predstavlja 10 učinkovitih slikovnih vrstic opazovanega področja na Zemlji. Iz danega sledi, da je potrebno linijske posnetke opravljati na vsakih 10 vzorčnih razdalj na Zemlji. Pri višini orbite 600 km znaša 10 vzorčnih razdalj 5,75 linijskih posnetkov oziroma slik na sekundo. Iz razmerja med predvidenim signalom in šumom za posamezna spektralna področja v tabeli 2 je razvidno, da je za zapis vrednosti slikovnih točk zadostna *10-bitna* dinamika. Iz podanega sledi, da je za zapis zajetega slikovnega materiala potrebna podatkovna hitrost *13,2 Mbit/s* za multispektralni zajem ali *0,52 Mbit/s* za zajem na posamezno spektralno področje. Če upoštevamo uporabo stiskanja podatkov brez izgube v razmerju *2:1*, se učinkovita podatkovna hitrost razpolovi na *6,6 Mbit/s* ali *0,26 Mbit/s* na posamezen spektralni kanal.

3.4 Slikanje z več prehodi

Uporaba zajema slikovnega materiala z več prehodi med posameznim preletom poveča širino opazovanega področja. Pri višini orbite 400 km je potreben kotni pospešek $1,3^\circ/s^2$ v dveh smereh, kot prikazuje slika 12. Pri uporabi višje orbite je potreben manjši kotni pospešek. Za zmanjšanje kompleksnosti delovanja se slikanje ne bo izvajalo med obračanjem satelita. Pri slikanju z dvema prehodoma v orbiti z višino 600 km je na posamezen prelet potrebno satelit zavrteti za $36,8^\circ$ vzdolžno v smeri gibanja in 14° prečno na smer gibanja. Satelit je potrebno stabilizirati v manj kot 28,9 s. Pri tem predvidevamo, da je čas potreben za pospeševanje in pojemanje obračanje satelita enakovreden. V kolikor se bo satelit najprej obračal vzdolžno v smeri gibanja in nato

prečno ter ob upoštevanju potrebnega časa za stabilizacijo satelita 2 s, znaša potreben kotni pospešek za izvajanje manevra prehoda $0,39^\circ/s^2$ v smeri preleta. Nižje orbite povečajo potrebni kotni pospešek, saj se čas preleta opazovanega področja zmanjša.




Slika 12: Prerez optične strukture in namestitev optičnih filtrov ter slikovnega senzorja.

4. ZAKLJUČEK

V prispevku je predstavljen splošen pregled misije TRISAT, vključno s predstavitvijo zgradbe satelita in splošnim opisom posameznih podsistemov ter njihovih medsebojni relacij. Nadalje je podrobneje predstavljena zasnova primarnega optičnega inštrumenta v obliki miniaturne linijske kamere s spektralnim odzivom od vidnega (400 nm) do kratkovalovnega infrardečega področja (1650 nm). Rezultati kažejo, da je z nano sateliti možno doseči zmeren zajem slikovnega materiala v multispektralnem načinu za namene oddaljenega zaznavanja procesov na površini Zemlje, pri tem pa večanje zemeljske vzorčne razdalje zaradi prostorskih omejitev optičnega dela zmanjšuje širino opazovanega področja. Prikazan je postopek večanja širine opazovanega področja na osnovi slikanja z več prehodi med posameznimi preleti, ki pa kaže omejitve s strani zahtevanih kotnih pospeškov za obračanje satelita glede na višino izbrane orbite. Trenutno izbrana reakcijska kolesa ne zadovoljujejo ocenjenim zahtevam, kar posledično pomeni integracijo dveh dodatnih reakcijskih koles v vzdolžni in prečni smeri gibanja. Prikazani so rezultati atmosferskega modela propustnosti sevanja za področje Slovenije, pri tem pa so izvedeni primeri izračunov potrebnih integracijskih časov za posamezna spektralna področja glede na podan atmosferski model in pripadajoče razmerje med signalom in šumom. Izvedena je bila tudi zasnova večje strukture v standardni 6U obliki dimenzij $60 \times 10 \times 10$ cm in teže 12 kg, ki je prikazana na sliki 13. Rezultati za večjo strukturo kažejo na izboljšanje vzorčne razdalje na 12,5 m pri višini orbite 500 km. Pri tem se ohranja širina opazovanega področja z uporabo slikovnega senzorja višje razločljivosti. Kljub temu povečana masa večje strukture zahteva močnejše vztrajnike za obračanje satelita v primeru izvajanja slikanja z več prehodi. Glede na nizko ceno zasnove in nizko ceno utiranja nano satelitov je možno za izvedbo vesoljskega segmenta

uporabiti večje število satelitov, saj se s tem izboljša časovna komponenta oddaljenega zaznavanja z bolj pogostimi preleti opazovanega področja.



Slika 13: Prerez zasnove satelita v standardni 6U z uporabo izboljšanega optičnega inštrumenta.

LITERATURA

1. National Research Council (2008), *Earth Observations from Space: The First 50 Years of Scientific Achievements Committee on Scientific Accomplishments of Earth Observations from Space*, National Academies Press.
2. D. Gačnik, I. Kramberger (2011), A low-cost on-board data handling system for ESMO mission, *11th ILEWG international conference on exploration and utilisation of the moon (ICEUM 11) - Global lunar conference*, Beijing, China.
3. M. Gostenčnik, I. Kramberger (2014), Iztok. Design of a compact low power fault tolerant on-board computer for small satellites, *Small Satellites Systems and Services Symposium*, Majorca, Spain, ESA.
4. I. Kramberger (2012), Design of generic CAN node for ESMO mission, *Small Satellites Systems and Services Symposium*, Portorož, Slovenia, ESA.
5. P. Seitz (2014), *More pixels or more than pixels? The future of semiconductor photosensing*, Image Sensors.

6. J. B. Campbell, R. H. Wynne (2011), *Introduction to Remote Sensing*, The Guilford Press, New York.
7. T. M. Lillesand, R. W. Keifer (2000), *Remote Sensing and Image Interpretation*, John Wiley and Sons, New York.
8. W. M. Cornette (2006), Moderate Spectral Atmospheric Radiance and Transmittance (MOSART) Computer Code Version 2.00, *Proc. IEEE-GRSS/AFRL Atmospheric Transmission Modeling Conference*, Lexington, MA.
9. G. C. Higgins (1964), Methods for Engineering Photographic Systems, *Applied Optics*, vol 3, no. 1.
10. C. G. Holst (1998), *CCD arrays, cameras, and displays*, JCD Publishing, Washington.
11. C. J. Leachtenauer (1997), W. Malila, J. Irvine, L. Colburn, N. Salvaggio, General Image-Quality Equation: GIQE, *Applied Optics*, vol. 36, 8322-8328.
12. T. Rotovnik, D. Gačnik, I. Kramberger, et al. (2014). Miniaturized multispectral SWIR optical payload for small satellites, *Small Satellites Systems and Services Symposium*, Majorca, Spain, ESA.
13. <http://www.trisat.um.si>
Informacije o konferenci misiji TRISAT.

INDUSTRIJSKE APLIKACIJE

AVTOMATSKO ŠTETJE PROMETA S POMOČJO VIDEO-SLIKOVNEGA MATERIALA V REALNEM ČASU

Boštjan Celan¹, Matjaž Šraml¹, Goran Jovanović², Peter Podbreznik¹

¹Univerza v Mariboru, Fakulteta za gradbeništvo
E-pošta: bostjan.celan@gmail.com, matjaz.sraml@um.si,
peter.podbreznik@um.si

²Appia, Ljubljana
E-pošta: goran.jovanovic@appia.si

POVZETEK: *Analiziranje odvijanja prometa je ključnega pomena za različna področja načrtovanja in določanja projektnih elementov prometne infrastrukture. Štetje prometa je obsežno področje in zanj na svetovnem tržišču obstaja mnogo rešitev. Takšne rešitve so praviloma finančno nedostopne majhnim podjetjem in različnim institucijam. Z razvojem sistema avtomatskega štetja prometa s pomočjo video-slikovnega materiala v realnem času, kateri za svoje delovanje ne potrebuje drage opreme, je rešitev za prej omenjene težave. Skupaj s tem za svoje delovanje ne zahteva posegov v prometno infrastrukturo in s tem podaljšuje njeno življensko dobo in kvaliteto. Sistem deluje na način primerjave zaporednih slik video posnetka. Z odštevanjem zaporednih slik odstrani ozadje in določi objekt v opazovanem območju. S pomočjo koordinat na novo določenega objekta in virtualne črte ter izračunom povprečnih vrednosti intenzitete slikovnih elementov, prešteje vsak objekt znotraj opazovanega območja. Skupaj s tem omogoča osnovno klasifikacijo vozil, ki temelji na prej omenjenem izračunavanju povprečnih vrednosti slikovnih elementov znotraj opazovanega območja. Povprečna natančnost algoritma je $97,5 \pm 2,18$ %, izračunana na podlagi šestih video posnetkov s približno 350 vozili.*

1. UVOD

Pogosto pojavljanje zastojev v prometnem toku se običajno rešuje s preoblikovanjem prometnega režima in/ali infrastrukture. Tovrstni ukrepi praviloma vplivajo na navade udeležencev in posledično tudi na njihov življenjski stil, zato morajo ukrepi biti izvedeni premišljeno. Zaradi kompleksnosti prometnih tokov in infrastrukture je potrebno pred uvedbo ukrepov izvesti analize in simulacije, s katerimi je mogoče predvideti različne vrste posledic, nato pa po uvedbi nove prometne ureditve evalvirati izvedene ukrepe.

V obeh primerih je lastnosti prometnega toka mogoče izmeriti bodisi ročno s človeškimi viri, bodisi avtomatsko z uporabo najrazličnejših merilnih naprav, ki za delovanje izkoriščajo različne fizikalne principe, kot so: elektromagnetizem, inducirana napetost, odboj svetlobe, sprememba tlaka itd. Ključna problema uveljavljenih merilnih naprav sta

invazivna metoda nameščanja in/ali ne nemoteča metoda merjenja, kar praviloma vpliva na obnašanje deležnikov.

Naprave za zajem slik in videa so v zadnjem desetletju doživele izjemen razcvet in podobno tudi programska oprema (algoritmi na področju računalniškega vida, digitalne obdelave slik itd.). Ob ustrezni izvedbi merilne metode s kamerami je le-ta neinvazivna (ohranjanje prometne infrastrukture) in nemoteča (ne vpliva na obnašanje deležnikov), s čimer se poveča verodostojnost meritve. Raziskovalno delo bo usmerjeno v razvoj novih algoritmov in metod za merjenje lastnosti prometnih tokov.

Analizirali smo različne sisteme za avtomatsko spremljanje prometa, kot so Anacomda OD, OKO-T1, Miovision, De Rotondeteller, Logiroad in Countingcars. Našteti sistemi so si med seboj precej različni, tako po funkcionalnosti, kot tudi po ponujenih storitvah. Tako sistem Miovision ponuja le snemalno opremo in storitve preštevanja vozil in pešcev na različni prometni infrastrukturi ter hkrati še klasifikacijo [20]. Na drugi strani pa sistem Countingcars temelji na povsem drugačnem konceptu, saj osnovni paket ponuja dve kameri, program in COUNTpad vmesnik s katerim uporabniki samostojno obdelajo video vsebine [21]. Sistema, kot sta Logiroad [22] in Anacomda OD [23] pa ponujata obdelavo podatkov in izvedbo analiz v realnem času. Praviloma sistemi za detekcijo vozil uporabljajo širokokotne kamere z visokim stojalom (v primeru krožnega križišča 13-15 m).

Aplikacije za video detekcijo prometa temeljijo na različnih principih in zato zagotavljajo različne funkcionalnosti, in sicer:

- Zaznavanje izrednih prometnih situacij [17].
- Zaznavanje vozil iz drugih gibajočih vozil [1, 2].
- Štetje prometa in merjenje hitrosti ter zaznavanje vozil s hitrostnimi prekoračitvami [3, 6].
- Zaznavanje in sledenje vozil v realnem času [18, 10, 11, 12].
- Štetje prometa v realnem času [13, 5, 14, 7, 15].
- Zaznavanje in klasifikacija vozil [4, 8].
- Zaznavanje pešcev in vozil [16].
- Razvoj smernic na področju sistemov zaznavanja vozil iz video materiala [19].

2. ZASNOVA SISTEMA

Aplikacija za avtomatsko štetje prometa je bila izdelana v razvojnem okolju Microsoft Visual Studio 2010, z uporabo odprtokodne knjižnice OpenCV. Za detekcijo gibanja je bila uporabljena metoda z odštevanjem ozadja [24].

Rezultat so binarne slike, kjer slikovni elementi z minimalno intenziteto predstavljajo mirujoča območja slik, slikovni elementi z maksimalno intenziteto pa gibajoča. Slednji slikovni elementi pa vedno ne predstavljajo samo objektov, katere želimo obdelovati v nadaljevanju. Hkrati z njim navadno potujejo sence ali pa se na primer reflektira

svetloba. Takšni slikovni elementi so bili odpravljeni s funkcijami raztezanja in krčenja, katerih rezultat je zagotavljanje prvotne oblike analiziranega objekta, kot prikazuje slika 1.



Slika 1: Binarizirana slika, dobljena z metodo odštevanja ozadja (levo) in slika posnetka (desno).


Območja z maksimalno intenziteto na sliki 1 levo predstavljajo potencialno zanimive objekte. Predpostavljamo, da se objekti v prometu gibljejo po prometni infrastrukturi, zato detekcija gibanja na celotnem video posnetku ni potrebna. Zaradi tega smo uporabili opazovanje v izbranih območjih, kjer se tudi izvaja štetje s predpostavko, da se znotraj območja lahko pojavljajo samo objekti opazovanja, v našem primeru vozila. Identifikacija premikajočih objektov je bila dosežena s funkcijo oblikovanja obrisov opazovanih objektov. Vsakemu objektu je bila določena x in y koordinata s pomočjo katere se je lahko pričel postopek štetja. Za potrebe štetja objektov smo uporabili virtualno črto in koordinate opazovanega objekta znotraj opazovanega območja. Preštevanje objektov se je izvajalo z izračunom evklidske razdalje med sredinsko točko virtualne črte in koordinatami opazovanega objekta po enačbi (1):

(1)

$$d = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2},$$

pri čemer velja:

- d – evklidska razdalja med točkama,
- x_1, y_1 in x_2, y_2 – koordinate dveh točk, tj. sredinska točka virtualne črte in koordinate opazovanega objekta.



Slika 2: Območje opazovanja z virtualno črto.

Dodatno smo vpeljali še izračun povprečne intenzitete opazovanega območja, s čimer se je določila velikost opazovanega objekta. Minimalno velikost objekta smo vpeljali kot dodatni pogoj za identifikacijo vozil in je bila določena izkustveno.

Podatki o opazovanih območjih so zapisani v skupni konfiguracijski datoteki, in se ob zagonu programa samodejno naložijo. Konfiguracijski podatki so: oba prej omenjena pogoja (povprečna intenziteta slikovnih elementov znotraj opazovanega območja in evklidska razdalja), stopnja občutljivosti algoritma na maksimalno intenziteto slikovnih elementov, velikost obroba opazovanega objekta, koordinate mejnih točk opazovanega območja, vrednosti povprečne intenzitete slikovnih elementov za posamezno kategorijo vozil.

Klasifikacija vozil se je izvajala na podlagi izračuna povprečne intenzitete slikovnih elementov znotraj opazovanega območja. Vrednosti posamezne kategorije vozil so bile določene izkustveno, glede na velikost območja opazovanja in oddaljenosti kamere. Klasificiranje pa je delovalo na podlagi izkustveno pridobljenih vrednosti povprečne intenzitete slikovnih elementov za posamezno kategorijo vozil.



Slika 3: Zaslovna slika aplikacije za avtomatsko štetje prometa in klasifikacijo.

Zaslovna slika aplikacije (slika 3) prikazuje delovanje avtomatskega števca iz video slikovnega materiala, in sicer, preštevavanje objektov znotraj opazovanega območja glede na kategorijo vozil.

3.REZULTATI IN DISKUSIJA

3.1 Ekperimentalno okolje

Za zajem podatkov smo uporabili različne nizko cenovne kamere oz. fotoaparate kot so: Go pro hero 2, Fujifilm X100, Nikon Coolpix L810, Samsung D70, kamere na mobilnih telefonih in spletne kamere.

Pridobiti je bilo potrebno zadostno število posnetkov, ki so morali biti vsebinsko različni in sicer za:

- hitro cesto (podnevi in ponoči),
- krožno križišče,
- turbo krožno križišče,
- obremenjeno mestno cesto.

Snemanje je potekalo v različnih vremenskih in časovnih obdobjih. Uporabljenih je bilo 6 različnih posnetkov, kar skupno predstavlja za 1 uro in 17 minut video materiala s 350 vozili.

Celotno video gradivo je bilo potrebno najprej analizirati ročno in si zabeležiti vse prehode vozil s pripadajočimi časovnimi značkami.

3.2 Rezultati

Analiza delovanja algoritma je pokazala, da je bilo 6 posnetkov takšnih pri katerih je algoritem deloval nemoteno (zaradi ustrezne postavitve kamere in svetlobe). Slednji so

tako v nadaljevanju bili izbrani kot referenčni posnetki za določevanje robustnosti in natančnosti algoritma.

Tabela 1 prikazuje izračun natančnosti algoritma in število prešteti vozil v posameznem posnetku.

Tabela 1: Določitev natančnosti algoritma

Ime posnetka	"HC nocni"	"Koroški most1"	"Štetje Ptujška - Hitracesta 3"	"Hitra cesta 2"	"Koroški most 2"	"Kneza Koclja"
Vrsta ceste in vreme	HC - noč (jasno)	HC - dan (oblačno)	HC – dan (oblačno)	HC - dan (sončno)	HC - dan (oblačno)	mestna cesta - dan(sončno)
Pravilno prešteta vozila	11	49	56	70	74	79
Vsa vozila na posnetku	11	49	58	74	77	81
Natančnost (%)	100	100	96,55	94,59	96,1	97,53

Iz rezultatov je razvidna 100 % natančnost preštevanja algoritma v nočnem času, med 96 % in 100 % natančno preštevanje v dnevnem času na hitri cesti in v oblačnem vremenu, 94,6 % v sončnem vremenu na enaki vrsti ceste in 97,5 % natančno na mestni cesti, kjer so prostorske praznine med vozili manjše. Povprečna natančnost našega sistema tako znaša $97,46 \pm 2,18$ % pri 6 video posnetkih s 350 vozili.

Pri testiranju sistema smo ugotovili, da je algoritem občutljiv na svetlobo, od kota postavitve snemalne naprave in na različne vremenske razmere, kot so oblačnost, dež, sonce, sneg in dodatno še na premike snemalne naprave. Namreč območje opazovanja je »integrirano« na snemalno napravo, in v primeru premika slednje pride tudi do premika območja opazovanja. To povzroči spremembo vseh parametrov, ki so odvisni od posameznega video posnetka. Hkrati s tem se je pri preskušanju algoritma izkazalo, da je kot snemanja snemalne naprave pokazatelj uporabnosti video posnetka v algoritmu. Rezultati v Tabeli 1 dokazujejo, da algoritem zagotavlja štetje vozil z višjo natančnostjo, kot ročno štetje vozil.

4. ZAKLJUČEK

Svetovno tržišče ponuja veliko enakih ali podobnih rešitev kot je Sistem za avtomatsko štetje prometa s pomočjo video-slikovnega materiala, vendar pri vseh velja, da uporabljajo opremo, ki je praviloma finančno nedostopna manjšim podjetjem. Opisani sistem zato temelji na uporabi nizkocenovne opreme in enostavni arhitekturi algoritma. Razvoj sistema je vseboval področja zajemanja video materiala, ročno in avtomatsko analiziranje video materiala ter programiranje algoritma. Enostavnost arhitekture

algoritma se izkazuje z uporabo metode odštevanja ozadij, katera omogoča hitro procesiranje vhodnih podatkov. Hkrati z uporabo osnovnega matematičnega pristopa in nekaterih funkcij, ki jih omogoča uporabljena knjižnica, pa tvori, sistem preštevanja vozil na prometni infrastrukturi z visoko natančnostjo (97,5 %). S posameznimi nadgradnjami bo sistem v prihodnje skupaj z višjo robustnostjo, omogočal merjenje hitrosti na hitrih cestah in avtocestah.

