

SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

Goran Salamunićcar

DETEKCIJA KRATERA IZ DIGITALNIH TOPOGRAFSKIH SLIKA

DOKTORSKI RAD

Zagreb, 2012



UNIVERSITY OF ZAGREB
FACULTY OF ELECTRICAL ENGINEERING AND COMPUTING

Goran Salamunićcar

CRATER DETECTION FROM DIGITAL TOPOGRAPHY IMAGES

DOCTORAL THESIS

Zagreb, 2012

Doktorski rad je izrađen na Sveučilištu u Zagrebu, Fakultetu elektrotehnike i računarstva, Zavodu za elektroničke sustave i obradbu informacija.

Mentor: Prof.dr.sc. Sven Ločarić

Doktorska disertacija ima: 237 stranica

Disertacija br.:

Povjerenstvo za ocjenu i obranu doktorske disertacije:

1. Dr.sc. Slobodan Ribarić, redoviti profesor
   Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva
2. Dr.sc. Marko Subašić, docent
   Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva
3. Dr.sc. Tihomir Marjanac, izvanredni profesor
   Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet

Datum obrane disertacije: 24. travnja 2012.

SAŽETAK

Naslov: Detekcija kratera iz digitalnih topografskih slika.

Sažetak: U ovome radu predložena je nova metoda za detekciju kratera iz digitalnih topografskih slika. Rezultati su: (1) okruženje za razvoj i osnovno vrednovanje algoritama za detekciju kratera (CDA-ova) koja uključuje mjeru udaljenosti između kratera (u području: planetarna širina, planetarna visina, dijametar); (2) katalog za vrednovanje CDA-ova s 57633 kratera katalogiziranih bez korištenja CDA-ova te metodi za provjeru konzistentnosti i integraciju kataloga; (3) metoda za detekciju kratera koristeći detektor ruba i gradijent, izmijenjenu Houghovu transformaciju, morfometrijska mjerenja i analizu topografije te parametarskog prostora Houghove transformacije, podešavanje pomicanjem i kalibraciju; (4) metodologija za napredno vrednovanje CDA-ova korištenjem topografskih i optičkih slika, kontekstno temeljene metode za registraciju kratera između kataloga, interaktivne obrade kandidata za krater i registraciji u katalog; (5) poboljšanje detekcije kratera metodom interpolacije prilagođene obliku kratera, koja se pokazala učinkovita prilikom detekcije malih kratera iz topografija Marsa i Mjeseca; (6) dodatno poboljšanje detekcije kratera strojem s potpornim vektorima, čime se postiže bitno manje pogrešnih detekcija. Dodatni rezultati su najpotpuniji javno dostupni katalozi Marsa i Mjeseca s 132843 odnosno 64215 kratera te primjene za: topografiju Fobosa (katalog s 1102 kratera), vrednovanje laboratorijskih kratera, topografiju rekonstruiranu iz optičkih slika Mjeseca te topografije Venere (katalog s 345 kratera) i Zemlje (katalog s 24 kratera).

Ključne riječi: detekcija kratera, detektori ruba, Houghova transformacija, stroj s potpornim vektorima.

ABSTRACT

Title: Crater Detection from Digital Topography Images.

Abstract: This work proposes a new method for detection of craters from digital topography images. The results are: (1) a framework for development and basic evaluation of crater detection algorithms (CDAs), which includes a measurement definition for distances between craters (in longitude-latitude-diameter space); (2) a catalogue for evaluation of CDAs, which consists of 57633 craters catalogued without usage of CDAs, including methods for evaluation of consistency and for integration of catalogues; (3) a method for crater detection using edge detection and gradient, modified Hough transform, morphometry measurements and analysis of topography and parameter space of Hough transform, slip-tuning, and calibration; (4) methodology for advanced evaluation of CDAs using topography and image datasets, including a method for registration of craters between different catalogues based on context, interactive evaluation of crater-candidates and registration in catalogue; (5) an improvement of crater detection utilizing a Crater Shape-based interpolation method that proved to be efficient for the detection of very small craters from the topographies of Mars and the Moon; and (6) an additional improvement of crater detection using support vector machines, which considerably decreases false detections. The accompanying results are the most complete publically available catalogues for Mars and the Moon, with 132843 and 64215 craters, respectively, and applicability for: Phobos' topography (catalogue with 1102 craters), evaluation of laboratory craters, topography reconstructed from Lunar optical images, and topographies of Venus (catalogue with 345 craters) and Earth (catalogue with 24 craters).