LITERATURA

1. Kumar Deb, Swapan in Kumar Nathr, Rajiv (2012), Vehicle Detection Based on Video for Traffic Surveillance on road, *Int. J Comp Sci. Emerging Tech.*, vol. 3, str. 121 – 137.
2. Jazayeri, Amirali, in drugi (2011), Vehicle Detection and Tracking in Car Video Based on Motion Model, *IEEE Transactions on Intelligent Transportation Systems*, vol. 12, str. 583 – 595.
3. Adinarayana.G, in drugi (2011), Video Surveillance System for Speed Violated Vehicle Detection, *International Journal of Electronics & Communication Technology (IJECT)*, vol. 2, str. 50 – 54.
4. Zhang, Guohui, Avery, Ryan P. in Wang, Yin Hai (2006), A Video-based Vehicle Detection and Classification System for Real-time Traffic Data Collection using Uncalibrated Video Cameras, *Transportation Research Record: Journal of the Transportation Research Board*, Transportation Research Board of the National Academies, str. 138 - 147.
5. Yue, Yonghong (2009), A Traffic-Flow Parameters Evaluation Approach Based on Urban Road Video, *International Journal of Intelligent Engineering and Systems*, vol. 2, str. 33 – 39.
6. N. Chintalacheruvu, V. Muthukumar (2012), Video Based Vehicle Detection and its Application in Intelligent Transportation Systems, *Journal of Transportation Technologies*, vol. 2, str. 305-314.
7. NJ Uke, RC Thool (2013), Moving Vehicle Detection for Measuring Traffic Count Using OpenCV, *Journal of Automation and Control Engineering*, Engineering & Technology Digital Library, Singapor, vol. 1, str. 349-352.
8. Mishra, Pradeep Kumar, in drugi (2013), Video-based Vehicle Detection and Classification in Heterogeneous Traffic Conditions using a Novel Kernel Classifier, *IETE Journal of Research*, vol. 59, str. 541 – 550.

9. Lien, Cheng-Chang in Tsai, Ming-Hsiu (2011), Real-Time Traffic Flow Analysis without Background Modeling, *Journal of Information Technology and Applications*, vol. 5, str. 1-14.
10. Coifman, Benjamin, in drugi (1998). A real-time computer vision system for vehicle tracking and traffic surveillance, *Pergamon*, Transportation Research Part C 6, str. 271 - 288.
11. Xia, Jie, in drugi (2009), Moving Vehicle Tracking Based on Double Difference and CAMShift, *Proceedings of the 2009 International Symposium on Information Processing (ISIP'09)*, Academy Publisher, str. 29 – 32.
12. Achler, Ofer in M.Trivedi, Mohan (2004), Camera Based Vehicle Detection, Tracking, and Wheel Baseline Estimation Approach, *Intelligent Transportation Systems, 2004. Proceedings. The 7th International IEEE Conference*, IEEE, str. 743 – 748.
13. Chaudhuri, Subhashis, V. Mathew, Tom in R.Patil, Gopal (2012), Real Time Traffic Counting System using Video Image Processing, predstavitel na nacionalni konferenci urbane mobilnosti, Mumbai.
14. Tarko, A. P., in R. S. Lyles (2002), Development of a Portable Video Detection System for Counting Turning Vehicles at Intersections, *Publication FHWA/IN/JTRP-2001/18, Joint Transportation Research Program*, Indiana Department of Transportation and Purdue University.
15. Lei, M., in drugi (2008). A video-based real-time vehicle counting system using adaptive background, *Signal Image Technology and Internet Based Systems, 2008. SITIS '08*, IEE, str. 523 – 528.
16. Ping-Han, Lee, in drugi (2009), Real-time pedestrian and vehicle detection in video using 3D cues, *Multimedia and Expo, 2009. ICME 2009*, IEE, str. 614 – 617.
17. N. Agarwal, N. Andrisevic, K. Vuppla, M. S. Stachowicz (2014), Vehicle detecting and tracking in video for incident detection, Minnesota Department of Transportation.
18. Li, Qinjun, in drugi (2011), Video Vehicle Detection and Tracking System, *Advances in Computer Science and Education Applications*, Springer Berlin Heidelberg, str. 24 – 31.
19. Bonneson, James A., Abbas, Montasir (2002), Intersection video detection manual, Texas Transportation Institute, Texas A&M University System.

20. <http://miovision.com/>
Miovision.
21. <http://www.countingcars.com/default.asp>
Countingcars.
22. <http://www.logiroad.com/>
LOGIROAD
23. <http://www.sormea.fr/?hl=en>
SORMEA.
24. http://docs.opencv.org/modules/video/doc/motion_analysis_and_object_tracking.html?highlight=backgroundsubtractorMOG#backgroundsubtractormog
Motion Analysis and Object Tracking.

OPTIČNA RAZPOZNAVA ZNAKOV V SLIKAH NARAVNIH SCEN

Rok Petek, Luka Šajn, Peter Peer, Andrej Ikica

Fakulteta za računalništvo in informatiko

URL: <http://www.fri.uni-lj.si>

POVZETEK: *Kot podlago za razpoznavo znakov smo izbrali metodo smernih segmentnih značilnk z nelinearno mrežo, ker je bila razvita za mobilne platforme in tako izpolnjuje merila hitrost. Metodo smo združili s slikovnim predprocesiranjem, segmentacijo in klasifikacijo. Tri različne metode so bile uporabljene na treh različnih slikovnih bazah ICDAR, CVL OCR DB ter hibridno zbirko, ki smo jo generirali iz dveh prej omenjenih podatkovnih baz.*

1. UVOD

Optična razpoznava znakov v slikah naravnih scen je izredno problematična, saj se lahko tekst pojavi v različnih velikostih, barvah, pisavah in orientacijah. Prav tako so slike naravnih scen slabše kvalitete in vsebujejo kompleksna ozadja, kar oteži proces razpoznave. Sistemi optične razpoznave znakov v slikah naravnih scen so sestavljeni iz štirih korakov in sicer predprocesiranje, segmentacija, pridobivanje značilnk in klasifikacija.

Za potrebe evalvacije metod razpoznave znakov smo uporabili zbirko slik teksta v naravnih scenah ICDAR [1], CVL OCR DB [2] in hibridno zbirko, ki smo jo generirali iz obeh zbirk. Na področju OCR-ja je v okviru konference ICDAR organizirano tekmovanje iz razpoznave in detekcije teksta v slikah naravnih scen. Za potrebe tekmovanja je bila generirana zbirka slik teksta, ki predstavlja standard za evalvacijo metod razpoznave in detekcije teksta v slikah naravnih scen. Zbirka vsebuje slike teksta v različnih resolucijah, zajete z različno opremo. Zbirka slik teksta CVL OCR DB (angl. Computer Vision Laboratory OCR DataBase) je javna zbirka anotiranih slik teksta v naravnih scenah. Zaradi potreb po boljši učni množici, smo ustvarili hibridno zbirko slik teksta med zbirkama ICDAR in CVL OCR DB. Pri tem postopku smo iz obeh zbirk izbrali le slike najboljših kvalitete. Tako smo dobili razmeroma optimalen reprezentativen učni model posameznega znaka oziroma razreda.

2. METODE

Pri izboru metod smo se osredotočili na metode, ki so primerne za mobilne platforme. Implementirali smo metodo, ki so jo predlagali Jonghyun in sodelavci [3]. Metoda zajema tri glavne korake: binarizacijo na podlagi FCM (fuzzy c-means), pridobitev značilnk smernih segmentov nelinearne mreže in klasifikacijo na podlagi MDC.

Predlagano metodo smo tudi razširili, kjer smo za binarizacijo uporabili tudi Otsu-jevo upragovanje, ter SIFT in Gaborjev filter za pridobivanje značilk, pri klasifikaciji smo pridobljene značilke klasificirali z omenjenim MDC klasifikatorjem ter SVM, KNN in ANN klasifikatorji.

2.1 Predprocesiranje

V slikah naravnih scen se navadno pojavljajo šumi, kot so: neenakomerno porazdeljena svetloba, zamegljenost slike, slaba osvetljenost, zamaknjenost, itd. Vsi naštetih faktorji onemogočajo kakovostno pridobivanje značilk. V prvem koraku predprocesiranja smo sliko izostrili, nato smo odpravili šum z Wiener filtrom, končni korak predprocesiranja pa je bilo glajenje slike, prav tako je bil postopek glajenja izveden s prilagodljivim dvodimenzionalnim Wiener filtrom.

2.2 Segmentacija

Proces segmentacije nam je omogočil ločitev slikovnih elementov na tiste, ki pripadajo znaku in na tiste, ki pripadajo ozadju. Problem binarizacije je določanje praga, saj lahko z različnimi pragovi izpostavimo različne objekte na sliki. Najbolj primerna metoda za iskanje praga je prilagodljiva binarizacija, tak primer binarizacije je dvorazredni FCM. Fuzzy C-means [3] je tehnika podatkovnega grozdenja, kjer je vsaka točka pripisana nekemu skupku podatkov. FCM dobro obravnava spremembe v svetlosti in slike s slabo osvetlitvijo.

Drug primer binarizacije je globalna upravalna tehnika, ki predvideva, da slika vsebuje dva razreda slikovnih elementov oz. ima bimodalni histogram (ospredje in ozadje), tak primer binarizacije je Otsu upragovanje. Je zelo hiter način upragovanja, saj operira samo s sivinskimi histogrami.

2.3 Pridobivanje značilk

2.3.1 Pridobivanje značilk

Značilke smernih segmentov nelinearne mreže [3] obravnavajo celoten znak kot vzorec in ga poskušajo razlikovati z ostalimi, z uporabo podatkov o celostni obliki znaka na podlagi nelinearne mreže.

Pri pridobitvi značilk smernih segmentov nelinearne mreže za vsako binarizirano sliko pripravimo $N \times M$ nelinearno mrežo, ki je invariantna na skaliranje. Mreža je razdeljena na horizontalno (H), vertikalno (V), levo-diagonalno (L) in desno-diagonalno (R) smer. Vzorec znaka, naj bi bil višine H in širine W . Funkcija $f(i, j)$ predstavlja posamezen slikovni element (i, j) v i -ti vrstici in j -tem stolpcu, tu velja sledeč pogoj:

$$1 \leq i \leq H, \text{ in } 1 \leq j \leq W.$$

Pri konstrukciji $N \times M$ nelinearne mreže upoštevamo pogoje:

$$N \leq H, M \leq W,$$

Nelinearno mrežo izračunamo z naslednjimi koraki:

1. Najprej so izračunani horizontalni in vertikalni projekcijski profili, $h(i)$ in $v(j)$ z naslednjima enačbama:

$$h(i) = \sum_{k=1}^W f(i, k)$$

kjer velja:

$$1 \leq i \leq H$$

in

$$v(i) = \sum_{k=1}^H f(k, j)$$

kjer velja:

$$1 \leq j \leq W$$

2. Vertikalni in horizontalni profili izračunajo vsoto črnih slikovnih elementov posamezne vrstice. Vrstice vhodne slike so nato indeksirane od 1 do H (višina) in particionirane v N zaporedne trakove. Trakove delijo mejni indeksi $[1, e_1], [e_1 + 1, e_2], \dots, [e_{N-1} + 1, H]$, kjer so v posameznem traku robni indeksi e_1, e_2, \dots, e_{N-1} določeni tako, da so gostote črnih slikovnih elementov enake za vse trakove. Določanje indeksov je definirano s spodnjo enačbo:

$$D(k) = \sum_{l=s_k}^{e_k} h(i)$$

kjer velja:

$$s_1 = 1, s_{k+1} = e_k + 1, e_N = H$$

in

$$1 \leq k \leq N.$$

Tako kot vrstice, so tudi stolpci vhodne slike indeksirani od 1 do W (širina) in razdeljeni v M število trakov z vertikalno projekcijo $v(j)$. Z izračunanimi N horizontalnimi trakovi in M vertikalnimi trakovi je lahko formirana $N \times M$ mreža (slika 1, primer a). Nelinearna mreža je primerna za pridobitev značilik v slikah znakov z različnimi pisavami in znakovnimi dekoracijami, ki so pogoste v naravnih scenah.

Po generiranju nelinearne mreže so 4-smerni segmenti izračunani za vsak črn slikovni element v sliki, upoštevajoč da so strukturne karakteristike slikovnega elementa predstavljene s horizontalno, vertikalno ter dvema glavnima diagonalnima linijama. Za vsak črn slikovni element (x, y) vhodne slike, sta izračunani dolžini $RLH_{x,y}$ in $RLV_{x,y}$ z merjenjem njune horizontalne vertikalne poti. Meritev dolžine se ustavi ob dotiku prvega belega slikovnega elementa. Z uporabo teh dveh vrednosti, lahko izračunamo vrednosti horizontalnega in vertikalnega prispevka $DCH_{x,y}$ in $DCV_{x,y}$ s sledečima formulama:


$$DCH_{x,y} = RLH_{x,y} / (RLH_{x,y} + RLV_{x,y})$$

in

$$DCV_{x,y} = RLV_{x,y} / (RLH_{x,y} + RLV_{x,y}).$$

Vrednosti smernih prispevkov $DCH_{x,y}$ in $DCV_{x,y}$ so povprečene s številom vseh črnih elementov v posamezni celici $N \times M$ mreže. S tem povprečenjem dobimo prvo

polovico vseh značilk, torej $2 \times N \times M$ vrednosti. Druga polovica $2 \times N \times M$ značilk za levo-diagonalno in desno diagonalno smer, je izračunana enako kot prva polovica, le da je slika znaka rotirana za 45° (slika 1, primer b).



Slika 1. (a) Nelinearna mreža velikosti 9×7 , (b) 4-smerna značilka

2.3.2 SIFT

Algoritem SIFT [5] pridobi interesne točke slike, ki opišejo objekt v sliki. Opis objekta je lahko uporabljen pri identifikaciji enakega objekta na drugi sliki z drugačno vsebino. V naši implementaciji SIFT-a smo uporabili »gosti« SIFT [6], ki je bolj primeren za detekcijo kategorij objekta, kot specifičnih objektov. Ta metoda uporablja način pridobivanja značilk na nasičeni uniformni mreži.

2.3.3 Gaborjev filter

Gaborjev filter lahko predstavlja signale v enodimenzionalnem in dvodimenzionalnem prostoru. V prostorski domeni je apliciran dvodimenzionalen Gaborjev filter. Gaborjev filter se neposredno nanaša na Gaborjeve valčke, saj so lahko zasnovani za različne velikosti in rotacije. Valček lahko označi prostorsko strukturo frekvenca na sliki in obenem ohrani informacijo prostorskih razmerij, tako je primeren za pridobitev orientacijsko odvisne frekvenčne vsebine vzorcev [7].

2.4 Klasifikacija

2.4.1 MDC

Klasifikator MDC [3] zagotavlja klasifikacijo pri minimalnem številu zahtevanih parametrov in računske zahtevnosti, vendar zaradi nizke računske zahtevnosti klasifikacijska natančnost ni optimalna. Algoritem MDC poišče srednjo vrednost oz. povprečje vzorcev posameznih razredov in izmeri razdaljo med povprečji vzorcev razreda in testnega oz. neznanega vzorca. Testni vzorec torej dodeli tistemu razredu, katerega povprečna vrednost je najbližja neznanemu oz. testnemu vzorcu [8]. V predlagani metodi klasifikacije MDC [3] je uporabljena Evklidska razdalja, vendar smo dosegali boljše rezultate z uporabo Manhattanske razdalje oziroma razdalje mestnega bloka (angl. cityblock distance).

2.4.2 K-NN

Klasifikator K-NN [4,9] dodeli oznako, vsakemu testnemu vzorcu, dodeljen znak je najpogostejši med k-učnimi vzorci, kar pomeni, da je posamezen vektor klasificiran glede na večinsko glasovanje njegovih sosedov. Pri klasifikaciji značilik smo dosegali boljšo klasifikacijsko natančnost z uporabo Manhattanske razdalje namesto Evklidske.

Z izbiro optimalnega parametra k lahko povečamo klasifikacijsko natančnost. V našem primeru več razredne klasifikacije smo uporabili vrednost $k=1$ [4].

2.4.3 SVM

Metoda podpornih vektorjev [4] (SVM) je tehnika klasifikacije z uporabo hiperploskve. Njegova naloga je poiskati hiperravnino v n-dimenzionalnem prostoru, ki ločuje vzorce različnih razredov. Hiperravnine ni mogoče zviti, zato ko podatki niso linearno ločljivi, uporabimo jedrni trik (angl. kernel trick), ki povečuje mejo med hiperravninami. V našem primeru se je RBF jedro izkazalo za najustrežnejše [4]. Pri izbiri večrazredne SVM klasifikacije smo izbrali metodo »eden proti vsem«.

2.4.4 ANN

Umetna nevronska mreža [4] je vezje večih enostavnih procesnih enot t.i. nevronov. Način povezovanja nevronov razlikuje med seboj omrežne modele v predkrmljene mreže, ponavljajoča se omrežja ali samoorganizirana omrežja. Pri klasifikaciji ANN smo aplicirali dvonivojsko (skriti in izhodni nivo) predkrmljeno nevronske mrežo (njen graf je usmerjen aciklično). Na splošno potrebujejo težji problemi večje število nevronov.

3. REZULTATI

Proces predprocesiranja oz. izboljšanja kakovosti je malenkost popačil slike dobre kvalitete, tako nam je predprocesiranje povprečno poslabšalo klasifikacijsko natančnost za 5%, kar je posledica tega, da predprocesiranje ni optimizirano za slike dobre razpoznavnosti, temveč je bolj primerno za slike slabše kakovosti.

Najboljše rezultate pridobivanja značilik je dosegala metoda smernih segmentov nelinearne mreže. Najustrežnejša velikost nelinearne mreže je bila 9×5 , iz česar lahko razberemo, da so latinski znaki bolj pokončni kot korejski znaki, saj je bila v predlagani metodi [3] priporočena velikost nelinearne mreže 9×7 .



Slika 2. Primerjava korejskega in latinskega znaka.

Tabela 1. Tabela rezultatov zbirke slik teksta CVL OCR DB, pri kateri je bilo uporabljeno navzrkižno preverjanje (k-fold, za k=10)

CVL OCR DB				
	MDC	K-NN	SVM	ANN
DSF-mesh 9×5	79.24%	88.60%	88.45%	82.33%
	67.85%	82.73%	79.22%	74.71%
SIFT	57.24%	79.45%	78.88%	64.79%
	50.37%	72.61%	70.29%	57.17%
Gabor	41.88%	73.41%	71.93%	58.99%
	35.29%	65.41%	64.76%	51.52%

Kot je razvidno iz tabele 1, nam je prinesla največjo klasifikacijsko natančnost kombinacija metod, Otsu upragovanje, značilke smernih segmentov nelinearne mreže velikosti 9×5 ter K-NN klasifikacija in sicer 88.60%, pri invariančnosti velikosti znaka (52 razredov oz. 26 pri invariantnosti na velikost znaka, brez numeričnih znakov). Druga vrstica, prikazuje rezultat natančnosti pri neinvariantnosti velikosti znaka, kjer je le ta manjši. Pri klasifikaciji je pomembno tudi dejstvo, da je K-NN klasifikator najhitrejši med vsemi izbranimi. V povprečju se je izkazalo, da se je z uporabo invariantnosti glede na velikost znakov klasifikacijska natančnost povečala za 10-15%.

Klasifikator MDC se je povprečno izkazal najslabše, ANN pa je z vidika klasifikacijske natančnosti bližje SVM metodi.