Keywords: crater detection, edge detection, Hough transform, Supported Vector Machines.

PREDGOVOR

U ovom dijelu ukratko su opisani razlozi i okolnosti pod kojima je rad nastao, kao i kronološki slijed znanstvenih istraživanja provedenih prije i tijekom izrade doktorske disertacije.

Znanstvena istraživanja koja su prethodila ovoj doktorskoj disertaciji (Salamunićcar, 2004, 2009: prvi rad je primjenom slučajnih procesa u lunarnoj i planetarnoj znanosti pokazao da je na globalnu distribuciju kratera utjecalo nešto što je morao biti globalni fizikalni proces; drugi rad je topografsko-profilnim dijagramima pokazao da se taj globalni proces vremenom povlačio prema topografski sve nižim i nižim područjima) bila su ograničena relativno malim brojem kratera u tada dostupnim katalozima. To je bila osnovna motivacija za razvoj algoritma za detekciju kratera, odnosno za temu ove doktorske disertacije.

Nakon što je proučena tada dostupna literatura, primijećeno je da svaki novi rad ne daje samo novu metodu za detekciju kratera, nego i koristi neki novi način za vrednovanje učinkovitosti predložene metode. Čak i kada su se koristile relativno slične metode za vrednovanje, iste su bile primijenjene na različitim testnim podacima te su time rezultati ocijene bili praktički neusporedivi. Stoga je u prvom koraku napravljena okolina za objektivno vrednovanje algoritama za detekciju kratera, kako bi se koristila za razvoj metoda koje su opisane u ovome radu (Salamunićcar i Lončarić, 2008d).

Koristeći navedenu okolinu za razvoj algoritama za detekciju kratera, započet je rad na metodi za detekciju kratera iz topografskih slika Marsa s potencijalnom primjenom i na druge planete. Kako bi se pokazalo koliko prethodno nekatalogiziranih kratera je novo-razvijeni algoritam pronašao, odnosno koliki je njegov doprinos, bilo je potrebno napraviti detaljnu reviziju svih prethodno katalogiziranih kratera Marsa. Isti su bili dostupni kroz nekoliko prethodno ručno napravljenih kataloga. To je rezultiralo katalogom koji se kasnije koristio u vrednovanju algoritama za detekciju kratera (Salamunićcar i Lončarić, 2008e).

Ovim su se ostvarili svi preduvjeti rada na metodi za detekciju kratera iz topografskih slika Marsa. Sama metoda (Salamunićcar i Lončarić, 2010b) temelji se na detekciji ruba i gradijentu, izmijenjenoj Houghovoj transformaciji, morfometrijskim mjerenjima te analizi topografije i parametarskog prostora Houghove transformacije, podešavanju pomicanjem i kalibraciji. Novom metodom pronađeno je i katalogizirano toliko prethodno nekatalogiziranih kratera da se ukupni broj katalogiziranih kratera gotovo pa udvostručio.

Nakon što je nova metoda za detekciju kratera već bila objavljena, u prethodno napravljeni katalog integriran je nešto manje potpun katalog koji je rezultat metode za detekciju kratera iz topografskih slika na kojoj je radila jedna druga grupa znanstvenika. Analizom tog kataloga i kataloga ovoga rada, odnosno usporedbom metode ovoga rada za detekciju kratera i metode koja je rezultirala tim katalogom, došlo se do zaključka da vrednovanje koje osigurava početna okolina za razvoj algoritama za detekciju kratera više nije dovoljno dobro kako bi se kvalitativno mogle usporediti sve bitne značajke ove dvije metode. Te dvije metode važne su jer su u to vrijeme bile jedine koje su pokazale da mogu obraditi podatke cijelog planeta te kao rezultat napraviti globalan katalog kratera. To je vodilo do novih istraživanja metodologije za vrednovanje algoritama za detekciju kratera, koja su napravljena u suradnji sa znanstvenicima Pedrom Pinom, Lourençom Bandeirom i Joséom Saraivom s Tehničkog sveučilišta u Lisbou iz Portugala (Salamunićcar et al., 2011a).

Prvi najvažniji dodatni doprinos u daljnjem razvoju metode za detekciju kratera je u primjeni interpolacije prilagođene obliku kratera. Ovim istraživanjem pokazano je da suprotno očekivanjima, interpolacija ulaznih topografskih podataka i određenih međurezultata može znatno poboljšati sveukupna svojstva detekcije, što se posebno očituje kod malih kratera definiranih s malim brojem

slikovnih elemenata. Također, u vrijeme razvoja metode interpolacije postali su dostupni i topografski podaci za Mjesec u otprilike istoj horizontalnoj rezoluciji kao što su i prethodno bili dostupni za Mars. To je bila dodatna motivacija da se i sama metoda za detekciju kratera, poboljšana interpolacijom, uz katalogizaciju kratera na Marsu koristi i za katalogizaciju kratera na Mjesecu. Navedeno je rezultiralo trenutno najpotpunijim javno dostupnim katalozima ova dva planetarna tijela. Ova istraživanja napravljena su u suradnji sa znanstvenikom Erwanom Mazaricom s Massachusetts Institute of Technology iz SAD-a (Salamunićcar et al., 2011f).

Drugi najvažniji dodatni doprinos u daljnjem razvoju metode za detekciju kratera je u primjeni strojnog učenja korištenjem stroja s potpornim vektorima. Primjene metoda razvijenih u ovome radu su: u izradi najpotpunijih javno dostupnih kataloga kratera Marsa, Mjeseca i Fobosa, vrednovanju laboratorijskih kratera, detekciji kratera iz topografskih slika dobivenih iz optičkih te detekciji kratera iz topografskih slika Venere i Zemlje.

Znanstvena istraživanja provedena prije izrade doktorske disertacije sveukupno su rezultirala objavom 2 rada u znanstvenim časopisima (Salamunićcar, 2004, 2009), koji su bili motivacija za temu ove doktorske disertacije. Znanstvena istraživanja provedena tijekom izrade doktorske disertacije sveukupno su rezultirala objavom 30 radova na znanstvenim konferencijama (29 navedenih u ovoj doktorskoj disertaciji te novoobjavljen rad: G. Salamunićcar, S. Lončarić, "Crater Detection from Venus Digital Topography and Comparison with Martian and Lunar Craters.", *43rd Annual Lunar and Planetary Science Conference – 43rdLPSC*, NASA LPI, Houston, USA, March 2012, no. 1159. pp. 1-2), jednim poglavljem u knjizi (G. Salamunićcar, S. Lončarić, chapter "Crater Detection Algorithms: A Survey of the First Decade of Intensive Research" in book B. Veress, J. Szigethy (Eds.), "Horizons in Earth Science Research. Volume 8", Nova Science Publishers, New York, USA, 2012, ISBN: 978-1-61942-933-8, accepted.) i 5 radova u znanstvenim časopisima (Salamunićcar i Lončarić, 2008d, 2008e, 2010b; Salamunićcar et al., 2011a, 2011f), a dosad su citirani u 39 radova gdje autor ove doktorske disertacije nije jedan od koautora.