Znaki kot so »h« in »k« ter »c« in »o« so bili največkrat napačno klasificirani, saj so tudi njihove strukturne karakteristike zelo podobne.

Metoda Coates et al., 2010 [10] uporablja zbirko ICDAR, kjer dosega 81.4% natančnost in 85.5% natančnost pri invariantnosti znaka (62 razredov, vsebuje tudi numerične znake). Ta metoda je doslej na splošno dosegala najboljše rezultate tudi v primerjavi z drugimi metodami na zbirki ICDAR.

4. ZAKLJUČEK

Potencialne izboljšave bi bile primerne na nivoju segmentacije oz. binarizacije, kjer bi lahko z naprednejšimi metodami predprocesiranja dosegali boljše rezultate. Slike bi lahko tudi afino normalizirali za bolj razpoznavnost.

Na klasifikacijsko natančnost pa je tudi vplivala slaba testna množica, katero bi lahko izboljšali oz. generirali sintetično, tako da bi ustvarili skupek znakov istega razreda različnih pisav, naklona, zameglitve, šuma ter nagiba. Pri tem bi umetno reproducirali značilnosti slik naravnih scen in obenem ohranili raznolikost in razpoznavnost med posameznimi vzorci.

LITERATURA

1. Simon M. Lucas, Alex Panaretos, Luis Sosa, Anthony Tang, Shirley Wong, Robert Young, Kazuki Ashida, Hiroki Nagai, Masayuki Okamoto, Hiroaki Yamamoto, Hidetoshi Miyao, Yunmin Zu, Wuwen Ou, Christian Wolf, Jean-Michel Jolion, Leon

- Todoran, Marcel Worring, Xiaofan Lin. ICDAR 2003 Robust Reading Competitions: Entries, Results and Future Directions. *International Journal of Document Analysis and Recognition*, 7(2-3):str. 105-122, 2005.
2. Andrej Iking, Peter Peer. Cvl ocr db, an annotated image database of text in natural scenes, and its usability. *Informacije MIDE M*, 41(2):str. 150-154, 2011.
 3. Jonghyun Park, Guesang Lee, Euichul Kim, Junsik Lim, Soohyung Kim, Hyungjeong Yang, Myunghun Lee, Seongtaek Hwang. Automatic detection and recognition of korean text in outdoor signboard images. *Pattern Recognition Letters*, 12, (31): str. 1728-1739, 2010.
 4. Mohammed Cheriet, Nawwaf Kharm a, Cheng-lin Liu, Ching Suen. *Character Recognition Systems: A Guide for Students and Practitioners*. Wiley-Interscience, 2007.
 5. Kamarul Hawari Ghazali, Mohd. Marzuki Mustafa, Aini Hussain. Feature extraction technique using SIFT keypoint descriptors. In *Proceedings of the International Conference on Electrical Engineering and Informatics, Electronic and Systems Engineering Faculty of Engineering, Universiti Kebangsaan Malaysia, Malaysia, 2007*.
 6. <http://www.vlfeat.org>
VLFeat knjižnjica (2012)
 7. Jing Zhang, Xilin Chen, Andreas Hanneman, Jie Yang, Alex Waibel. A robust approach for recognition of text embedded in natural scenes. In *Int. Conf. on Pattern Recognition*, str. 204-207, 2002.
 8. Alok Sharma, Kuldip K. Paliwal, Godfrey C. Onwubolu. Class-dependent PCA, MDC and LDA: A combined classifier for pattern classification. *Pattern Recognition Letters*, zbornik 7, (39): str. 1215-1229, 2006.
 9. Gurpreet Singh Lehal, Chandan Singh. Handwritten Gurmukhi character recognition using statistical and background directional distribution features. *International Journal on Computer Science and Engineering*, str. 2{12, 1999.
 10. Adam Coates, Blake Carpenter, Carl Case, Sanjeev Satheesh, Bipin Suresh, Tao Wang, David J. Wu, Andrew Y. Ng. Text detection and character recognition in scene images with unsupervised feature learning. In *International Conference on Document Analysis and Recognition*, str. 440-445, 2011.

NADGRADNJA METODE BARVNE VZTRAJNOSTI Z VZORCI S SEGMENTACIJO NA OSNOVI DRSEČEGA OKNA

Martin Šavc, Božidar Potočnik

Laboratorij za sistemsko programsko opremo
Fakulteta za elektrotehniko, računalništvo in informatiko
E-pošta: martin.savc@um.si

POVZETEK: V tem članku povzemamo metodo barvne vztrajnosti s primerki (angl. *Exemplar based colour constancy*). Metoda primerja vzorce slike na podlagi teksturnih značilk in oceni osvetlitev na podlagi prilagojenega modela odbojnosti. V eksperimentu primerjamo uporabo kombinacije značilk MR8 in barvnih histogramov, predlagane v izvornem delu, z lastnimi značilkami. Z manjšo spremembo v implementaciji dosežemo bistveno boljše rezultate v primerjavi z rezultati izvorne metode. Povprečna kotna napaka ocenjene osvetlitve na testni bazi slik se zmanjša za 0,5 stopinj.


1. UVOD

Cilj metod barvne vztrajnosti je ocena barve osvetlitve scene iz podatkov zajete slike. Eden izmed možnih pristopov k oceni osvetlitve je izkoriščanje regularnosti v slikah (npr. pomen povprečne barve, maksimalne barvne vrednosti, konveksna lupina barv).

Opis takšnih regularnosti bomo imenovali model odbojnosti. Z njim želimo posredno ali neposredno opisati pričakovan izgled barv površin v sliki. Primeri modelov odbojnosti so povprečna barva v sliki (npr. v metodi *Gray World Assumption* [1]), maksimalna barvna vrednost v sliki (npr. v metodi *MaxRGB* [1]), konveksna lupina možnih barv slike (npr. v metodi *Gamut mapping* [1]).

Kompleksnejši model odbojnosti naučimo na učni množici slik. Običajno je model posplošen in naučen na vseh slikah v množici. Kadar je scena slike preveč monotona, njena vsebina ne ustreza posplošenemu modelu in ocena osvetlitve je seveda napačna.

Zanimiva rešitev problema, kadar vsebina slike ne ustreza posplošenemu modelu, je predstavljena v delu avtorjev H. R. V. Joze in M. S. Drew [2]. Gre za metodo barvne vztrajnosti s primerki (angl. *Exemplar based colour constancy*). Ta metoda primerja vzorce opazovane slike z vzorci učnih slik in barvni model prilagodi posameznemu vzorcu. Uporabljen model odbojnosti tako ni več posplošen, ampak specifičen za vsebino vzorca.



Slika 1: Prikaz delovanja metode barvne vztrajnosti s primerki. Vzorec iz slike x_i najprej opišemo z vektorjem t_i . Z algoritmom k-najbližjih sosedov (KNN) poiščemo l podobnih vektorjev t_j, \dots, t_{j+l} in njihovih vzorcev x_j, \dots, x_{j+l} iz učnih slik. Za vsakega izmed teh vzorcev je poznana tudi osvetlitev e_j . Za vzorec slike x_i in podoben vzorec x_j se z metodo MaxRGB določita transformaciji M_i in M_j . Le-ti se uporabita skupaj s poznano osvetlitvijo e_j za oceno osvetlitve e_{ij} .

V nadaljevanju tega prispevka naredimo povzetek metode barvne vztrajnosti s primerki in predstavimo podrobnosti naše implementacije. V eksperimentalnem delu preizkusimo nekaj variacij, ki v izvornem delu niso bile preizkušene. V zaključku povzamemo in interpretiramo rezultate.

2. PREGLED METODE

Metodo v grobem razdelimo na tri dele: 1) segmentacijo slike, 2) primerjanje segmentiranih vzorcev in iskanje podobnih učnih vzorcev, 3) gradnjo modela odbojnosti in oceno osvetlitve. Diagram metode je prikazan v sliki 1. Posamezni koraki so podrobneje opisani v nadaljevanju.

2.1 Segmentiranje slike na vzorce

Sliko najprej razdelimo na vzorce x_i . V izvornem članku je za segmentiranje slike bil uporabljen algoritem *Mean Shift* [3]. Model segmentacijskega algoritma uvede svoje omejitve na vzorce. Ti lahko kasneje seveda vplivajo na model odbojnosti.

Nekatere površine se pogosto pojavljajo ena poleg druge (npr. nebo in drevesa, ali nebo in strehe). V takšnih primerih je uporabno imeti vzorce, ki zajemajo več različnih površin. Ker je opis v teh primerih pestrejši, lahko to izboljša iskanje podobnih vzorcev.

V našem delu za segmentacijo slike namesto algoritma *Mean Shift* uporabimo drseče okno. Okno pomikamo preko slike s konstantnim korakom. Na vsakem mestu del slike, ki se nahaja pod oknom izrežemo kot vzorec x_i . Tako lahko vzorci vsebujejo tudi

elemente več sosednjih površin. To lahko pomaga tako pri primerjavi vzorcev kot pri oceni osvetlitve. Vendar pa takšen pristop vnaša tudi redundanco – velike uniformne površine so namreč po nepotrebnem razdeljene v manjše vzorce. Če bi bila ocena osvetlitve napačna za en takšen vzorec, bi najverjetneje bila napačna za vse.

2.2 Primerjanje vzorcev

Za lažje primerjanje je vzorec slike \mathbf{x}_i opisan z vektorjem značilik \mathbf{t}_i . Kot paralela modelu odbojnosti lahko opis teh značilik imenujemo teksturni model.

V izvornem članku je uporabljen slovar *textonov* odzivov banke filtrov MR8 (*angl. Maximum Response 8*) [4] v kombinaciji z barvnimi histogrami. V banki filtrov MR8 je uporabljenih 38 filtrov: 6 orientacij, 3 velikosti za 2 usmerjena filtra, ter dva neusmerjena filtra, in sicer Gaussov nizko prepustni filter ter filter Laplace nad Gausom (*angl. Laplacian of Gaussian*). Pri filtriranju slike se v vsaki točki izračuna in ohrani le maksimalen odziv usmerjenih filtrov preko različnih orientacij. Končni rezultat banke filtrov je 8 odzivov v vsaki točki: odzivi za dva usmerjena filtra pri treh velikostih ter odziva za dva neorientirana filtra.

Vzorec \mathbf{x}_i najprej filtriramo z banko filtrov MR8. Robne točke – točke katerih izračun odziva zahteva uporabo točk izven vzorca – so pri tem zavržene. Ostale točke nato primerjamo s slovarjem *textonov*. *Texton* je tipičen primer odziva banke filtrov. Vsaki točki je prirejen najbližji *texton* iz slovarja glede na evklidsko razdaljo. Iz prirejenih *textonov* nato sestavimo histogram, ki služi kot vektor značilik *textonov* $\mathbf{t}_{\text{ex},i}$. Slovar *textonov* tvorimo že v učni fazi s pomočjo algoritma rojenja k-povprečij.

Poleg histograma *textonov* so za opis posameznega vzorca dodani še histogrami barvnih kanalov $\mathbf{t}_{\text{col},i}$. Vzorec najprej barvno popravimo z algoritmom MaxRGB. Nato vsak kanal pretvorimo v histogram 16 elementov. Končni vektor značilik \mathbf{t}_i , ki ga uporabljamo v tem prispevku je, bodisi histogram *textonov*, bodisi histogrami barv ali normirana in združena histograma *textonov* in barv.

Primerjavo vektorjev \mathbf{t}_i izvedemo z algoritmom k-najbližjih sosedov. Za vsak \mathbf{t}_i poiščemo l najbolj podobnih vektorjev \mathbf{t}_j in njihovih izvornih vzorcev \mathbf{x}_j iz učnih slik.

2.3 Model odbojnosti

Za oceno osvetlitve potrebujemo model odbojnosti. Izvorni članek predlaga uporabo preprostega modela osnovanega na algoritmu MaxRGB [1].

Algoritem MaxRGB oceni osvetlitev kot maksimalno vrednost slike v vsakem barvnem kanalu. Ocena osvetlitve v prilagojenem algoritmu za vzorec \mathbf{x}_i na podlagi podobnega vzorca \mathbf{x}_j je \mathbf{e}_{ij} in se izračunana kot

$$\mathbf{e}_{ij} = \mathbf{M}_i^{-1} \mathbf{M}_{ij} \mathbf{M}_j \mathbf{e}_j, \quad (1)$$

kjer je \mathbf{e}_j vnaprej poznana osvetlitev vzorca \mathbf{x}_j , \mathbf{M}_j je transformacija MaxRGB za vzorec \mathbf{x}_j , \mathbf{M}_i je transformacija MaxRGB za vzorec \mathbf{x}_i . \mathbf{M}_{ij} pa je transformacija med maksimalno barvo obeh vzorcev s popravljeno osvetlitvijo. Ker sta si vzorca podobna, predpostavimo, da je \mathbf{M}_{ij} transformacija enaka identiteti.

Za oceno osvetlitve v sliki z uniformno osvetlitvijo je potrebno ocene osvetlitve \mathbf{e}_{ij} združiti v eno oceno. To storimo z uporabo mediane za vsak barvni kanal posebej.


3. EKSPERIMENT

V tem prispevku primerjamo rezultate algoritma barvne vztrajnosti z vzorci pri čemer uporabljamo kot značilke a) bodisi samo vektor značilk *textonov*, b) bodisi samo barvne histograme ali pa c) uporabljamo kombiniran vektor značilk (glej poglavje 2). Dobljene rezultate smo primerjali z rezultati metod *Spatio Spectral Statistics* [5] in izvorno metodo barvne vztrajnosti s primerki [2]. Za lažjo primerjavo smo uporabili rezultate objavljene na spletni strani [6].

Ekspiriment smo izvedli na zbirki slik GehlerShi [7][8]. Zbirka vsebuje 568 slik. Za oceno osvetlitve vsaka slika vsebuje barvno tablico Gretag Macbeth. Slike so razdeljene v tri vnaprej določene validacijske sete. Vsak set vsebuje učno in testno množico slik. Učna množica vsebuje dve tretjini vseh slik, testna množica vsebuje preostalo tretjino slik. Vsaka slika se dvakrat pojavi v učni množici in enkrat v testni.

Učne slike smo najprej obdelali z banko filtrov MR8 in izbrali učne vzorce za slovar *textonov*. Vzorce smo izbrali v mreži z razdaljo 16 točk med vzorci. Z algoritmom k-povprečij smo poiskali 1000 povprečij, tj. *textonov* v slovarju.

Za segmentacijo slike smo uporabili kvadratno okno velikosti 256 točk, ki smo ga pomikali preko slike s korakom 128 točk. Za vsak vzorec smo generirali histogram *textonov*, histogram barv in transformacijo MaxRGB vzorca.



Slika 2: Rezultati validacije na učnih setu. Grafi prikazujejo odvisnost povprečne kotne napake od uporabljenega števila sosedov l v metodi kNN za oceno osvetlitve. Posamezna krivulja prikazuje rezultat za izbrano značilko.

Za oceno napake ocene osvetlitve smo uporabili kotno napako [1], tj. kot med oceno osvetlitve e' in izmerjeno osvetlitvijo e v stopinjah (tj. znan podatek iz testne množice). Napako smo povzeli s povprečjem, mediano in trimean statistiko za množico slik. Gre za ustaljeno prakso poročanja rezultatov kot je uporabljena tudi v drugi literaturi [1]. Primerjavo rezultatov algoritmov smo izvedli tudi s testom Wilcoxon [1] (*angl. Wilcoxon signed ranked test*).

Učno množico smo dodatno razdelili na 4 validacijske sete. Z njimi smo preizkusili različna števila najdenih sosedov l v metodi kNN (glej poglavje 2). Za testno množico smo uporabili število sosedov, ki je doseglo najmanjšo povprečno kotno napako.

4. REZULTATI

V nadaljevanju podajamo rezultate eksperimentov. Najprej si pogledjmo rezultate validacije uporabljenega števila sosedov v metodi kNN na učnih setih. Na voljo smo imeli tri učne sete. Rezultati validacije so prikazani na sliki 2. Vpliv števila sosedov je za različne uporabljene značilke različen. Najbolj očiten vpliv ima na samostojne MR8 *textone*. Nekaj vpliva ima tudi na barvni histogram, medtem ko je vpliv pri združenih značilkah skoraj neopazen. Razlike med značilkami so zelo majhne. Skala na vertikalni osi je namreč prilagojena prikazu. Najboljše rezultate smo dosegli z uporabo kombiniranih značilk. Malce slabše so se obnesli samo barvni histogrami. Najslabše rezultate pa smo dosegli z uporabo izključno MR8 *textonov*. Nastavitve parametrov metode so podane v poglavju 3.

Tabela 1: Povzetek rezultatov primerjanih metod. Poleg imen metode je zapisana še uporabljena metoda segmentacije in uporabljene značilke. Najboljši rezultati so poudarjeni s krepko pisavo.

Algoritem	Povprečna napaka	Mediana napake	Trimean napake
Spatio Spectral Statistics, Max Likelihood	3,6	3,0	3,0
ExBCC, Mean Shift, MR8 + ColourHist	2,9	2,3	2,4
ExBCC, potujoče okno, MR8	2,6	1,8	2,0
ExBCC, potujoče okno, ColourHist	2,5	1,8	1,9
ExBCC, potujoče okno, MR8 + ColourHist	2,4	1,7	1,9

Končne rezultate smo primerjali še z rezultati originalno objavljene metode barvne vztrajnosti s primerki (uporabljena kratica ExBCC) ter metode *Spatio Spectral Statistics*. Povzeti rezultati so prikazani v tabeli 1. V drugi vrstici so navedeni rezultati izvorne metode s segmentacijo slik z metodo *Mean Shift* in uporabo kombiniranih značilk. V

zadnjih treh vrsticah so navedeni rezultati naše implementacije. Že iz teh rezultatov bi lahko sklepali, da naša implementacija doseže bistveno boljše rezultate. Uporaba kombiniranih značilk je sicer najboljša, vendar pa ni veliko boljša od samostojnih *textonov* MR8 ali barvnih histogramov.

Rezultate različnih metod smo med sabo primerjali tudi s statističnim testom Wilcoxon. Rezultati tega testa so prikazani v tabeli 2. Naše implementacije so boljše od obeh primerjanih metod. Test pokaže tudi, da je uporaba kombiniranih značilk boljša od uporabe samo *textonov* MR8. V drugih primerih pa ni signifikantne razlike v rezultatih.

Tabela 2: Rezultati Wilcoxon testa. Test nad pari metod je bil izveden z nivojem signifikantnosti 0,01. V vrstici so zapisana imena metod z zaporednimi indikatorji. Nad stolpci so zapisana samo indikatorji. Puščica levo nakazuje, da je metoda v vrstici bila signifikantno boljša, puščica gor pa, da je metoda v stolpcu bila signifikantno boljša.

Wilcoxon test, $p < 0,01$	1.	2.	3.	4.	5.
Spatio Spectral Statistics, Max Likelihood 1.		^	^	^	^
ExBCC, Mean Shift, MR8 + ColourHist 2.	<		^	^	^
ExBCC, potujoče okno, MR8 3.	<	<			^
ExBCC, potujoče okno, ColourHist 4.	<	<			
ExBCC, potujoče okno, MR8 + ColourHist 5.	<	<	<		

5. ZAKLJUČEK

V tem članku smo predstavili metodo barvne vztrajnosti s primerki ter lastno implementacijo oz. adaptacijo te metode. Adaptirali smo segmentacijski korak te metode, pri čemer smo originalno segmentacijsko metodo *Mean Shift*, zamenjali s segmentacijo z drsečim oknom. S tako prilagojeno metodo smo dosegli bistveno boljše rezultate kot so rezultati, poročani v izvornem članku.

Kombinirane značilke so sicer dale najboljše rezultate, vendar pa je bila razlika majhna in v nekaterih primerih nesignifikantna. Ni povsem jasno, zakaj so se avtorji metode odločili uporabiti kombinirane značilke.

Edina bistvena razlika med našo implementacijo in opisom v izvornem članku je uporaba drsečega okna za pridobitev vzorcev namesto segmentacije *Mean Shift*. Najverjetneje smo tako zajeli pestrejše vzorce. Ti so vsebovali več različnih sosednjih površin, ki so se v podobnih konfiguracijah pojavljale tako v učnih kot testnih slikah. To je omogočalo boljše iskanje podobnih vzorcev in vodilo v boljšo oceno osvetlitve.

V osnovi je metoda zelo fleksibilna pri načinu segmentacije, izbiri značilik za primerjavo vzorcev in izbiri metode barvne vztrajnosti za ocenjevanje osvetlitve. Nadaljnje izboljšave lahko črpajo in prispevajo k rešitvam na vseh treh področij. Za nas najbolj zanimiva je prilagajanje obstoječih ali razvoj novih metod barvne vztrajnosti, ki bi uspešno delovale kot del te metode.

Ena izmed praktičnih slabosti metode je potreba po veliki zbirki učnih vzorcev. Le-ta je tako časovno kot prostorsko precej potratna. Nadaljnje raziskave bomo vsekakor usmerili v gradnjo kompaktnjših modelov, ki pa bi vseeno bili dovolj fleksibilni za prilagajanje vsebini posamezne slike.

LITERATURA

1. A. Gijsenij, T. Gevers, J. van de Weijer (2011), Computational Color Constancy: Survey and Experiments, *IEEE Transactions on Image Processing*, vol. 20, št. 9, str. 2475-2489.
2. H.R.V. Joze, M. S. Drew (2014), Exemplar-Based Color Constancy and Multiple Illumination, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 36, št. 5, str. 860-873.
3. D. Comaniciu, P. Meer, (2002), Mean shift: a robust approach toward feature space analysis, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 24, št. 5, str. 603-619.
4. M. Varma, A. Zisserman. (2002), Classifying images of materials: Achieving viewpoint and illumination independence, *Computer Vision—ECCV 2002*. Springer Berlin Heidelberg, str. 255-271.
5. A. Chakrabarti, K. Hirakawa, T. Zickler (2012), Color Constancy with Spatio-Spectral Statistics, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 34, no. 8, str. 1509-1519.
6. <http://colorconstancy.com>
Javno objavljeni rezultati metod barvne vztrajnosti.
7. P. Gehler, C. Rother, A. Blake, T. Minka, T. Sharp (2008), Bayesian Color Constancy Revisited, *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*.
8. L. Shi, B. Funt, *Re-processed Version of the Gehler Color Constancy Dataset of 568 Images*, dostopno na: <http://www.cs.sfu.ca/~colour/data/>

USPEŠNOST REKONSTRUKCIJE SCENE IZ VEČ POGLEDOV MED VOŽNJO POLJSKEGA ROBOTA

Jože Kraner, Matjaž Divjak, Jurij Rakun, Damjan Zazula

Univerza v Mariboru

Fakulteta za elektrotehniko, računalništvo in informatiko

E-pošta: joze.kraner@gmail.com

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

POVZETEK: *Tudi v kmetijstvu se vedno pogosteje srečujemo s poljskimi roboti, ki za navigacijo uporabljajo množico različnih senzorjev. Med temi senzorji je pogosto video kamera, ki omogoča posnetke med vožnjo robota ter analizo dinamičnih scen in njihovo 3D-rekonstrukcijo. V članku predstavimo nekaj poskusov s poljskim robotom, ki je opremljen tako s kamero kot tudi z laserskim merilnikom oddaljenosti. Iz parov zaporednih slik rekonstruiramo 3D-sceno, določimo oddaljenosti predmetov in razdalje primerjamo z referenčnimi laserskimi izmerami. Posebno pozornost namenimo izbiri primernih korespondenčnih točk, saj te pomenijo ključ do uspešne rekonstrukcije. Predstavljamo svoj postopek, ki optimalno izbere točk doseže s povezavo in primerjavo rekonstruiranih položajev in usmeritev kamere pri izbrani trojici slik. Predlagani kriterij je pri iskanju zanesljivega in usklajenega nabora korespondenčnih točk uspešnejši od znanega postopek na osnovi homografij.*

1 UVOD

Vse pogosteje se z računalniškim vidom srečujemo tudi v kmetijstvu, kjer so tipična opravila povezana z različno kmetijsko mehanizacijo. Stroji so opremljeni z digitalnimi kamerami, tako da lahko snemajo objekte v svojem okolju in z analizo posnetkov pridobijo informacije za svojo navigacijo ali za upravljanje z aktuatorji, ki pomagajo pri izvedbi opravil. Znani so robotske roke in premični roboti, ki znajo obirati sadje ali pobirati poljske pridelke [1, 2]. Pri tem je bistveno, da pravilno ocenijo položaj, oddaljenost in velikost sadeža in da ga nepoškodovanega pospravijo v svojo košaro.

Za določanje oddaljenosti sadeža od robotske roke in za premikanje po terenu se uporablja množica senzorjev, ki so nameščeni na robotu [3]. Med njimi so ultrazvočni ali laserski merilniki, katerih odlika je precej natančno določanje oddaljenosti, kadar imamo opravka z redkimi objekti na sceni. Če je gostota objektov večja, tovrstni merilniki odpovedo. Negotove so tudi meritve na objektih, katerih struktura se spreminja po višini, saj na primer laserski merilnik praviloma tipa na stalni višini, tako da določi oddaljenost

objektov, ki na tej višini odbijejo laserski žarek. S takšnimi merilniki tudi ne moremo rekonstruirati celotne oblike objektov ali njihove teksture. To je sicer možno, če imamo prostorski laserski ali ultrazvočni prebrnik, kar pa se redko uporablja v kombinaciji s kmetijskimi stroji oz. roboti.

Med danes običajnimi zaznavami so tudi pri kmetijski mehanizaciji vizualni posnetki z digitalnimi kamerami. Kamera se med delovanjem stroja premika, kar pomeni, da beleži posnetke iste scene z različnih položajev in z različnimi usmerjenostmi. Takšen nabor več pogledov na sceno omogoča njeno 3D-rekonstrukcijo [7]. Globinska informacija, ki jo na ta način pridobimo, je vitalnega pomena pri navigaciji in upravljanju stroja ali robota. Vsaj dva posnetka iste scene sta povezana z epipolarno omejitvijo, izraženo s temeljno matriko (ang. *fundamental matrix*). V njej se zrcalijo vsi notranji in zunanji parametri kamere. Notranjimi parametri kamere, ki določajo ploskovno ločljivost, premik optične osi kamere glede na koordinatni sistem slike in nepravokotnost slikovnega senzorja, se dajo določiti s kalibracijo kamere v obliki kalibracijske matrike. Iz temeljne matrike lahko s pomočjo kalibracijske matrike izračunamo osnovno matriko (ang. *essential matrix*), katere elementi povezuje le zunanje parametre, torej položaj in usmeritev kamere v svetovnem koordinatnem sistemu [8].

Ko se robot s kamero premika, dobivamo zaporedne posnetke, na katerih se vsaj deloma vidi ista scena. Zato lahko sceno rekonstruiramo na osnovi epipolarne geometrije z več pogledi (ang. *multiview constraint*). Določiti moramo korespondenčne točke, ki označujejo isto značilnico oz. piksel na vseh slikah scene [12]. Dobro ujemanje korespondenčnih točk na več slikah je ključnega pomena za verno rekonstrukcijo scene. Obstajajo različne možnosti, da ugotovimo, pri katerih korespondenčnih parih točk je ujemanje dovolj kakovostno, in se pri rekonstrukciji opremo le nanje.

V članku opisujemo poskuse s poljskim robotom, ki nosi kamero in laserski merilnik oddaljenosti in je bil razvit na Fakulteti za kmetijstvo in biosistemske vede v Mariboru. Pri običajni uporabi tega robota se laserski merilnik uporablja v navigaciji, tako da se robot izogiba oviram, pogled s kamero pa omogoča odkrivanje objektov, ki se jim mora robot približati – recimo, da želi priti do cvetlice, ki jo bo zalil. Namenoma smo poskuse zasnovali tako, da smo geometrijske razmere med opazovanimi objekti ocenili samo iz digitalnih posnetkov kamere, vzporedne laserske meritve oddaljenosti pa smo uporabili kot referenco.


Med vožnjo smo posneli zaporedje slik in na njih določili korespondenčne točke. Tako smo odstranili vse, ki so očitno kazale slabo ujemanje njihovih slikovnih okolic. Ustreznost preostalih smo nato primerjali na dva načina. Prvič, poskušali smo odstraniti slabe pare točk glede na to, ali se da zanje vzpostaviti enotna homografija. Na ta način smo prišli do prečiščenega nabora korespondenčnih točk in nato z njimi ter epipolarno geometrijo več pogledov rekonstruirali opazovano sceno. Drugič, izločanja slabih korespondenc smo se lotili še s preverjanjem, kako uspešno rekonstrukcijo scene lahko opravimo z njimi. Iz začetnega nabora korespondenčnih točk smo naključno jemali n -terice na treh zaporednih slikah, tvorili projekcijske matrike za te tri slike in se iz lastnosti teh matrik odločili, katera n -terica korespondenčnih točk je dala najboljšo 3D-

rekonstrukcijo. Kakovost 3D-rekonstrukcije smo ocenili tako, da smo koordinate rekonstruiranih 3D-točk primerjali z referencami, ki jih je izmeril robotov laserski merilnik.

V 2. poglavju razložimo zasnovo uporabljenega poljskega robota ter metod za rekonstrukcijo scene s pomočjo robotskega vida, 3. poglavje pa opisuje testno okolje in rekonstrukcijske rezultate. Zadnje, 4. poglavje kritično ovrednoti dobljene rezultate in sklene prispevek.

2 ZASNOVA POLJSKEGA ROBOTA IN METODE ROBOTSKEGA VIDA

Robot je sestavljen iz štirih glavnih komponent: mehanike, aktuatorjev, senzorjev in vgrajene elektronike. Mehanični del sestavlja štirikolesni pogon. Ima dve osi, ki ju lahko ločeno nadzorujemo s servomotorji, avtomatski menjalnik z dvostopenjskim prenosom in motor. Dodani so aktuatorji, ki omogočajo škropljenje: rezervoar pod pritiskom, dva elektromagnetna ventila in dve šobi. Na robota so nameščeni naslednji senzori: digitalna kamera (DMK 31BU03, proizvajalec The Imaging Source, ZDA), laserski merilnik razdalj (TIM310, proizvajalec SICK, ZDA) in kompas. S pogonskim sistemom, aktuatorji in senzori upravlja elektronika, ki s pomočjo vgrajenega računalnika krmili periferna vezja. Na sliki 1 je prikazan model robota s ključnimi elementi.



Slika 1: Shematski prikaz konstrukcije za poljskega robota CornStar: na sprednji strani (levo na sliki) sta vidna digitalna kamera zgoraj in pod njo laserski merilnik oddaljenosti.

Robota poganja motor X-power eco A4130-06BL s hitrostjo 510 obratov na minuto na volt. Robot lahko doseže hitrost do 2 m/s. Štirikolesni pogon z dvema osema, ki se lahko

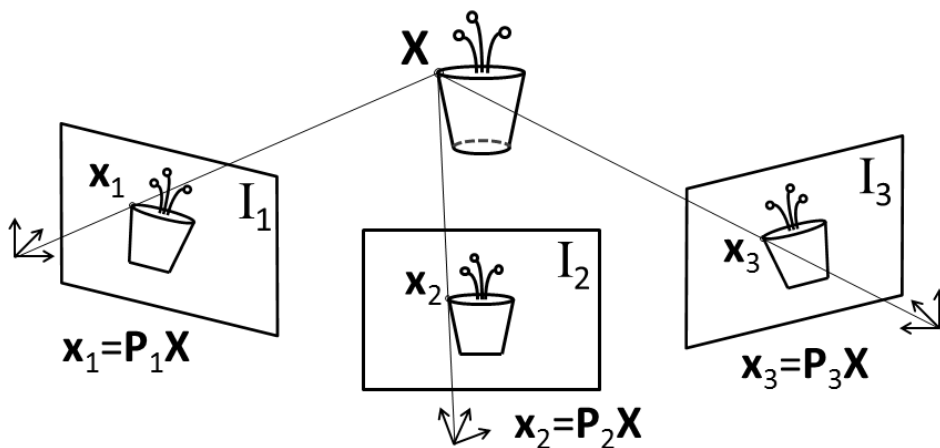
premikata vsaka zase, omogoča izredno majhen obračalni krog. Dva elektromagnetna ventila, šobi in rezervoar, ki so povezani s plastičnimi cevmi, so namenjeni škropljenju rastlin na izbranih lokacijah.

Senzorični del robota je sestavljen iz industrijske kamere DMK 31BU03 [4] in laserskega merilnika razdalj SICK TIM310 [5]. Kamera zajema slike z ločljivostjo 1024×768 pikselov in s frekvenco 30 slik/s. Laserski senzor pregleduje območje 270° s kotno ločljivostjo 1°. Meri razdalje od 5 cm do 4 m z napako ±40 mm. Kamera in merilnik razdalj povezuje z računalnikom USB-povezava.

2.1 Rekonstrukcija scene iz dveh slik

Rekonstrukcija 3D-scene iz množice slik oz. video posnetka je dobro raziskano področje, na voljo je veliko različnih rutin in algoritmov [12]. Za osnovno rekonstrukcijo potrebujemo dve sliki iste scene, posneti iz različnih zornih kotov (epipolarna geometrija). Pri robotskih aplikacijah lahko predpostavimo, da se je robot med zajemom prve in druge slike premaknil in da je prišlo do (trenutno neznanega) premika in zasuka kamere (slika 2). Pomembno je, da so tisti deli scene, ki jih želimo rekonstruirati, vidni na obeh slikah. Osnovni koraki postopka rekonstrukcije so naslednji:


- določanje korespondenčnih točk,
- računanje temeljne matrike F ,
- računanje osnovne matrike E ,
- računanje projekcijskih matrik P_1 in P_2 ,
- določanje 3D-koordinat s triangulacijo.



Slika 2: Več pogledov na isto sceno: 3D-točka X se preslika v 2D-točke x .

Korespondenčne točke so pari 2D-točk, ki so prisotni na obeh slikah I_1 in I_2 in ustrezajo istemu delu scene. Če imamo v sceni 3D-točko X , potem se ta točka preko projekcijskih matrik P_1 in P_2 preslika v 2D-korespondenčni točki x_1 in x_2 (slika 2). Korespondenčne

pare točk določimo tako, da najprej na vsaki sliki ločeno poiščemo množico značilnih točk, nato pa določimo pare točk, ki so si najbolj podobni. V našem primeru smo za določanje značilnih točk uporabili detektor vogalov FAST [9], okolico značilnih točk pa smo opisali z binarnim deskriptorjem FREAK [10]. Najbolj podobne pare točk smo izbrali s primerjavo njihovih deskriptorjev. Primer korespondenčnih točk na dveh slikah je prikazan na sliki 3, kjer so korespondenčni pari povezani s črto.



Slika 3: Primer korespondenčnih točk na dveh slikah

Temeljna matrika \mathbf{F} preslika posamezno 2D-točko iz slike \mathbf{I}_1 na epipolarno premico v sliki \mathbf{I}_2 in jo lahko izračunamo iz množice korespondenčnih točk [12]. Za računanje \mathbf{F} smo uporabili robusten algoritem LMEDS iz knjižnice OpenCV [14], ki matriko \mathbf{F} določi po nelinearnem postopku in sproti izloči točke osamelce (ang. *outliers*).

Iz matrike \mathbf{F} lahko s pomočjo kalibracijske matrike \mathbf{K} opredelimo osnovno matriko \mathbf{E} : $\mathbf{E} = \mathbf{K}^T \mathbf{F} \mathbf{K}$. Kalibracijska matrika \mathbf{K} opisuje notranje parametre kamere in smo jo določili vnaprej s pomočjo rutin iz Camera Calibration Toolbox [16]. Osnova matrika \mathbf{E} vsebuje samo zunanje parametre kamere, zato lahko iz nje po Hornovem postopku [11] 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. Prava rešitev je tista, pri kateri ležijo vse rekonstruirane prostorske točke pred kamero [12]. Ker smo \mathbf{P}_2 izrazili glede na projekcijsko matriko prve kamere, slednjo definiramo kot $\mathbf{P}_1 = [\mathbf{I} \mid \mathbf{0}]$.

Ko poznamo projekcijski matriki \mathbf{P}_1 in \mathbf{P}_2 , lahko s postopkom linearne triangulacije izračunamo 3D-koordinate za vse 2D-točke, za katere poznamo korespondence, ter s tem dobimo 3D-predstavitev scene, izraženo glede na položaj kamere pri prvi sliki \mathbf{I}_1 .

2.2 Izbira nabora ustreznih korespondenčnih točk

Iz zaporedja posnetkov, ki jih je naredil poljski robot, ko je vozil po eksperimentalnem poligonu, smo izbirali trojice slik, s katerimi smo želeli zagotoviti čim boljše rekonstrukcijo scene. Uporabili smo epipolarno geometrijo, kot je opisano v prejšnjem podpoglavju. Da bi dosegli čim natančnejšo rekonstrukcijo, smo morali izbrati nabore

korespondenčnih točk, ki se čim boljše ujemajo. Eksperimentalno smo preverili dva postopka, s katerima smo iskali optimalne nabore korespondenčnih točk.

Pravi temelji na računanju homografije \mathbf{H} [17] med nabori točk, ki na eni in drugi sliki tvorijo korespondenčne pare. Izločimo vse pare, ki ne ustrezajo preslikavi s \mathbf{H} . Tako prečiščen nabor korespondenčnih parov nato vključimo v rekonstrukcijo scene, ki jo opravimo z enim samim računanjem projekcijskih matrik. Da bi zagotovili primerljivost z drugim pristopom k optimizaciji nabora korespondenc, smo že pri izločanju s homografijami \mathbf{H} izhajali iz trojice slik. Zaradi splošnosti opišimo takšno trojico kot $\{\mathbf{I}_{k-1}, \mathbf{I}_k, \mathbf{I}_{k+1}\}$. Obravnavali so samo tiste korespondenčne točke, ki so se ujele med paroma slik $\{\mathbf{I}_{k-1}, \mathbf{I}_k\}$ in slik $\{\mathbf{I}_k, \mathbf{I}_{k+1}\}$. Vzeli smo izhodiščno točko na sliki \mathbf{I}_k in če smo zanj našli korespondenčni točki na slikah \mathbf{I}_{k-1} in \mathbf{I}_{k+1} , smo ti dve točki preverjali še med seboj. Če sta se s svojima okolicam ujemali, smo najdeno trojico točk proglasili za korespondenčne. Potem smo določili homografije med vsemi tremi možnimi pari slik izmed treh izbranih: \mathbf{H}_{k-1} , \mathbf{H}_k in \mathbf{H}_{k+1} . Obdržali smo samo tiste korespondenčne točke, ki so jih potrdile vse tri homografije.

Drugi postopek za optimizacijo korespondenčnih točk smo uvedli sami, zato smo ga želeli primerjati z znanim postopkom, ki uporablja homografije. Izhajali smo spet iz trojice slik $\{\mathbf{I}_{k-1}, \mathbf{I}_k, \mathbf{I}_{k+1}\}$. Zanje smo določili korespondenčne točke tako, kakor smo opisali že za prvi postopek v prejšnjem odstavku. Dobljenih korespondenc nismo dodatno prečiščevali, ampak smo jih uporabili neposredno za 3D-rekonstrukcijo. Naključno smo med njimi izbirali n -terice in z njimi določili projekcijske matrike. Izračune smo večkrat ponovili za različne naključne n -terice korespondenčnih točk (metoda RANSAC). Po optimizacijskem kriteriju smo se nazadnje odločili, katera n -terica točk je prispevala najnatančnejše projekcijske matrike.