ZAHVALA

Puno se zahvaljujem: mentoru Svenu Ločariću za sveukupni rad koji je rezultirao s 5 zajedničke publikacije u znanstvenim časopisima, jednim poglavljem u knjizi i 30 zajedničkih publikacije na znanstvenim konferencijama te za pokrivanje troškova registracije na konferencijama *38th COSPAR* i *42nd LPSC* iz sredstava projekta *Inteligentne metode obrade i analize slika* (036-0362214-1989); članovima povjerenstva za ocjenu i obranu doktorske disertacije Slobodanu Ribariću, Marku Subašiću i Tihomiru Marjancu za korisne prijedloge i motivaciju; Pedru Pini, Lourençu Bandeiri i Joséu Saraivi za doprinos radu na naprednoj evaluaciji algoritama za detekciju kratera koji je rezultirao publikacijom u znanstvenom časopisu i za doprinos radu na strojnoj detekciji i globalnom katalogu kratera na Fobosu; Erwanu Mazaricu za doprinos u pripremi topografskih i optičkih slika za Mjesec i radu na najpotpunijem globalnom katalogu kratera na Mjesecu koji je rezultirao publikacijom u znanstvenom časopisu; te posebno mojoj obitelji na pruženoj podršci, supruzi Ines, majci Višnji, sestri Emi, Vladi i baki Miri.

Također se želim zahvaliti: Dejanu Vinkoviću, Damiru Vučini, Mladenu Gomerčiću, Igoru Pehnecu, Marinu Vojkoviću, Tomislavu Hercigonji i Luči Karbonini za doprinos radu na laboratorijskim kraterima i njihovoj evaluaciji koristeći algoritme za detekciju kratera; Christianu Wöhleru i Arneu Grumpu za doprinos radu na automatiziranoj detekciji kratera na Mjesecu na temelju rekonstrukcije topografije iz Chandrayaan-1 M^3 slika; Zdravku Nežiću za reviziju preostalih kratera iz kataloga našeg prethodnog rada; Gregu Michaelu za reviziju jednog od objavljenih radova koja je znatno doprinijela tom radu; Hrvoju Novoselu i Hrvoju Kneževiću za doprinos radu na detektorima rubova; i Deanu Gržaniću, Mirku Karasu, Deanu Katušiću, Srđanu Katušiću, Milivoju Kovaču, Jadranku Luciću, Danijelu Mehiću, Domagoju Prelošćanu, Vedranu Primorcu, Nihadu Rizvanoviću, Bojanu Spasiću, Dariu Stilinoviću, Ljubici Šare i Draženu Zoriću za pružanje pristupa njihovim računalima koji su zajedno korišteni za izračunavanje optimalnih parametra za algoritam za detekciju kratera.

Zahvalan sam autorima kataloga kratera koje smo koristili, za dozvolu da možemo koristiti njihove podatke: za kataloge kratera na Marsu posebno Nadini G. Barlow, Janni Rodionovoj, Josephu M. Boycu, Ruslanu O. Kuzminu i Tomaszu F. Stepinskom; te za kataloge kratera na Mjesecu posebno Jonathanu McDowell i Janni Rodionovoj.

Svim ostalim koji ovdje nisu spomenuti, ali nisu niti zaboravljeni, također se najsrdačnije zahvaljujem na njihovom doprinosu ovom radu.

ACKNOWLEDGMENTS

Many thanks: to my mentor Sven Ločarić for overall work resulting with 5 joint publications in scientific journals, 1 book chapter and 30 joint publications on scientific conferences and for covering costs of registration for *38th COSPAR* and *42nd LPSC* conferences from project *Intelligent Image Processing and Analysis Methods* (036-0362214-1989); to the dissertation evaluation and defense committee members Slobodan Ribarić, Marko Subašić and Tihomir Marjanac for useful suggestions and motivations; to Pedro Pina, Lourenço Bandeira and José Saraiva for contributing to the work on advanced evaluation of crater detection algorithms resulting with publication in scientific journal, and for contributing to the work on machine detection and global catalog of Phobos craters; Erwan Mazarico for contributing to the preparation of datasets for the Moon and the work on the most complete global catalog of Lunar craters resulting with publication in scientific journal; and specially to my family for given support, wife Ines, mother Višnja, sister Ema, Vlado and grandmother Mira.

I would also like to thank: Dejan Vinković, Damir Vučina, Mladen Gomerčić, Igor Pehnec, Marin Vojković, Tomislav Hercigonja and Luči Karbonini for contributing to the work on laboratory craters and their evaluation using crater detection algorithm; Christian Wöhler and Arne Grump for contributing to the work on automatic detection of Lunar craters based on topography reconstruction from Chandrayaan-1 M^3 imagery; Zdravko Nežić for review of remaining craters from a catalogue from our previous work; Greg Michael for particularly helpful review of one of the papers; Hrvoje Novosel and Hrvoje Knežević for contributing to the work on edge detectors; and Dean Gržanić, Mirko Karas, Dean Katušić, Srđan Katušić, Milivoj Kovač, Jadranko Lucić, Danijel Mehić, Domagoj Prelošćan, Vedran Primorac, Nihad Rizvanović, Bojan Spasić, Dario Stilinović, Ljubica Šare, and Dražen Zorić for providing computers which was used for computation of optimal parameters for crater detection algorithms.

I am grateful to the compilers of the crater catalogues that we used, for permission to use their data: for Martian crater catalogues particularly to Nadine G. Barlow, Janna Rodionova, Joseph M. Boyce, Ruslan O. Kuzmin and Tomasz F. Stepinski; and for Lunar crater catalogues particularly to Jonathan McDowell and Janna Rodionova.

To all others not mentioned here but not forgotten I also express my deepest gratitude for their contribution to this work.

SADRŽAJ

1. UVOD 1
1.1. Motivacija za detekciju kratera iz topografskih slika 2
1.2. Struktura rada 4
2. PREGLED PODRUČJA I DOSADAŠNJIH ISTRAŽIVANJA 5
2.1. Uvod 6
2.2. Klasifikacija s obzirom na korištene podatke 10
2.3. Klasifikacija s obzirom na korištene metode 14
2.3.1. Podjela metoda s obzirom na korištenje detektora ruba 14
2.3.2. Podjela metoda s obzirom na korištenje Houghove transformacije 16
2.3.3. Podjela metoda s obzirom na korištenje strojnog učenja 16
2.4. Klasifikacija s obzirom na mogućnost obrade globalnih podataka 19
2.5. Klasifikacija s obzirom na vrednovanje rezultata 21
2.6. Zaključak 22
3. OKOLINA ZA RAZVOJ ALGORITAMA ZA DETEKCIJU KRATERA 23
3.1. Uvod 24
3.2. Početni referentni katalog s 17 582 kratera 25
3.3. Kriteriji za odabir topografskih slika Marsa za razvojni poligon 29
3.4. Mjera udaljenosti između kratera 30
3.5. Površina ispod F-ROC krivulje kao mjera za vrednovanje 32
3.6. Zaključak 34
4. I. KORAK: TEMELJNA METODA ZA DETEKCIJU KRATERA 35
4.1. Uvod 36
4.2. Predložena metoda 37
4.3. Modul 1: Detekcija ruba i analiza gradijenta 40
4.3.1. Iznos i smjer gradijenta 40
4.3.2. Izračunavanje iznosa gradijenta 41
4.3.3. Izračunavanje smjera gradijenta 43
4.3.4. Razlika u odnosu na klasične detekcije ruba 44
4.3.5. Zasebni pristup za Shen-Castanov detektor ruba 46
4.3.6. Zapis prilagođen daljnjim koracima obrade i višeprocesorskim sustavima 46
4.4. Modul 2: Izmijenjena Houghova transformacija 47
4.4.1. Osnovni principi Houghove transformacije 47
4.4.2. Poboljšanja korištenjem detekcije ruba s analizom gradijenta 49
4.5. Modul 3: Analiza morfometrije i parametarskog prostora 52
4.5.1. Mjerenje topografskog profila kratera 53
4.5.2. Određivanje odnosa dubine i dijametra 54
4.5.3. Mjerenje cirkularnosti u topografskoj slici 54
4.5.4. Mjerenje cirkularnosti u parametarskom prostoru 54
4.5.5. Detekcija i mjerenje ruba kratera 55
4.5.6. Detekcija i mjerenje centralnog uzvišenja kratera 55
4.5.7. Određivanja područja gdje je krater očuvan 55
4.6. Modul 4: Adaptivna korekcija vjerojatnosti 56