Zasnovali smo optimizacijski kriterij, s katerim smo povezali prehode med koordinatnimi sistemi, določenimi s položaji in orientacijami kamere pri snemanju slik $\{\mathbf{I}_{k-1}, \mathbf{I}_k, \mathbf{I}_{k+1}\}$. Izhodiščna je bila slika \mathbf{I}_k . Privzeli smo, da ta slika določa središče svetovnega koordinatnega sistema. Nato smo določili transformacijski matriki za prehod v koordinatna sistema pri slikah \mathbf{I}_{k-1} in \mathbf{I}_{k+1} : $\mathbf{M}_{k,k-1} = [\mathbf{R}_{k,k-1}, \mathbf{t}_{k,k-1}]$ in $\mathbf{M}_{k,k-1} = [\mathbf{R}_{k,k-1}, \mathbf{t}_{k,k-1}]$, pri čemer predstavlja \mathbf{R} matrike zasuka, \mathbf{t} pa vektorje premika. Nazadnje smo izračunali še zvezo med položajema in usmeritvijo kamere pri slikah \mathbf{I}_{k-1} in \mathbf{I}_{k+1} : $\mathbf{M}_{k-1,k+1} = [\mathbf{R}_{k-1,k+1}, \mathbf{t}_{k-1,k+1}]$. Matrike zasukov in vektorje premikov smo izluščili pri tvorbi projekcijskih matrik po postopku, kot je razložen v prejšnjem podpoglavju.

Če pri rekonstrukciji teh matrik ni napak, mora veljati, da imata zaporedna zasuka iz položaja k v $k-1$ in nato še v $k+1$ enak učinek kot zasuk in položaja k v $k+1$. Iz tega izhaja naš prvi optimizacijski kriterij:

$$\mathbf{R}_{k-1,k} \mathbf{R}_{k,k-1} = \mathbf{R}_{k,k+1} \Rightarrow \mathbf{R}_{k,k+1}^{-1} \mathbf{R}_{k-1,k} \mathbf{R}_{k,k-1} = \mathbf{I}. \quad (1)$$

Kadar pri rekonstrukciji nastopajo napake, še posebej če so slabo izbrane korespondenčne točke, rezultat enačbe (1) ni identiteta. Zato lahko ocenimo ustreznost izbranega nabora korespondenčnih točk z naslednjim odstopanjem:

$$e_R = \frac{1}{9} \sum_{\substack{\text{po členih} \\ \text{matrice}}} \left| \mathbf{R}_{k,k+1}^{-1} \mathbf{R}_{k-1,k} \mathbf{R}_{k,k-1} - \mathbf{I} \right|. \quad (2)$$

Podobno lahko razmislimo o premikih. Če bi bila rekonstrukcija brez napak, bi nas morali zaporedni premiki iz položaja k skozi položaj $k-1$ do položaja $k+1$ privedi na isto mesto kot premik iz položaja k v $k+1$. Žal pa ne razpolagamo z absolutnimi vrednostmi premikov, ker lahko v rekonstrukcijskem postopku določimo premike v projekcijskih matrikah le do konstante natančno. Uporabljene rutine iz knjižnice [14] zato vedno vračajo vektorje premikov, ki so normalizirani s komponento v z -smeri, torej s $t^{(z)}$. Prizvemimo takšne vektorje premikov in zapišimo relacijo, ki zanje velja pri izbrani trojici slik:

$$\left[\mathbf{R}_{k-1,k+1} \mathbf{t}_{k,k-1}, \mathbf{t}_{k-1,k+1}, -\mathbf{t}_{k,k+1} \right] \left[t_{k,k-1}^{(z)}, t_{k-1,k+1}^{(z)}, t_{k,k+1}^{(z)} \right]^T = 0. \quad (3)$$

Ker komponent $t_{k,k-1}^{(z)}$, $t_{k-1,k+1}^{(z)}$ in $t_{k,k+1}^{(z)}$ ne poznamo, lahko enačbo rešimo le s smislu najmanjše kvadratne napake. Izvedemo razcep na singularne vrednosti:

$$[\mathbf{U}, \mathbf{D}, \mathbf{V}] = \text{SVD} \left(\left[\mathbf{R}_{k-1,k+1} \mathbf{t}_{k,k-1}, \mathbf{t}_{k-1,k+1}, -\mathbf{t}_{k,k+1} \right] \right) \quad (4)$$

in v $D(3,3)$ dobimo srednje kvadratno odstopanje od idealnega rezultata za enačbo (3). To odstopanje je tem večje, čim slabše je ujemanje med izbranimi korespondenčnimi točkami. Tako pridemo še do druge ocene za njihovo ustreznost:

$$e_t = D(3,3). \quad (5)$$

Končno oceno za ustreznost izbranih korespondenčnih točk dobimo z upoštevanjem obeh delnih ocen iz enačb (2) in (5). Pri naših poskusih smo ju preprosto sešteli.

2.3 Uspešnost rekonstrukcije

Pri poskusih s poljskim robotom smo izkoristili laserski merilnik oddaljenosti, ki je pritrjen na robota, tako da smo njegove izmere jemali kot reference za primerjavo z rekonstruirano sceno, kakršno smo zgradili iz trojic kamerinih slik. Pri tem smo se morali soočiti z dvema težavama.

Laserski merilnik na robotu motri prostor pred sabo samo v eni horizontalni ravnini. Zato smo morali poskrbeti, da smo z rekonstrukcijo prišli do točk, ki jih zanesljivo izmeri tudi laserski merilnik. Ker poznamo višino nad tlemi, na kateri pregleduje laser, smo na k -ti in $(k+1)$ -ti sliki iz izbrane trojice slik ročno določili N točk na robovih cvetličnih lončkov, za katere smo prepričani, da so v ravnini laserskega žarka. Te točke smo potem s projekcijskima matrikama za izbrani sliki in s postopkom triangulacije reprojicirali v prostor, tako da smo upoštevali koordinatni sistem, ki pripada položaju kamere za sliko \mathbf{I}_k .

Potem smo razbrali referenčne koordinate teh točk iz laserskih odčitkov pri položaju robota ob snemanju slike \mathbf{I}_k . Laserske meritve so absolutne, zato so dane v dolžinskih merskih enotah. Iz slik rekonstruirana scena seveda nima absolutnih koordinat, zato tako dobljene točke niso neposredno primerljive z laserskimi referencami. Ugotavljamo lahko le, ali obstaja podobnostna transformacija, ki priredi rekonstruirane točke referenčnim točkam z minimalno kvadratno napako. Če označimo vektor s koordinatami i -te 3D-točke z $\mathbf{X}(i)$, vektor z referenčnimi koordinatami pa z $\mathbf{X}_r(i)$, lahko ugotovimo uspešnost rekonstrukcije z naslednjim odstopanjem:

$$E = \frac{1}{3N} \sqrt{\sum_{i=0}^{N-1} \sum_{\text{po koordinatah}} (\mathbf{X}_r(i) - \mathbf{T}\mathbf{X}(i))^2}, \quad (6)$$

pri čemer je transformacija \mathbf{T} dobljena kot:

$$\mathbf{T} = [\mathbf{X}_r(0), \mathbf{X}_r(1), \dots, \mathbf{X}_r(N-1)] [\mathbf{X}(0), \mathbf{X}(1), \dots, \mathbf{X}(N-1)]^\#, \quad (7)$$

kjer $\#$ pomeni matrični psevdoinverz. Čim manjše je odstopanje E , tem boljše je ujemanje rekonstruirane scene z referenčnimi laserskimi izmerami.

3 EKSPERIMENTALNO OKOLJE IN REZULTATI

Na sliki 4 je prikazano eksperimentalno okolje. V laboratoriju smo postavili testni poligon z dvema vzporednima vrstama cvetličnih lončkov. Lončke smo nameščali v parih, tako da sta bila po dva postavljena drug na drugega. Lončki so stožčaste oblike, visoki 9 cm in premera 9 cm pri dnu ter 12 cm pri vrhu. Vrsti lončkov sta bili vzporedni in oddaljeni 90 cm. Med vrstama smo vstavili lonček s cvetlico, tako da je bil pomaknjen približno na tri četrtine oddaljenosti od začetka testnega poligona.

3.1 Zajem podatkov

Robota smo od začetka poligona počasi pognali proti cvetlici. Ob premikanju smo zajemali slike iz kamere in razdalje iz laserskega merilka ter jih shranili na robotov lokalni disk. Podatke smo kasneje uvozili v okolje matlaba in jih obdelali z algoritmi za 3D-rekonstrukcijo scene iz več pogledov, kakor smo opisali v poglavju 2.

V postopkih smo nastavili parametre na naslednje vrednosti:

- število korespondenčnih točk, ki smo jih vključevali v RANSAC-iteracije pri drugem postopku optimizacije (podpoglavje 2.2), je bilo enako 10;
- optimizacijo smo iskali skozi 50 iteracij metode RANSAC;
- ročno smo določili $N = 12$ točk za primerjavo z laserskimi meritvami (slika 5);
- za rekonstrukcijo smo potrebovali kalibrirano robotsko kamero. Ocenjena kalibracijska matrika je:

$$\mathbf{K} = \begin{bmatrix} 1689,82864 & 0 & 511,5 \\ 0 & 1438,58365 & 383,5 \\ 0 & 0 & 1 \end{bmatrix}.$$



Slika 4: Postavitev eksperimentalnega okolja

3.2 Rezultati

Iz zaporedja slik, ki jih je posnela robotska kamera pri sprehodu po eksperimentalnem poligonu, smo izbrali tri trojice slik. Slike v trojici so bile med seboj oddaljene za 7 slikovnih okvirov, trojice pa so bile locirane na razdaljah 1,825 m, 1,693 m in 1,503 m pred cvetličnim lončkom. Za vse tri testne primere smo izračunali projekcijske matrike, in to z optimizacijo po dveh postopkih: s pomočjo homografij in s pomočjo enačb (2) in (5). Povprečna odstopanja za 12 izbranih točk so zbrana v preglednici 1.

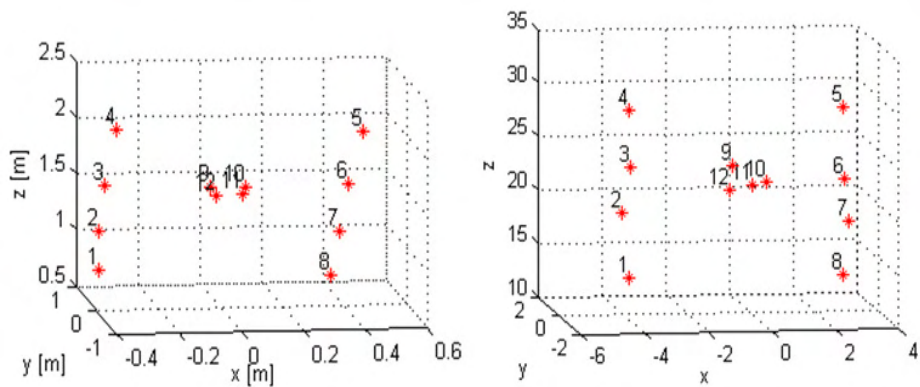
Preglednica 1: Odstopanja med rekonstruiranimi in referenčnimi točkami

Srednje kvadratno odstopanje [m]	
Optimizacija korespondenc s homografijami	Optimizacija korespondenc s kriterijem 3 slik
0,0085	0,0075
0,0145	0,0116
0,0167	0,0152

Slika 5 prikazuje točke, ki smo jih ročno označili in jih z najprimernejšimi projekcijskimi matrikami rekonstruirali v prostoru. Rezultate rekonstrukcije kaže slika 6: desna podslika vsebuje rekonstruirane točke, odčitki iz laserja pa so na levi podsliki.



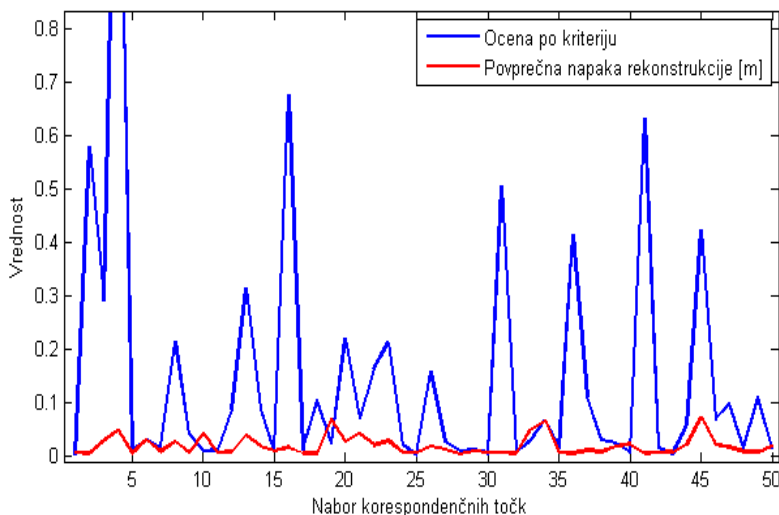
Slika 5: Ročna izbira testnih točk v eksperimentalnem okolju: točke so izbrane na lokacijah, za katere so na razpolago tudi referenčne laserske meritve.



Slika 6: Prikaz testnih točk v prostoru: položaj referenčnih laserskih meritev (levo), položaj rekonstruiranih točk z epipolarno geometrijo več pogledov in optimizacijo korespondenčnih točk po enačbah (2) in (5).

Slika 7 prikazuje z modrim grafom spreminjanje kumulativne ocene po kriteriju iz enačbah (2) in (5) skozi 50 tekov RANSAC-a. Vzporedno je z rdečo narisana rekonstrukcijska

napaka, računana po enačbi 6. V vsaki iteraciji smo naključno izbrali 10 korespondenčnih točk, ki so služile za opredelitev projekcijskih matrik.



Slika 7: Primerjava združenih ocen po kriteriju iz enačb (2) in (5) ter srednje kvadratne napake, dobljene iz razlik med referenčnimi laserskimi meritvami in 3D-rekonstrukcijo skozi 50 tekov RANSAC-a: kumulativno odstopanje po enačbah (2) in (5) je prikazano modro, rekonstrukcijska napaka pa rdeče.

4 RAZPRAVA IN SKLEPI

Dobljeni rezultati so pokazali, da je lahko rekonstrukcija 3D-scene uspešna, če znamo določiti natančne korespondence med pari točk vsaj na dveh slikah. Zagotoviti moramo tudi zanesljivo kalibracijsko matriko. Čeprav smo svoj poskus omejili na preprosto eksperimentalno postavitvev in le majhno število preverjanj, je pokazal, da je lahko rekonstrukcija 3D-scene, dosežena z elementi epipolarne geometrije in s triangulacijo, uspešna tudi izhajajoč samo iz dveh posnetkov scene.

Naš glavni namen je bil preveriti, kako bi lahko čim bolj optimizirali nabor kakovostnih korespondenčnih parov točk. Primerjali smo uveljavljen postopek, ki temelji na medslikovnih homografijah, s postopkom, ki smo ga predlagali v tem članku v podpoglavju 2.2. Preglednica 1 kaže, da je naš postopek zagotovil izbiro korespondenčnih parov, s katerimi je bila 3D-rekonstrukcija uspešnejša. Slika 7 poudarja pomembno ugotovitev: kriterij, ki smo ga uvedli z enačbama (2) in (5), zagotavlja izbiro optimalnih naborov točk za rekonstrukcijo, hkrati pa je izračunljiv brez referenčnih vrednosti, torej le iz slik, ki vstopajo v rekonstrukcijo.

Ker smo kot izhodišče vzeli robotski vid, bo treba seveda razmisliti tudi o zniževanju časovne zahtevnosti rekonstrukcijskega postopka in njegovim prilagajanjem za izvedbo v realnem času.

ZAHVALA

Raziskava je bila delno podprta z reintegracijskim projektom 7. evropskega okvirnega programa qFATIGUE (pogodba št. FP7-PEOPLE-2010-RG-269438), delno pa s sredstvi Javne agencije za raziskovalno dejavnost Republike Slovenije (programska skupina P2-0041).

5 LITERATURA

- [1] A. R. Jiménez ird. (2000), A survey of computer vision methods for locating fruit on trees, *Transaction of the ASAE*, vol. 43, str. 1911-1920.
- [2] M. Benady, G. E. Miles (1992), Locating melons for robotic harvesting using structured light, *Transaction of the ASAE*, no. 92-7021.
- [3] R. Fernández, C. Salinas, H. Montes, J. Sarria (2014), Multisensory System for Fruit Harvesting Robots, *Sensors*, vol. 14, str. 23885-23904.
- [4] Kamera DMK 31BU03,
http://www.theimagingsource.com/en_US/products/cameras/usb-ccd-mono/dmk31bu03/
- [5] Laserski merilnik razdalj Sick TIM310,
<https://www.mysick.com/PDF/Create.aspx?ProductID=60873&Culture=en-US>.
- [6] Prikaz napake pri meritvi razdalj glede na oddaljenost točke,
<http://www.robotsinsearch.com/products/tim310-1030000-0>.
- [7] D. A. Forsyth, J. Ponce (2011), *Computer vision: a modern approach*, 2. izdaja, Prentice Hall.
- [8] E. Trucco, A. Verri (1998), *Introductory Techniques for 3-D Computer Vision*, Prentice-Hall.
- [9] E. Rosten, R. Porter, T. Drummond (2008), Faster and better: A machine learning approach to corner detection, *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol. 32, str. 105-119.
- [10] A. Alahi, R. Ortiz, P. Vandergheynst (2012), FREAK: Fast Retina Keypoint, *IEEE Conference on Computer Vision and Pattern Recognition*, str. 510-517.
- [11] B. K. P. Horn (1990), *Recovering baseline and orientation from essential matrix*, Internal report.

- [12] R. I. Hartley, A. Zisserman (2000), *Multiple View Geometry in Computer Vision*, Cambridge University Press.
- [13] Fundamental matrix (computer vision),
https://en.wikipedia.org/wiki/Fundamental_matrix_%28computer_vision%29.
- [14] Open source computer vision library, <http://opencv.org/>.
- [15] Essential matrix, https://en.wikipedia.org/wiki/Essential_matrix.
- [16] Camera calibration toolbox for Matlab,
http://www.vision.caltech.edu/bouguetj/calib_doc/.
- [17] Homography (computer vision),
https://en.wikipedia.org/wiki/Homography_%28computer_vision%29.

MEDICINSKE IN BIOMEDICINSKE APLIKACIJE

DETEKCIJA IN SLEDENJE KAVITACIJSKIH MEHURČKOV PRI MEDICINSKIH LASERSKIH POSEGIH

Jaka Pribošek⁽¹⁾, Peter Gregorčič⁽¹⁾, Andrej Vrečko⁽²⁾, Janez Diaci⁽¹⁾

⁽¹⁾ Univerza v Ljubljani, Fakulteta za strojništvo,
Aškerčeva 6, 1000 Ljubljana

⁽²⁾ Optotek d.o.o., Tehnološki park 21, 1000 Ljubljana
E-pošta: jaka.pribosek@fs.uni-lj.si

POVZETEK: Članek obravnava problematiko sprotnega nadzora laserskih medicinskih posegov. Pri tem se osredotočamo na tiste posege, kjer pride do nastanka kavitacijskih mehurčkov. Ti so še zlasti pomembni v oftalmologiji in medicini, saj predstavljajo tako »orodje«, kot tudi vir neželenih poškodb okoliškega tkiva. Poleg tega pa jih je mogoče uporabiti tudi za optimizacijo laserskih parametrov v realnem času. V ta namen pa je potrebno razviti ustrezen algoritem, ki omogoča njihovo prepoznavo in sledenje v realnem času. V članku predstavljamo razvoj algoritma za spremljanje nastanka kavitacijskih mehurčkov med samim operativnim posegom. Algoritem sestoji iz detekcijskega in sledilnega dela, ki oba temeljita na Bayesovem zlivanju podatkov. V članku predstavljamo nekatere preliminarne rezultate uporabe algoritma na izbranih in-vivo posnetkih operativnih posegov v medicini.

1. UVOD

V sodobni laserski medicini postaja sproti nadzor izjemnega pomena. Omogoča namreč boljšo učinkovitost in varnost laserskih medicinskih posegov. Za razvoj in implementacijo sprotnega nadzora pa je potrebno najprej dobro poznavanje ključnih mehanizmov pri posameznem posegu, na osnovi tega pa je nato potrebno razviti ustrezno detekcijsko metodo za spremljanje posega. Pri sami implementaciji pa je ključnega pomena procesiranje zajetih podatkov v realnem času, saj lahko s pomočjo ustreznega in dovolj hitrega procesiranja nato laserske parametre sproti prilagajamo tako, da omogočajo učinkovitejše in varnejše zdravljenje.

V članku se osredotočamo na tiste medicinske posege, pri katerih pride do nastanka kavitacijskih mehurčkov. Načeloma so to posegi, kjer z laserskim bliskom povzročamo uparjanje kapljevine. Avtomatska detekcija, ki omogoča sproti spremljanje dinamike kavitacijskih mehurčkov, je še posebej pomembna pri nekaterih zobozdravstvenih posegih, kot je lasersko čiščenje zobnih kanalov [1] ter pri oftalmoloških posegih, kot sta laserska kapsulotomija [2] in selektivna laserska trabekuloplastika [3].

V primeru laserskega čiščenja zobnih kanalov sta detekcija in avtomatska analiza kavitacijskih mehurčkov pomembna predvsem z vidika preučevanja optodinamskega izkoristka energijske pretvorbe [4]. Pri tem višji optodinamski izkoristek pomeni manjše segrevanje okoliškega tkiva in s tem učinkovitejši in varnejši poseg. V primeru selektivne laserske trabekuloplastike pa so kavitacijski mehurčki, ki nastajajo med posegom, pomembni za določanje energijskega praga. Zdravnik namreč prične poseg pri nizki energiji bliska (običajno okoli 0,8 mJ) in jo nato v majhnih korakih (običajno 0,1 mJ) dviguje toliko časa, da vizualno opazi nastanek kavitacijskih mehurčkov. Nato energijo za en korak zmanjša pod vrednost tega praga. Težava take detekcije je v tem, da je prepuščena subjektivni presoji zdravnika in ga tudi dodatno obremenjuje. Zato obstaja realna potreba po ustreznem procesnem algoritmu, ki bo omogočil prepoznavo mehurčkov s pomočjo strojnega vida.

V prispevku predstavljamo razvoj algoritma za spremljanje nastanka kavitacijskih mehurčkov med operativnim posegom selektivne laserske trabekuloplastike. Algoritem je sestavljen iz detekcijskega in sledilnega dela. Oba temeljita na Bayesovem zlivanju podatkov. Poleg samega algoritma predstavljamo tudi nekatere uvodne rezultate uporabe algoritma na izbranih *in-vivo* posnetkih.

2. ALGORITEM ZA DETEKCIJO IN SLEDENJE

V tem poglavju predstavljamo algoritem avtomatske detekcije kavitacijskih mehurčkov med posegom selektivne laserske trabekuloplastike. Celotni algoritem predstavlja shema na Sl.1. Sestavljen je iz treh korakov: (i) predprocesiranje slike, (ii) detekcija pojava novih kavitacijskih mehurčkov ter (iii) sledenje obstoječim mehurčkom preko sekvence zaporednih slik.

2.1 Predprocesiranje slike

Pri selektivni laserski trabekuloplastiki se uporabljajo pragovne energije laserskih bliskov, pri katerih se kavitacijski mehurčki šele pojavijo. Nastali mehurčki so zato zelo majhni ter pogostokrat izjemno slabo kontrastni glede na podlago, ki jo predstavlja posnetek trabekularnega tkiva. Poleg tega je tkivo, na katerem se mehurčki pojavljajo lahko povsem različnih tekstur. Vse to močno otežuje avtomatsko detekcijo. Ta je dodatno otežena z dejstvom, da oftalmolog med posegom ves čas ročno upravlja laserski sistem in pri tem stalno spreminja vidno polje kamere. Stalne spremembe vidnega polja močno degradirajo delovanje detekcijskih in sledilnih algoritmov ter posledično terjajo ustrezno predprocesiranje zajetih posnetkov. Sliko je za dobro detekcijo tako potrebno najprej stabilizirati. Ker operativni poseg poteka lokalizirano, gibi kirurga pa so blagi, lahko med dvema zaporednima slikama v posnetku privzamemo relativno majhne spremembe v perspektivi. Le-te lahko matematično opišemo z afino preslikavo, ki je definirana s premikom (x,y) in zasukom v ravnini (φ) . Za določitev iskanih treh parametrov uporabimo Lucas Kanade algoritem (LK) [5]. Pri LK se končna registracija dveh zaporednih slik določa s pomočjo zaporednega približevanja. V praksi že majhno število iteracij zadostuje za kvalitetno stabilizacijo slike.



Slika 1: Celotni algoritem

2.2 Detekcija mehurčkov

Kavitacijske mehurčke detektiramo na stabiliziranem posnetku. Za zanesljivo detekcijo uporabljamo dva različna detektorja. Prvi temelji na spremljanju značilik, ki po obliki in intenziteti ustrezajo mehurčkom. Drugi temelji na zaznavanju nenadnih sprememb, ki ustrezajo hitremu pojavu mehurčkov. Podatke obeh detekcijskih algoritmov združimo s pomočjo Bayesovega zlivanja podatkov [6], s čimer zagotovimo večjo robustnost zaznavanja. Pri prvem detektorju vizualnih značilik vhodno sliko sprva visokopasovno filtriramo. Visokofrekvenčne komponente se pogosto pojavijo v okolici mehurčkov, ki jih želimo slediti ter v okolici morebitnih ostrejših robov na sliki. Drugi detektor gibanja spremlja nenadne spremembe med dvema zaporednima slikama. Registrirani zaporedni sliki medsebojno odštejemo ter s tem dobimo sliko različnosti. To nato binariziramo in s pomočjo algoritma povezanih gruč določimo težišča posamičnih gruč slikovnih elementov. Za boljše delovanje detekcij upoštevamo, da se mehurčki pojavijo neposredno v okolici pege, ki jo povzroča pilotni laserski žarek. Lokacija le-tega glede na mesto interakcije med laserskim bliskom in tkivom se med operacijo ne spreminja in jo lahko določimo pri kalibraciji in vzpostavitvi laserskega sistema. Zaradi stabilizacije slike, pa se ta lega na stabilizirani in obrezani sliki neprestano spreminja. Fiksne koordinate laserske pege na vhodni sliki tako preslikamo s pomočjo afine transformacije, ki jo dobimo iz LK algoritma. Okolici tako dobljenega centra laserskega žarka priredimo Gaussovo gostoto porazdelitvene verjetnosti s $\sigma=40$. S tem predvidevamo, da je pojav mehurčka bolj verjeten tem bližje centru laserskega žarka se nahaja. Končno zaznavanje mehurčkov je nato izvedeno s pomočjo Bayesovega zlivanja podatkov. Vse gostote porazdelitvenih verjetnosti normaliziramo, ter izračunamo povezano verjetnost. V primeru, da *maksimalna a posteriori* verjetnost zadošča pogojem minimalne verjetnosti, lokalni maksimum privzamemo kot lokacijo novo detektiranega mehurčka in ga dodamo


v bazo. Baza obsega lokacijo mehurčka na sliki, neposredno okolico mehurčka in čas, ob katerem se mehurček pojavi na posnetku.

2.3 Sledenje mehurčkom

Ko mehurček uspešno detektiramo, ga sledimo preko sekvence zaporednih slik. Za sledenje uporabljamo enostavno križno korelacijo trenutne slike s slikovnimi izseki, ki pripadajo mehurčkom v prejšnjem časovnem koraku. Za izboljšavo robustnosti takega sledenja vpeljemo apriorno poznavanje lokacije mehurčka iz prejšnje slike. Oba podatka tako združimo s pomočjo Bayesovega zlivanja podatkov. Določitev maksimuma aposteriorne verjetnosti določa novo lego premikajočega se mehurčka. Iz slike izluščimo nov izsek neposredne okolice mehurčka, ter posodobimo bazo mehurčkov.


3. EKSPERIMENT

Posneli smo prve *in-vivo* posnetke pri selektivni laserski trabekuloplastiki z lasersko napravo OptoYag&SLT M (Sl. 2). Posnetke smo analizirali s pomočjo opisanega algoritma. V primerjavi z mehurčki, ki jih je na sliki opazil človek, je algoritem uspešno zaznal in sledil kavitacijskim mehurčkom v 80% vseh primerov.



Slika 2: Primer uporabe algoritma na 1.(levo) in 27. sliki (desno) *in-vivo* posnetka. Viden je detektiran mehurček ter njegov izgled ob začetku ter koncu sledenja

Sledenje mehurčkom deluje zanesljivo in robustno, kar prikazuje Sl.3. Kljub spremembi v izgledu in osvetlitvi, je algoritem uspešno sledil mehurček preko sekvence 27-ih slik.



Slika 3: Baza pravilno sledenega mehurčka preko zaporedja 27 slik

3. ZAKLJUČEK

V prispevku smo predstavili koncept algoritma za sledenje kavitacijskim mehurčkom med selektivno lasersko trabekuloplastiko. Predstavljen algoritem je bil testiran na preliminarnih *in-vivo* posnetkih ter dosega visoko stopnjo učinkovitosti. Nadaljevanje študije gre zato v smeri nadgradnje detekcijskega algoritma, povišanja zanesljivosti delovanja in testiranja na široki bazi posnetkov različnih operacij.

LITERATURA

- [1] E. DiVito, O. A. Peters, G. Olivi, "Effectiveness of the erbium:YAG laser and new design radial and stripped tips in removing the smear layer after root canal instrumentation," *Lasers Med. Sci.*, vol. 27, no. 2, pp. 273–280, Mar. 2012.
- [2] G. Hawlina, D. Perov, B. Drnovšek, J. Možina, P. Gregorčič, "Optical coherence tomography for an *in-vivo* study of posterior-capsule-opacification types and their influence on the total-pulse energy required for Nd: YAG capsulotomy: a case series," *BMC Ophthalmol.*, vol. 14, no. 1, p. 131, 2014.
- [3] M. Waisbourd, L. J. Katz, "Selective laser trabeculoplasty as a first-line therapy: a review," *Can. J. Ophthalmol. J. Can. Ophthalmol.*, vol. 49, no. 6, pp. 519–522, Dec. 2014.
- [4] P. Gregorčič, M. Jezeršek, J. Možina, "Optodynamic energy-conversion efficiency during an Er: YAG-laser-pulse delivery into a liquid through different fiber-tip geometries," *J. Biomed. Opt.*, vol. 17, no. 7, pp. 0750061–0750069, 2012.
- [5] B. D. Lucas, T. Kanade, "An iterative image registration technique with an application to stereo vision.," in *IJCAI*, 1981, vol. 81, pp. 674–679.
- [6] H. Durrant-Whyte, T. C. Henderson, "Multisensor data fusion," *Springer Handb. Robot.*, pp. 585–610, 2008.

DRUGO

VIRTUALLY ENHANCED SCULPTURE

Blaž Meden, Blaž Jeršan, Gorazd Rajar, Franc Solina

**Computer vision laboratory,
Faculty of Computer and Information Science, University of Ljubljana,
Večna pot 113, 1000 Ljubljana, Slovenia
E-pošta: franc.solina@fri.uni-lj.si,
{blaz.meden, blaz.jersan, gorazd.rajar}@gmail.com**

ABSTRACT: *The article describes how a simulation environment for projecting virtual water droplets trickling over slanted surfaces was implemented. The motivation for this work was to enrich a stone sculpture by introducing a dynamic dimension into the usual static environment. The 3D shape of the projection surface on the sculpture was captured by the Kinect range scanner.*

1. INTRODUCTION

An age old way of making stone sculpture more dynamic and energetic is to combine stone with running water. This is manifested by the abundance of fountains made out of stone throughout history and in all parts of the world. We decided to animate a stone sculpture with virtual water droplets using modern computer technology. In recent years methods for capturing the 3D shapes have become much faster and easier to use. Sensors such as the Microsoft Kinect have opened the door to new applications where the 3D shapes of objects and scenes have to be known.

In this article we describe how we used the Kinect range sensor to capture the 3D shape of a stone sculpture to be able to project on the sculpture virtual water droplets that are running over the sculpture obeying the physical law of gravity. Projects which are somewhat related to our project are interactive sandboxes [1,2,3] where the users can shape the sand in the sandbox into new forms which are continuously captured by a Kinect. A video projector is also used to color the sand according to some rules. These boxes can be educational, demonstrating geographic, geologic, and hydrologic concepts or a platform for interactive games. The virtual space projected onto a physical 3D landscape becomes alive with all forms ranging from spiders, beetles and snails through ammonites and trilobites to sharks and dinosaurs, all inhabiting a Mixed Reality ecosystem [4].

To simulate the trickling of water droplets over a slanted surface we have to achieve the following goals:

1. capture a cloud of 3D points on the surface on which we want to project the animated droplets,
2. create a 3D model from the cloud of 3D points,
3. create a dynamic model for water,
4. project the liquid droplets on the 3D model and simulate their movement according to the laws of gravity,
5. adjust the projection of animated droplets to the 3D surface.

For testing of the system we used instead of the envisioned stone sculpture a white sheet stretched over support. The actual stone sculpture is still in the process of carving.

The rest of the article is divided as follows, Section 2 describes the equipment and tools that we used for implementation of our goals, Section 3 is on the installation and operation of the whole system, Section 4 shows the results of simulation, and Section 5 concludes the article.

2. EQUIPMENT AND TOOLS

2.1 Hardware

Range sensor—Kinect Kinect is a Microsoft product that captures range images on the principle of using multiple cameras. Kinect appeared together with the game console Xbox 360 primarily to capture the movement of players of computer games. But since Kinect is easy to use and is reasonably priced it became popular with a large user community that applies Kinect to a large variety of applications that need 3D shape capture. The output of Kinect is a cloud of 3D points in a given coordinate system.

Video projector For the projection of animated droplets on the 3D surface any digital video projector could be used that has a wide projection angle so that the projector needs not to be elevated too high above the projected surface. The elevation depends of course also on how long and wide is the sculpture.

Computer The processing power requirements for the envisioned system are quite high. The system must support the processing of the input image and the simulation of water droplets which is computationally very demanding and proportionally dependent on the number of simulated water droplets. We used a laptop computer with two graphical cards which made possible a simultaneous simulation of 15.000 water droplets at the speed of 30 frames per second. This gave a reasonably good approximation of liquid simulation.

2.1 Software

OpenFrameworks OpenFrameworks is an open source framework for integration of various technologies which are used in computer graphics, computer vision and interactivity in general. The framework is written in C++ and represents a high level abstraction of OpenGL, GLEW, Glut, FreeType, OpenCV and other libraries. The framework enables the use of different libraries which are developed by an active

community of developers. Beside the OpenFrameworks we used in the project also ofxKinect (which supports the communication with the range sensor Kinect) and ofxGui (which offers elements for adjusting the user interface parameters).

Microsoft Visual Studio Microsoft Visual studio is an integrated development environment which supports the C++ programming language and is on the Windows operating system the recommended tool for application development under OpenFrameworks. The entire programming code of the project is written in C++ so that during the entire project development Visual Studio was used.

3. INSTALLATION AND OPERATION OF THE SYSTEM




Figure 1: The setup of the equipment: the video projector and Kinect are aligned and close together above the sculpted surface.

The range sensor and the video projector must be mounted above the sculpture so that all parts of sculpture's surface are visible from their viewpoint. The field of view of the range sensor and the video projector should overlap as much as possible (Fig. 1) so that the alignment of the projection to the 3D model of the sculpture can be accurate enough and simple to achieve. Kinect has in our case a wider field of view as the video projector. Ideally, the projector and Kinect should be mounted directly above the sculpture so that the whole sculpture can be evenly illuminated by the projection and any shadows due to the configuration of the sculpture could be eliminated.

3.1 Range image capture

Kinect captures 3D points by using an infrared projector and infrared camera. The captured 3D points can be visualized as an intensity image of size 640×480 pixels or a cloud of 3D points. Our application takes the cloud of 3D points and aligns them with the global coordinate system of the space. Next, the 3D points are projected onto the horizontal plane. The projection is then saved as an intensity image. This gives us the perpendicular view of the scanned objects. From the projection we generate the 3D model of points which we color according to their height. The generated model serves as

a virtual representation of the scanned space and represents the supporting surface for liquid simulation.

Determination of the coordinate system of the 3D point cloud The 3D points obtained from Kinect are defined in a coordinate system which is rotated according to the slant of the Kinect sensor. The 3D points must therefore be transformed with an inverse rotation into a global coordinate system. The slant of the sensor is indicated by the gyroscope which is built into the Kinect. It is possible also to manually set the slant angle on the user interface of the system. The 3D points are after the transformation aligned with the global coordinates of the space. The global coordinates represent the following dimensions:

- z axis – vertical dimension or the direction of gravitation,
- x axis – first dimension of the horizontal plane,
- y axis – second dimension of the horizontal plane.

Conversion of the 3D point cloud into a 3D model The 3D model was constructed out of the generated intensity image which represents the vertical projection of the 3D point cloud. The 3D model is a grid of points where the coordinates of each 3D point are the x and y coordinate of the corresponding pixel in the intensity image and the z coordinate is the intensity (height) of the pixel. This 3D model represents the surface of the scanned sculpture. For debugging and easier visualization we color coded the height of the 3D model using the colors shown in Fig. 2.

3.2 Simulation of water droplets

Since we could not find an appropriate open source solution for the simulation of water droplets that move in the direction of the highest gravity gradient, we decided to write our own code. For the purpose of our visualization goal we decided to model the liquid with a high number of small particles in the form of spheres that move on the surface of our 3D model. Each particle or droplet is an independent unit that moves independently. The direction and the velocity of the movement of each droplet depend on:

- the gradient of the surface where the droplet currently is,
- the direction and velocity of the droplet in the previous step of the simulation,
- an adjustable chance factor.

A droplet therefore moves down the slope according to the slant of the surface. Since a droplet has a mass, the inertia from the previous step influences its movement in the next step of the simulation. Individual droplets however do not have any physical dimension and therefore no collisions between droplets can appear. The detection of collisions is computationally demanding and would reduce the maximum possible number of droplets that we can simulate on our hardware in real time. Additionally we do not use any shading and illumination of droplets which is also computationally demanding and does not add much to the realistic view of the liquid. A multitude of moving droplets create the appearance of running liquid. Since a large number of droplets reappear in the

same point of the 3D model and continue according to the surface gradient, we introduced a chance factor which takes care that the path of the water droplets originating from the same point is not identical. This chance factor greatly improves the appearance of the liquid and is computationally not demanding.

3.2 User interface

During the simulation of the droplets the user can change different parameters of the simulation using a simple graphical user interface. When the whole installation is being set up, the first task is to align the picture projected with the video projector to the projection surface on the sculpture. The picture is initially approximately aligned based on the position of the Kinect and on the centroid of the 3D points. The virtual camera in the simulation model is positioned in the point where the Kinect is mounted and directed towards the centroid of all 3D points captured by Kinect (approximately toward the projection surface).

However Kinect and the video projector can not be exactly in the same position as can be seen in Fig. 1 and therefore they cannot have exactly the same viewing angle. This difference must be adjusted manually. This can be done on the user interface by changing the projection angle and the scaling of the 3D surface model.

User interface for droplet simulation On the user interface we can change the following parameters of the simulated droplets:

- the number of droplets in the simulation,
- the viscosity of the droplets,
- the value of the chance factor for the movement of the droplets,
- color of the droplets,
- transparency of the droplets.

Creation of water sources Droplets must come from somewhere in order to run down the sculpture. The user can define the position of water sources on the sculpture interactively by selecting the position on the surface model with a mouse click. One can select several sources, however, the number of water droplets is then divided among them so that the simulation always uses the same predefined number of water droplets. If the maximum possible number of droplets in the current implementation (15.000) is divided among ten sources one can still get a realistic visualization.