4.7. Modul 5: Podešavanje kandidata za kratere pomicanjem 57
4.8. Klasifikacija parametara i njihova zavisnost 58
4.9. Primjer za topografsku sliku Marsa 59
4.10. Zaključak 60

5. II. KORAK: POBOLJŠANJE DETEKCIJE KRATERA INTERPOLACIJOM PRILAGOĐENOM OBLIKU KRATERA 61
5.1. Uvod 62
5.2. Metoda za detekciju kratera temeljena na interpolaciji 63
5.3. Modul 6: Interpolacija prilagođena obliku kratera 65
5.4. Modul 7: Adaptivne korekcije s obzirom na radijus planetarnog tijela 68
5.5. Metoda za projekciju podataka i kratera 69
5.6. Primjer za topografsku sliku Mjeseca 71
5.7. Zaključak 72

6. III. KORAK: POBOLJŠANJE DETEKCIJE KRATERA STROJEM S POTPORNIM VEKTORIMA 73
6.1. Uvod 74
6.2. Metoda za detekciju kratera zasnovana na učenju 75
6.3. Modul 8: Učenje strojem s potpornim vektorima 77
6.3.1. Osnovni principi stroja s potpornim vektorima 77
6.3.2. Učenje o oblicima kratera 78
6.3.3. Učenje o geološkom kontekstu kao dodatak učenju o kraterima 79
6.3.4. Dohvat značajki strojnog učenja 79
6.3.5. Metoda strojnog učenja temeljena na stroju s potpornim vektorima 80
6.3.6. Integracija rezultata strojnog učenja 82
6.4. Primjeri za topografske slike Marsa i Mjeseca 84
6.5. Zaključak 86

7. REFERENTNI KATALOG ZA VREDNOVANJE ALGORITAMA ZA DETEKCIJU KRATERA 87
7.1. Uvod 88
7.2. Problematika prethodnih kataloga i potreba za integracijom 89
7.3. Metoda za integraciju kratera iz različitih kataloga 93
7.4. Metoda za provjeru konzistentnosti kataloga 96
7.5. Rezultirajući katalog za vrednovanje s 57 633 kratera 97
7.6. Zaključak 101

8. METODE ZA VREDNOVANJE ALGORITAMA ZA DETEKCIJU KRATERA 102
8.1. Uvod 103
8.2. Priprema globalnih topografskih i optičkih slika 104
8.3. Uparivanje kratera iz različitih kataloga korištenjem konteksta 107
8.4. Interaktivna metoda za provjeru i registraciju kratera u kataloge 110
8.5. Površina ispod A-ROC krivulje i ostale mjere za vrednovanje 111
8.6. Postupak usporedbe algoritama za detekciju kratera 114
8.7. Zaključak 116