4. RESULTS

Fig. 2 shows a demonstration of the achieved visualization. For this visualization, the maximum number of 15.000 droplets was selected. The droplets are colored blue and when they reach the “water level”, also colored blue, they disappear and reappear in one of the sources. This visualization is only a proof of our concept for the simulation of water droplets since a white sheet supported by boxes was used as the projection surface.




Figure 2: Final visualization of water droplets running down sloping surfaces.

A stone sculpture is being carved out of white marble specially for this project. The marble will not be polished to a high degree so that the light will be absorbed rather than specularly reflected.

5. CONCLUSIONS

We implemented a system for projecting dynamic content (trickling of water droplets) onto a 3D varying projection surface. The system was tested on a simulated surface since the actual stone sculpture which will be the centerpiece of this interactive installation is in the process of carving.

REFERENCES

1. Kreylos, O.: Augmented reality sandbox. <http://idav.ucdavis.edu/~okreylos/ResDev/SARndbox/>, online; accessed 14-November-2014
2. Project mimicry. <http://mimicry.monobanda.nl>, online; accessed 14-November-2014
3. Sandystation the interactive sandbox. <http://en.sandystation.cz/>, online; accessed 14-November-2014
4. St. Jean, J.: Augmented reality evolution timeline using open-frameworks. <http://developkinect.com/news/augmented-reality/augmented-reality-evolution-timeline-using-openframeworks> (2012), online; accessed 14-November-2014

ŠTUDENTSKE APLIKACIJE

SISTEM OBOGATENE RESNIČNOSTI ZA SIMULACIJO BOLEZNI ČLOVEŠKEGA VIDA NA OSNOVI OCULUS RIFT OČAL

Boštjan Buh, Peter Peer

Fakulteta za računalništvo in informatiko, Univerza v Ljubljani

Večna pot 113, 1000 Ljubljana

E-pošta: bostjan.buh@gmail.com, peter.peer@fri.uni-lj.si

POVZETEK: V članku predstavljamo sistem, ki povezuje očala Oculus Rift z dvema spletnima kamera ter programom za simulacijo boleznih vida. Implementirali smo simulacije petih različnih boleznih z obogateno resničnostjo: barvne slepote, tunelskega vida, retinopatije, dioptrije ter degeneracije rumene pege. V implementaciji smo uporabili knjižnico Unity za povezavo očal s kamerama in simulacijo boleznih vida ter Visual Studio aplikacijo za nastavitve posameznih boleznih vida. Kvalitativni testi v Laboratoriju za uporabniško izkušnjo na Fakulteti za grafiko Univerze v Zagrebu so potrdili učinkovitost pristopa.

1. UVOD

Oči s pomočjo receptorjev (čutilnih celic) na mrežnici na zadnji strani očesnega zrkla zaznavajo svetlobo ter barvo. Svetloba pride do mrežnice tako, da potuje skozi zenice in prekatne tekočine do leče, ta pa lomi svetlobne žarke, ki se nato zberejo na mrežnici [1]. Receptorji se delijo na čepke ter paličice. Paličice so občutljive za svetlobo in ne zaznavajo barv. Čepki pa zaznavajo barvo in se delijo na tri vrste glede na barvo, ki jo zaznavajo: rdeče, zelene in modre. Največ čepkov se nahaja na t.i. rumeni pegi, ki se nahaja točno nasproti očesne leče. V primeru okvare čepkov, paličic ali leče ločimo več boleznih vida [2].

Tako se mnogokrat ob omembi boleznih vida kot so barvna slepota, tunelski vid, dioptrija ipd. pojavi vprašanje, kako osebe s temi boleznimi vidijo. Cilj našega projekta je implementacija simulacij različnih boleznih vida in prikazati osebam brez boleznih vida, kako vidijo osebe s posamezno boleznijo. Vse to mora delovati v realnem času s čim manjšo zakasnitvijo. To znanje se lahko potem uporablja tudi pri načrtovanju različnih uporabniških vmesnikov. Za doseg cilja smo uporabili očala za navidezno resničnost Oculus Rift, spletni kameri za stereo prikaz in razvili namensko programsko opremo. Rešitev zajema dve aplikaciji: aplikacijo za zajem slike kamer in simulacijo boleznih ter aplikacijo za upravljanje nastavitve prikaza boleznih. Za zajem slik ter implementacijo posameznih boleznih smo uporabljali knjižnico EmguCV, ki je C# vmesnik za knjižnico

OpenCV, ki je spisana v jeziku C++. Implementirali smo bolezni barvna slepota, tunnelski vid, retinopatija, dioptrija ter degeneracija rumene pege.


2. IMPLEMENTACIJA SIMULACIJ BOLEZNI VIDA

2.1. Priprava okolja

Osnovna naprava za simulacijo so Oculus Rift očala. To so očala, ki so namenjena potopitvi v virtualno resničnost. So prva nizkocenovna očala te vrste na tržišču. Oculus Rift je v osnovi sestavljen iz dveh malih LCD zaslonov ter leč, tako da pričara pravo 3D izkušnjo. Vsebuje tudi giroskop, merilec pospeškov ter magnetometer, kar omogoča zaznavanje obračanja v vse smeri. Oculus Rift kot vhodno sliko sprejme sliko, ki je sestavljena iz dveh slik, ki sta ena ob drugi ter vsaka zaseda točno polovico slike. Sliki morata biti ustrezno zamaknjeni, saj le tako dobimo ob gledanju pravi 3D občutek. Oculus nato vzame levo polovico slike za levo oko ter desno polovico za desno oko.

Za zajem slike smo uporabili Logitech HD Webcam C310 kameri z dodatnimi lečami za povečanje vidnega kota kamere. S 3D tiskalnikom smo naredili tudi ustrezna nosilca za kameri. Za prenos slike v Oculus Rift ter samo izvedbo simulacije smo uporabili razvojno okolje Unity [3], saj je Unity že optimiziran za delo z Oculus Riftom.

Unity omogoča, da za teksture objektov (sliko, ki se prikaže na objektih) uporabimo poljubne skripte, ki so napisane v jeziku C# [4]. Tako smo smo na enostaven način implementirali zajem slik iz kamere ter simulacije bolezn vid (Slika 1).



Slika 1: Zajem slik iz kamere.

2.2. Barvna slepota

Barvna slepota je nezmožnost zaznavanja vseh ali le nekaterih barv. Barvna slepota je lahko dedna in se prenaša s kromosomom X ali kromosomom 7, lahko pa se pojavi zaradi poškodbe možganov, živcev in očesa, ali izpostavitve kemikalijam. Poznamo več različnih oblik barvne slepote (Slika 2), v našem projektu smo implementirali protanopijo, devtranopijo, tritanopijo, protanomaliijo, devtranomalijo ter tritanomalijo [5, 6, 7].




Slika 2: Z leve proti desni: dojetanje barv brez barvne slepote, z protanopijo ter tritanopijo.

Osnovna ideja pri implementaciji je, da se po slikovnih elementih slike sprehodimo čez sliko ter vsakemu elementu nastavimo ustrezno barvo ter na ta način simuliramo različne barvne slepote.

Pri določeni barvni slepoti se manjkajoča barva nadomesti s preostalima dvema barvama. Na spletu smo našli nekaj osnovnih preslikav barv za simulacijo osnovnih barvnih slepot [8]. Podatke smo normalizirali tako, da je vsota vrednosti znotraj posamezne barve znašala točno 1 ter si rezultate shranili v seznam matrik velikost 3×3 . Nato smo se sprehodili čez vse slikovne elemente slike in nastavili novo vrednost posamezne komponente barve tako, da smo jo sestavili iz vseh treh barv (rdeče, modre in zelene) glede na transformacijsko matriko.

Slika 3 prikazuje rezultat simulacije za protonopijo ter tritanopijo.



Slika 3: Simulacija protonopije (levo) ter tritanopije (desno).
(Slika 1 prikazuje isto situacijo brez simulacije barvne slepote.)

2.3. Tunelski vid

Tunelski vid ali izguba perifernega vida je bolezen, ki zmanjša zorni kot vida (Slika 4). Periferni vid uporabljamo za zaznavanje objektov, ki niso v središču našega pogleda. Glavna razloga za to bolezen sta glavkom ter odstop mrežnice. Pri glavkomu je poškodovan vidni živec na mestu izhoda iz očesa, ki skrbi za prenos slike [9].



Slika 4: Različne stopnje tunelskega vida.

Simulacijo smo implementirali na način, da smo na začetku simulacije oz. pri zamenjavi ločljivosti zajema slike v aplikaciji za upravljanje simulacije izračunali razdaljo od središča slike za vsako slikovno točko. To smo izračunali ločeno za levo ter desno sliko, saj smo le tako lahko zagotovili ustrezno sliko na obeh očesih.

Nato smo si pripravili še tri spremenljivke, ki se bodo nastavljale preko aplikacije za upravljanje simulacije:

- Polmer, ki nam pove polmer velikosti vidnega polja v slikovnih točkah.
- Gradient, ki nam pove, kako hiter je prehod iz vidnega polja v nevidno polje.
- Prozornost, ki nam pove, kolikšna je še prepustnost slike na nevidnem polju.

Tunelski vid smo nato implementirali tako, da smo za vsako točko preverili, če je polmer v trenutni točki večji kot polmer iz nastavitvev, nato pa nastavili potrebne spremembe.

Slika 5 prikazuje dve različni simulaciji tunelskega vida.



Slika 5: Simulacija tunelskega vida.
(Slika 1 prikazuje isto situacijo brez simulacije tunelskega vida.)

2.4. Retinopatija

Retinopatija oz. diabetična retinopatija se pojavi zaradi mašenja kapilar v mrežnici. Kapilare se najprej le razširijo, čez čas pa tudi počijo in tako povzročijo pikčaste in lisaste krvavitve na mrežnici. V začetku oseba nima težav z vidom, težave se pojavijo z napredovanjem obolenja, ko se začnejo razraščati nove kapilare in tedaj oseba vidi črne

lise (Slika 6). Krvavitve se lahko pojavijo tudi v steklovini, kar lahko v končni fazi pripelje do slepote [10, 11].



Slika 6: Vid osebe z retinopatijo.

Pri retinopatiji se osebi prikazujejo črne pege oz. pike, ki lahko malo prepuščajo svetlobo ali pa popolnoma zabrišejo del slike ter so lahko večje ali manjše ter različnih oblik. Zaradi vseh teh različnih sprememb smo retinopatijo implementirali na način, da smo uporabili predlogo, ki je črno-bela slika, ki prikazuje, kje je okvara vida ter v kakšni meri.

Takoj pri zagonu oziroma pri spremembi nastavitvev, se v pomnilnik shrani slika, ki se uporablja kot predloga retinopatije. Nato se sprehodimo čez osnovno sliko ter primerjamo slikovne točke na istih mestih. Če slikovna točka v predlogi ni bela, potem trenutno slikovno točko potemnimo za toliko kot je temna slikovna točka predloge.

Slika 7 prikazuje primer simulacije retinopatije.



Slika 7: Primer retinopatije.

2.5. Dioptrija

Ločimo dve vrsti dioptrije: kratkovidnost (myopia) [12] in daljnovidnost (hyperopia) [13]. Obe se pojavita zaradi nepravilne oblike leče.

Pri kratkovidnosti se svetlobni žarki zberejo že pred mrežnico in se ob zadetku v mrežnico že razhajajo. Osebe s kratkovidnostjo vidijo dobro na blizu ter slabo na daleč. Take osebe morajo nositi razpršilno oz. konkavno lečo. Pri daljnovidnosti se svetlobni žarki zberejo šele za mrežnico. Daljnovidne osebe slabo vidijo na blizu. Osebe z daljnovidnostjo morajo nositi zbiralno oz. konveksno lečo.

Za implementacijo dioptrije smo rabili podatek o globini, saj smo le na ta način lahko zameglili oddaljene/bližnje predmete za implementacijo dioptrije. Zaradi tega smo za zajem slik ter delo s slikami uporabili knjižnico OpenCV oz. njen vmesnik EmguCV [14]. OpenCV že vsebuje metodo za izračun globine.

Za uspešno pridobivanje podatka o globini ter simulacijo dioptrije so bili potrebni naslednji koraki:

- Zajem kalibracijskih slik.
- Kalibracija kamer, s čimer smo zagotovili, da sta obe kameri vzporedni.
- Izračun globinske slike iz kalibriranih kamer.
- Simulacija dioptrije.

Zajem kalibracijskih slik ter kalibracija se izvajata v aplikaciji za upravljanje simulacije, izračun globine ter simulacija dioptrije pa v simulacijski aplikaciji.

Po kalibraciji kamer ter izračunani globinski sliki smo lahko implementirali tudi dioptrijo. Za zajeto sliko iz kamere si pripravimo več slik z različno intenzivno zameglitvijo slike in si slike zapomnimo. Nato glede na izbrano vrsto dioptrije, ki je lahko kratkovidnost ali daljnovidnost ter podatkom o globini na posamezni slikovni točki, uporabimo slikovno točko iz ustrezno zamegljene slike. Na ta način se nam lahko zameglijo le oddaljeni oz. le bližnji predmeti (Slika 8).



Slika 8: Simulacija kratkovidnosti in daljnovidnosti.

Poleg izbire dioptrije smo pri implementaciji upoštevali še naslednje nastavitve:

- Intenzivnost, ki nam pove največjo stopnjo zamegljenosti oddaljenega/bližnjega predmeta.
- Razdaljo, s katero lahko kontroliramo pri kateri razdalji se začne/konča dioptrija.

2.6. Degeneracija rumene pege

Degeneracija rumene pege oz. degeneracija makule je bolezen, ki prizadene območje rumene pege na mrežnici. Rumena pega vsebuje največ čepkov ter paličic in nam omogoča oster vid. Degeneracija rumene pege se pojavlja predvsem pri starejših ljudeh. Pri degeneraciji rumene pege oseba v začetnem stadiju vidi le popačeno valovito sliko, kasneje pa se mu na tem mestu pojavi še črna pega (Slika 9) [15].



Slika 9: Napredovanje degeneracije rumene pege in retinopatije.


Tako smo morali pri implementaciji degeneracije rumene pege najprej poškodovano območje narediti valovito ter nato še zatemniti območje.

Odločili smo se za podoben pristop kot pri retinopatiji, kjer smo uporabili sliko za predlogo, saj se lahko tudi degeneracija rumene pege razlikuje od osebe do osebe, pripravljeno pa smo imeli tudi že zatemnitev poškodovanega območja. Predloga je sestavljena enako kot pri retinopatiji, le da jo tukaj uporabljamo tudi za preslikavo valovite slike na poškodovano območje.

Za pripravo valovitega območja smo se odločili za uporabo senčilnikov (angl. shaders). Senčilniki so programi, ki se uporabljajo predvsem za prikaz svetlobe ter senc pri obdelavi slike, lahko pa se uporabljajo tudi za posebne efekte. V našem primeru smo s pomočjo senčilnikov implementirali valovito sliko tako, da smo s pomočjo sinusne funkcije zamikali posamezne slikovne točke slike. Za vsako točko se glede na njeno pozicijo ter velikost vala iz nastavitvev izračuna nova pozicija. Tako smo celotno sliko spremenili v valovito sliko ter si jo shranili za kasnejšo uporabo.

Ko smo imeli pripravljeno valovito sliko ter predlogo oblike bolezni in zatemnitve, smo na vsakem mestu, kjer v predlogi ni bila bela barva, obstoječo slikovno točko zamenjali s slikovno točko iz valovite slike. Nato smo vpeljali še spremenljivko intenzivnosti, ki v

odstotkih pove v kolikšni meri je potrebno zatemniti sliko, kjer v predlogi ni bela barva (Slika 10).



Slika 10: Simulacija različnih stopenj degeneracije rumene pege.

3. KVALITATIVNA OCENA RAZVITEGA SISTEMA

Preliminarno oceno našega sistema smo dobili, ko smo se dogovorili za sestanek s kolegi z zagrebške Fakultete za grafiko, ko so prišli na simpozij v Slovenijo. Bili so tako navdušeni nad simulacijami bolezni vida, da so nas povabili, da demonstriramo naš sistem v Zagrebu.

Tako smo kvalitativno ocenitev razvitega sistema izvedli z demonstracijo na zagrebški Fakulteti za grafiko, v Laboratoriju za uporabniško izkušnjo. Na demonstracijo so povabili kolege iz Fakultete za elektrotehniko in računalništvo, Pedagoške fakultete ter Fakulteta za grafiko Univerze v Zagrebu ter predstavnike nekaterih podjetij. Demonstracije se je udeležilo 20 oseb.

Vsaki osebi smo prikazali simulacije bolezni vida po vnaprej pripravljenem scenariju:

- Barvni slepoti protanopijo ter tritanopijo.
- Tunelski vid.
- Retinopatijo.
- Za zabavo smo demonstrirali tudi spremembo dojemanja barv po meri, z zamenjavo modrega in rdečega barvnega kanala smo namreč ljudje postali modrokožči in tako bili podobni avatarjem oz. smrkcom.

Simulacije so bile zelo dobro sprejete. Skoraj vsi uporabniki so dali pozitiven odziv. Zanimiv je bil odziv kolegice, ki se raziskovalno ukvarja z boleznimi vida: „Zdaj res končno vem, kako se počutijo in vidijo ti ljudje“. Čeprav je uporabnike sprva zmotila slabša ločljivost Oculus Rift očal, eno izmed oseb je obšla tudi manjša slabost ob uporabi, so ostali komentarji potrjevali smiselnost nadaljnega razvoja in uporabe takšnega sistema.

Zadovoljni so bili nad odzivom simulacije, saj skoraj ni bilo zaznati zakasnitve. Med samo simulacijo so imeli občutek realnosti, kot da je takšen svet v resnici pred njimi, kot da imajo posamezno bolezen vida. Cilj popolne potopitve v takšen navidezni oziroma obogaten svet je tako bil dosežen. Zapisana ocena sistema je še toliko zanesljivejša, ker se veliko oseb, ki so se udeležili demonstracije, raziskovalno ukvarja z boleznimi vida in poznajo ostala simulacijska orodja za te bolezni.

Kvalitativni eksperiment je tako potrdil, da je naša simulacija z očali Oculus Rift uporabna za simulacijo bolezní vida. Za še boljšo simulacijo bolezní je potrebno nadgraditi očala na novejšo različico 2, saj imajo slednja veliko boljšo ločljivost.

4. ZAKLJUČEK

Zadani cilj smo uspešno dosegli: pripravili smo aplikacijo, ki nam v realnem času simulira pet različnih bolezní vida ter omogoča tudi njihovo sočasno simulacijo. Problem, ki še vedno ostaja, je ločljivost Oculus Rift očal. Potrebna je tudi dodatna optimizacija algoritmov, kar pa ni tako pereč problem.

Z uporabo razvitega sistema smo ugotovili, da Oculus Rift očala lahko uporabljamo pri simulaciji bolezní vida, vendar z določenimi omejitvami. Glavna omejitev je seveda ločljivost slike očal. Naslednja omejitev je strojna, saj je pri simulaciji visoke kvalitete slike potrebna velika procesorska ter grafična moč za hitro simulacijo bolezní.

V prihodnosti bo sledila še primerjava razvitega sistema z Zimmerman paketom, ki se prav tako uporablja za simulacijo različnih bolezní vida.

Razvita aplikacija ima še veliko možnosti za izboljšave in nadgradnje:

- Dodamo lahko še veliko bolezní.
- Dodamo lahko ločene simulacije za posamezno oko.
- Lahko jo nadgradimo tako, da bi bila kompatibilna z novo verzijo Oculus Rift očal ter s tem zagotovimo boljšo uporabniško izkušnjo pri uporabi.
- Dodatno lahko optimiziramo simulacije tako, da ne bo potrebna tako velika procesorska ter grafična moč za izvajanje simulacij.
- Lahko jo uporabimo za obogatitev resničnosti v kakšnem drugem scenariju simulacije.