9. EKSPERIMENTALNI REZULTATI I VREDNOVANJE METODA ZA DETEKCIJU KRATERA 117
9.1. Optimalne vrijednosti parametara 118
9.1.1. Parametrizacija temeljne metode za detekciju kratera 118
9.1.2. Parametrizacija metode za detekciju kratera temeljene na interpolaciji 119
9.1.3. Parametrizacija metode za detekciju kratera temeljene na strojnom učenju 119
9.2. Rezultirajući katalozi Marsa s 132 843 i Mjeseca s 60 645 kratera 120
9.2.1. Doprinos temeljnog CDA-a prilikom izrade kataloga 115 225 kratera Marsa 120
9.2.2. Metodologija za evaluaciju i izrada kataloga 130 301 kratera Marsa 124
9.2.3. Doprinos CDA-a temeljenog na interpolaciji u izradi rezultirajućih najpotpunijih kataloga Marsa s 132 843 i Mjeseca s 60 645 kratera 129
9.3. Vrednovanje metoda za detekciju kratera 137
9.3.1. Vrednovanje temeljne metode za detekciju 137
9.3.2. Vrednovanje metode za detekciju temeljene na interpolaciji u obliku kratera 144
9.3.3. Vrednovanje metode za detekciju temeljene na strojnom učenju 148
9.3.4. Međusobna usporedba relativnih doprinosa metoda za detekciju 153
9.4. Strojna detekcija i globalni katalog kratera Fobosa s 1102 kratera 154
9.5. Testni poligon za vrednovanje laboratorijskih kratera 162
9.6. Detekcija kratera Mjeseca iz topografije rekonstruirane iz optičkih slika 171
9.7. Strojna detekcija kratera Venere 180
9.8. Strojna detekcija kratera Zemlje 183
9.9. Ukupni doprinos metoda za detekciju u katalogizaciji kratera 186
10. ZAKLJUČAK 187
11. POPIS LITERATURE 189
12. KAZALO POJMOVA 207
13. PRILOZI 208
POPIS PRILOGA NA OPTIČKOM DISKU 209
ŽIVOTOPIS 223
BIOGRAPHY 224

1. UVOD

U ovom poglavlju daje se uvod u ovaj rad, kroz sljedeća potpoglavlja:

- 1.1. Motivacija za detekciju kratera iz topografskih slika;
- 1.2. Struktura rada.

U potpoglavlju 1.1 opisuju se razlozi zbog kojih je potrebna detekcija kratera iz topografskih slika, a koji su ujedno i motivacija za ovaj rad. U idućem potpoglavlju 1.2 opisuje se struktura samog rada, odnosno ukratko se obrazlažu razlozi odabira ove strukture doktorskog rada.

1.1. Motivacija za detekciju kratera iz topografskih slika

Svakom novom lunarnom i planetarnom misijom, količina podataka koja se prikupi se znatno povećava (Maravell et al., 2006). S druge strane, broj znanstvenika koji analiziraju te podatke se ne mijenja bitno. S jedne strane je to dobro, jer svaki znanstvenik u prosijeku raspolaže s bitno više podataka. No s druge strane, time postaje praktički neizvedivo da se svi ti podaci nastave ručno obrađivati. Primjer je označavanje kratera na nekoj slici, kako bi se iz njihove distribucije procijenila starost tog dijela planetarnog tijela (Hartmann i Neukum, 2001). Stoga postoji potreba da se napravi program za analizu slike, kako bi se krateri mogli automatski katalogizirati te nakon toga i analizirati.

U ovome radu koriste se topografske i optičke slike. Slikovni element (*pixel*) optičkih slika sadrži informacije o intenzitetu svijetla (elektromagnetskog vala), koje može biti u dijelu vidljivog spektra, ultraljubičastog, infracrvenog, i slično. Primjer zapisa slikovnog elementa optičke slike su cjelobrojne vrijednosti intenziteta crvene, zelene i plave komponente u iznosu od 0 do 255. Specijalni slučaj su crno-bijele slike gdje su vrijednosti komponenata jednake te predstavljaju nijanse sive boje. Moguće su i druge kombinacije komplementarnih boja, kao što koriste pisači. Slikovni element topografskih slika sadrži vrijednost topografske (nadmorske) visine uobičajeno izražene u metrima. Primjer zapisa slikovnog elementa topografske slike su cjelobrojne vrijednosti u iznosu od -32768 do 32767. Kod planetarnih tijela gdje ne postoji more, nadmorska visina od 0 metara uobičajeno se definira kao prosječna visina. I kod optičkih i kod topografskih slika u daljnjem tekstu rada podrazumijeva se da se radi o digitalnim slikama.