5. LITERATURA

1. http://www.optika-pirc.com/?menu_item=sl_zgradba
Očesno zrklo.
2. http://projekti.gimvic.org/2003/2a/timko_barvila/TIMKO_Anja/html/kakoZazBarva.htm
Kako zaznavamo barve?
3. <http://docs.unity3d.com/Manual/>
Unity manual.
4. S. Uranič (2010), *Visual C# .NET*, Pasadena, Slovenija.
5. http://www.optika-pirc.com/?menu_item=sl_barvnaSlepota
Barvna slepota.
6. <http://www.color-blindness.com/wp-content/documents/Color-Blind-Essentials.pdf>
D. Flück, *Color blind essentials*.
7. B. Wong (2011), Points of view - Color blindness, *Nature methods*, 8(6): str. 441-450.

8. <http://web.archive.org/web/20081014161121/http://www.colorjack.com/labs/colormatrix/>
ColorMatrix
9. <http://www.allaboutvision.com/conditions/peripheral-vision.htm>
Peripheral vision loss.
10. http://en.wikipedia.org/wiki/Diabetic_retinopathy
Diabetic retinopathy.
11. http://www.optika-pirc.com/?menu_item=sl_retinopatija
Diabetična retinopatija.
12. <http://www.allaboutvision.com/conditions/myopia.htm>
Myopia (nearsightedness).
13. <http://www.allaboutvision.com/conditions/hyperopia.htm>
Hyperopia (farsightedness).
14. S. Shi (2013), *Emgu CV Essentials*, Packt publishing, Velika Britanija.
15. http://en.wikipedia.org/wiki/Macular_degeneration
Macular degeneration.

PREKRIVANJA V KONTEKSTU OBOGATENE RESNIČNOSTI

Tadej Vodopivec^{1,2}, Peter Peer¹

¹Fakulteta za računalništvo in informatiko, Univerza v Ljubljani

²Fakultät für Informatik und Biomedizinische Technik, TU Graz

E-pošta: tadej@vodopivec.net, peter.peer@fri.uni-lj.si

POVZETEK: *Prekrivanja so bistvenega pomena za kvaliteto vstavitve navideznih predmetov v resnični svet, saj se pri obogateni resničnosti ti predmeti izrisujejo na sliko oziroma tik pred očmi uporabnika. Zaradi tega je potrebno pravilno ugotoviti, kateri deli predmetov so iz njegove perspektive zakriti in tistih delov ne izrisati. V tem članku je na kratko opisana obogatena resničnost, zaznavanje prekrivanj in principi izrisa predmetov, na koncu pa je predstavljen en izmed možnih pristopov za segmentacijo rok.*

1. UVOD


Obogatena resničnost je skupek tehnologij, ki z uporabo iluzij daje občutek, da se v prostoru nahajajo stvari, ki jih tam dejansko ni. Je mešanica med resničnim svetom in navidezno resničnostjo, kjer resnični svet tvori samo kontekst, ali pa tudi bistvo, navidezna resničnost pa se uporablja za dodajanje navideznih elementov. Obogatitve je mogoče izvesti v realnem času ali pa pri kasnejši obdelavi, pogled je lahko prvoosebni ali pa je predmet obogatitve predhodno zajeti video-posnetek.

Pri dodajanju navideznih predmetov na sliko je pomembno, da so predmeti vstavljeni prepričljivo, pri čemer imajo prekrivanja zelo veliko vlogo.

2. OBOGATENA RESNIČNOST

Zanimanje za obogateno resničnost se je bistveno povečalo v zadnjih letih, kar je razvidno tudi iz zgodovine iskanja po ključni besedi besedne zveze »augmented reality« na Google-ovem iskalniku, kot je razvidno iz grafa na sliki 1. Raziskave, povezane z obogateno resničnostjo, potekajo na področju diagnosticiranja, proizvodnje, servisiranja, kot tudi uporabe v zabavni industriji.

Pri obogateni resničnosti računalnik v uporabnikovo vidno polje vstavi dodatne vizualne informacije, ki obogatijo uporabnikov pogled na svet. Namesto, da se celoten resnični svet nadomesti z navideznim, kot se to dogaja pri navidezni resničnosti, obogatena resničnost omogoča, da se uporabnik premika po resničnem svetu, s tem da računalnik nudi zelene dodatne grafične informacije oziroma pomoč.



Slika 1: Prikaz zgodovine iskanja pojma »augmented reality« v Google-ovem iskalniku. Na horizontalni osi je prikazan datum, na vertikalni osi pa normalizirana relativna pogostost pojavljanja, kjer ima največja pogostost vrednost 100. Orodje Trends ne omogoča prikaza natančnih podatkov.

Za to, da uporabnik sprejme navidezne predmete kot del sveta okoli sebe, morajo biti le-ti dovolj prepričljivo vstavljeni v ta svet. Predmeti morajo med sabo in na realni svet vplivati na dva načina: fizično in vizualno. S fizičnim vplivom je mišljeno, da predmeti upoštevajo fizikalne zakonitosti, se premikajo zvezno, zaznavajo trke in se ne nahajajo na istem mestu kot nek drug predmet. Z vizualnim vplivom je mišljeno, da se predmeti pravilno prikažejo. Sem tako spadajo pravilni odsevi, osvetlitev, sence in seveda prekrivanja.


Pomembno se je zavedati, da je interakcija povsem enosmerna, saj mora resnični svet vplivati na navideznega, navidezni pa ne more vplivati na resničnega.

3. PREKRIVANJA

Do prekrivanj pride, ko bi morala dva predmeta v vidnem polju biti vidna na istem mestu, a je en predmet bližje opazovalcu kot drugi. Bližji predmet v tem primeru prekrije bolj oddaljenega, ki ga je videti le delno ali pa sploh ne. V realnem svetu so prekrivanja nekaj vsakdanjega in o njih praktično ne razmišljamo. Na njih smo tako navajeni, da si svet brez njih le s težavo predstavljamo. Prekrivanja nam dajo zelo dobro informacijo o tem, kje se predmeti nahajajo in kako oddaljeni so od nas. Brez upoštevanja prekrivanj izrisanega predmeta ne dojemamo kot del okolja, ali pa si predstavljamo, da le-ta lebdi nekje pred kamero (slika 2).

3.1. Zaznavanje prekrivanj

Prekrivanja se lahko zaznava na več načinov. Najenostavnejši je, če natančno vemo, kaj je del ozadja in kaj ospredja oziroma če imamo kontrolo nad resničnim svetom do te



Slika 2: Levo: primer navideznega predmeta na mizi. Desno: Primer istega predmeta iz drugega zornega kota, ko bi moral biti skrit za resničnim predmetom (namizno lučko).

mere, da lahko to razliko naredimo očitno. Primer takega zaznavanja prekrivanja je t.i. zeleni zaslon [1], ki se uporablja v filmski industriji in na televiziji. V tem primeru se ena barva, za katero poskrbimo, da se v ospredju ne uporablja, označi za barvo ozadja in se je v končni sliki ne izriše. Takšno zaznavanje je lahko zelo natančno in računsko nezahtevno.


Drugi način je z uporabo modela resničnega predmeta, ki je lahko vnaprej znan [2], ali pa se ga zgradi v realnem času z uporabo orodij kot na primer DTAM (Dense Tracking and Mapping in Real-Time) [3] oziroma SLAM (Simultaneous Localization and Mapping) [4]. Ta orodja na podlagi slike iz kamere, ki se premika, zgradi točkovni oblak videnega (slika 3). Prednost take izgradnje modela je, da se ga lahko zgradi tudi za nikoli prej videne predmete poljubnih oblik. Meje, ki so zaznane na podlagi takega modela, lahko vsebujejo velike napake, saj imajo točke v točkovnem oblaku veliko šuma, zaradi česar je izdelani model le groba ocena oblike.

Tretji način je z uporabo RGB-D kamere, ki poleg barve vsake točke na sliki vsebuje tudi podatek o oddaljenosti te točke. Primer take kamere je Kinect [5] podjetja Microsoft.

3.2. Izris navideznih predmetov

Ko poznamo vrstni red predmetov po oddaljenosti in njihove meje, je potrebno predmete pravilno izrisati. V primeru, ko se zakrivata dva resnična predmeta, je njuno prekrivanje pravilno zajeto že na sliki s kamere in dodatno delo ni potrebno. V primeru, da se zakrivata dva navidezna predmeta, je velikokrat dovolj, če se predmeta izriše v vrstnem redu po oddaljenosti, kjer se najprej izriše predmet, ki je bolj oddaljen in nato predmet, ki je bližje. Tak princip delovanja se imenuje slikarjev algoritem [6]. Na ta način bo del oddaljenega predmeta, ki mora biti zakrit, nadomeščen z delom predmeta, ki ga zakriva. Algoritem ni optimalen z vidika izrabe virov, a je učinkovit z vidika vizualizacije.

Ko navidezni predmet zakriva resničnega, se lahko navidezni predmet izriše direktno na ekran na mesto, kjer bi moral biti izrisan. Takšna vstavitev predmeta je najenostavnejša in ne zahteva manipuliranja s prikazom.



Slika 3: Primer točkovnega oblaka, narejenega po postavitvi iz slike 2.

Poseben primer nastopi, ko resnični predmet zakriva navideznega. Tukaj pride do težav, saj so navidezni predmeti v večini primerov izrisani uporabniku tik pred očmi, ali direktno na sliki, tudi če bi se morali nahajati dlje, ali sploh ne bi smeli biti vidni. Za občutek, da se predmeta pravilno prekrivata, mora biti resnični predmet v celoti viden, navidezni pa le na tistem delu, ki ga ne prekriva noben drug predmet. To se doseže tako, da se prekritega dela navideznega predmeta ne izriše. Pri takem izrisu je zelo pomembno, da je meja, kjer je ta predmet zakrit, čim bolj natančno znana, saj je že zelo majhno odstopanje takoj opazno in škoduje vtisu, da se predmet nahaja na določenem mestu. Primerjava izrisa, ko je meja med navideznim in resničnim predmetom napačno in pravilno zaznana, je viden na sliki 4.

4. SEGMENTACIJA ROK ZA OBOGATENO RESNIČNOST

Pomemben primer uporabe obogatene resničnosti je izris navideznih predmetov v realnem času na očalih, ki jih uporabnik nosi. Takšen sistem so prvič razvili pri Boeingu [8] in je bil namenjen pomoči v proizvodnji. Pri nošenju očal je vidno polje uporabnika enako normalnemu, interakcija uporabnika s svetom pa poteka z rokami. Uporabnik ima roki velik del časa pred sabo in tako v svojem vidnem polju. Ker so roke del njegovega telesa, so praviloma zelo blizu in večino časa prekrivajo vsaj del slike.

Zaradi težavnosti zaznavanj prekrivanj med resničnimi in navideznimi predmeti, potenciala uporabe očal za obogateno resničnost in pogostosti uporabnikovih rok v vidnem polju, smo se odločili, da bomo razvili algoritem za segmentacijo rok.

Ena od možnih iztočnic za razločevanje rok je barva kože [9], na žalost pa v praksi to še ni dovolj za oceno silhuete rok z dovoljšno natančnostjo za prepričljivo integracijo.

Osnovna ideja je z uporabo širokokotne kamere zajeti posnetke rok pred različnimi ozadji in na podlagi teh slik ročno izdelati monokromatske bitne slike, ki bodo služile kot učna množica za učenje konvolucijske nevronske mreže [10].



Slika 4: Primer napake pri zaznavi natančne meje med navideznim in resničnim predmetom (navidezni Darth Vader je vstavljen v model labirinta v resničnem svetu) [7]. Levo: napačno zaznana meja, desno: izboljššan približek.

Na podlagi posnetkov in pripadajočih monokromatskih bitnih slik se prvi klasifikator nauči razlikovati med deli slike, ki ležijo na uporabnikovi roki od ozadja. Nadalje je ideja natrenirati verigo klasifikatorjev: vhodni podatki prvega klasifikatorja bodo le posnetki, medtem ko bodo naslednji klasifikatorji v verigi imeli dostop tudi do rezultatov segmentacije prejšnjih klasifikatorjev. Če bo potrebno, bomo implementirali sistem lestvice, kjer se bo ločljivost progresivno povečevala. Vsak klasifikator bo ocenil segmentacijo na višji ločljivosti, dokler ne bo zadnji klasifikator v vrsti vrnil klasifikacijo pri polni ločljivosti.

Na ta način se ne bo povečala le hitrost, ampak bo že prvi klasifikator ocenil grobo območje ozadja in s tem preprečil velike napake, medtem ko bodo naslednji klasifikatorji postopoma vedno natančneje definirali meje in s tem preprečevali lokalne napake.

Drugi pristopi k segmentaciji rok vključujejo predpogoj, da je kamera statična in se roke zaznava na podlagi njihovega gibanja, segmentacijo na podlagi globine pridobljene z RGB-D kamere, ali samo na podlagi barve. Vsak pristop ima svoje prednosti in slabosti, noben pa ne ponuja natančne segmentacije za vsakodnevno rabo.

5. ZAKLJUČEK

Prekrivanja so bistvenega pomena pri razumevanju položaja predmetov, njihova natančna detekcija in pravičen izris pa pripomoreta k občutku, da je predmet del sveta v katerem se nahaja. V članku smo predstavili problem prekrivanj v kontekstu obogatene resničnosti in nekaj primerov, kako se z njimi soočiti. Za pravičen prikaz je prekrivanja potrebno natančno zaznati in jih pravilno upoštevati pri izrisu. Prekrivanja so odvisna od zornega kota in perspektive opazovalca. Predstavili smo tudi pristop k segmentaciji rok, ki lahko pride do izraza, ko uporabnik uporablja očala za obogateno resničnost v realnem času.

Na področju detekcije prekrivanj je še veliko možnosti za izboljšave, saj so trenutne metode nezanesljive in računsko zahtevne.

LITERATURA

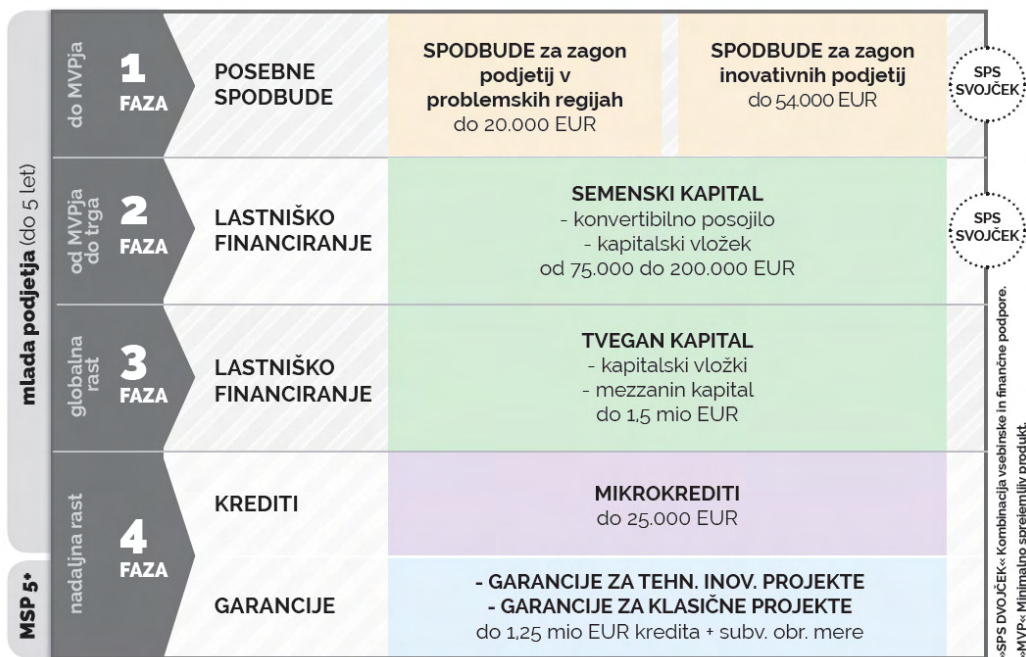
1. Shigeru Shimoda, Masaki Hayashi, and Yasuaki Kanatsugu, New chroma-key imagining technique with Hi-Vision background. *IEEE Transactions on Broadcasting* 35(4):357-361, 1989.
2. David E. Breen, et al. Interactive occlusion and automatic object placement for augmented reality. *Computer Graphics Forum*, Blackwell Science Ltd, 1996, pp. 11-22.
3. Richard A. Newcombe, Steven J. Lovegrove, and Andrew J. Davison. DTAM: Dense tracking and mapping in real-time. *International Conference on Computer Vision (ICCV)*, IEEE, 2011, pp. 2320-2327.
4. Jakob Engel, Thomas Schöps, and Daniel Cremers. LSD-SLAM: Large-scale direct monocular SLAM. *European Conference on Computer Vision (ECCV)*, Springer International Publishing, 2014, pp. 834-849.
5. Zhengyou Zhang. Microsoft kinect sensor and its effect. *MultiMedia* 19(2):4-10, IEEE, 2012.
6. James D. Foley, and Andries Van Dam. *Fundamentals of interactive computer graphics*. Vol. 2. Addison-Wesley, 1982.
7. Georg Klein, and Tom Drummond. Sensor fusion and occlusion refinement for tablet-based AR. *IEEE and ACM International Symposium on Mixed and Augmented Reality (ISMAR)*, IEEE, 2004, pp. 38-47.
8. Thomas P. Caudell, and David W. Mizell. Augmented reality: An application of heads-up display technology to manual manufacturing processes. *Proceedings of the Twenty-Fifth Hawaii International Conference on System Sciences*, Vol. 2, IEEE, 1992, pp. 659-669.
9. Xintao Li, et al. Hand Segmentation Based on Skin Tone and Motion Detection with Complex Backgrounds. *Proceedings of Chinese Intelligent Automation Conference*, Springer, 2013, pp. 105-111.
10. Dan C. Ciresan, et al. Flexible, high performance convolutional neural networks for image classification. *IJCAI Proceedings of International Joint Conference on Artificial Intelligence*, 2011, pp. 1237-1242.



Slovenski podjetniški Sklad (SPS) je javni finančni sklad v 100% lasti Republike Slovenije in je spodbujevalec razvoja mikro, malih in srednje velikih podjetij z ugodnimi finančnimi spodbudami.

Sklad bo v letu 2015 svoje produkte namenil dvema ciljnim skupinama podjetij:

- 1. MLADA PODJETJA (podjetja mlajša od 5 let)** spremljajo v vseh fazah razvoja – od zagona in priprave MVP – ja (minimalno sprejemljivega produkta) do preverjanja tržnega potenciala, vstopa in širitve na globalni trg ter globalno rast. Mladim podjetjem so namenjene naslednje finančne linije:
 - **posebne spodbude** so namenjene zagonskim podjetjem v prvi razvojni fazi, kjer podjetje razvija MVP. Gre za fazo t.i. »problem-solution fit« ali fazo t.i. »problem-rešitev«, v kateri mora podjetje dokazati, da je na trgu zaznalo problem ki ga je vredno reševati.
 - **lastniško financiranje** se izvaja v obliki semenskega kapitala v drugi razvojni fazi, kjer podjetje nadaljuje razvojne aktivnosti podjetja, ter v obliki tveganege kapitala kjer so podjetja že pripravljena na globalno rast.
 - **krediti in garancije** so namenjene mladim podjetjem v 4. razvojni fazi za tekoče poslovanje in nadaljnjo rast podjetja.
- 2. PODJETJA MSP5+ (podjetja starejša od 5 let)** pa so bolj ali manj primerna za sredstva 4. razvojne faze, ki že ustaljenemu podjetju omogočajo tekoče poslovanje in nadaljnjo rast podjetja ter se izvajajo v obliki **kreditov in garancij**.



Bodite pravočasno obveščeni: Prijavite se na e-novice Sklada, naložite si mobilno aplikacijo preko trgovine Play, ravno tako pa spremljajte razpise na spletni strani Sklada (www.podjetniskisklad.si) - ter na spletni strani Iniative start up (www.startup.si), ki mladim podjetjem zagotavlja še vsebinsko podporo.