Geografska dužina neke točke je kutna udaljenost mjerena od nultog meridijana do pripadajućeg meridijana te točke, i ista je u iznosu od -180° do 180°. Geografska širina neke točke je kutna udaljenost prema sjeveru ili jugu od ekvatora, ista je 0° na ekvatoru, -90° na Južnom i +90° na Sjevernom polu. Pod globalnom slikom podrazumijeva se slika cijelog planetarnog tijela. Kod jednostavne cilindrične projekcije, globalna slika sastoji se od dvodimenzionalne matrice slikovnih elemenata. Pod horizontalnom rezolucijom podrazumijeva se koliko stupnjeva je dugačak i širok pojedini slikovni element. Primjerice, pod 1/64° podrazumijeva se slika dužine 23040 (64 x 360°) slikovnih elemenata i širine 11520 (64 x 180°) slikovnih elemenata. Ukoliko geografsku širinu i dužinu pojedinog slikovnog elementa želimo izraziti u metrima, utoliko se isto može izračunati koristeći radijus planetarnog tijela (*rpt*). Tako se pod horizontalnom rezolucijom od 1/64° podrazumijeva ~1737.4 metara po slikovnom elementu za Zemlju (*rpt* = ~6371 km), ~924.5 za Mars (*rpt* = ~3390 km) i ~473.8 za Mjesec (*rpt* = ~1737.4 km). Pod vertikalnom rezolucijom podrazumijeva se vertikalna preciznost topografske slike, koja je uobičajeno ±1m.

Uobičajeni fizički proces dobivanja topografskih slika planetarnih tijela je slanje laserskog impulsa sa satelita određenom frekvencijom prema površini te mjerenje vremena potrebnog da se reflektira i vrati do satelita. Umnoškom vremena i brzine svjetlosti dobiva se dvostruka udaljenost od površine do satelita. U idućem koraku uračunavaju se gravitacijske anomalije koje se nalaze u blizini velikih planina, kanjona i slično, kako bi se što preciznije odredio točan položaj satelita u trenutku mjerenja te udaljenost od površine do satelita preračunala u udaljenost do gravitacijskog središta planetarnog tijela. Dodatno se automatskim procedurama detektiraju i otklanjaju pogrešna mjerenja, recimo kada se laserska zraka odbija od pješčanog oblaka, a ne od same površine. Rezultat prethodnih koraka je globalni skup točaka u trodimenzionalnom prostoru, koje se nalaze na putanjama kojima je satelit obilazio planetarno tijelo. Često su točke mjerenja koje se nalaze na pojedinoj putanji blizu jedna drugoj, dok su putanje relativno udaljenije jedna od druge te ne nužno paralelne. Stoga se može dogoditi da pojedinom slikovnom elementu globalne topografske slike ne odgovara točno jedno mjerenje nadmorske visine, nego da na tom području nema niti jednog mjerenja ili ih imamo više. Stoga se koristi interpolacija kako bi se mogla definirati vrijednosti za

svaki slikovni element. Može se istovremeno slati više laserskih impulsa prema površini kako bi mjerenje topografije bilo brže. Primjer je izrada topografije Mjeseca kada se istovremeno šalje pet impulsa. Uz izradu topografije laserskim impulsima ponekad se koriste i drugi instrumenti, kao što su primjerice radar (kod Venere gdje je vrlo gusta atmosfera pa se ne mogu koristiti laserski impulsi) ili sonar (za izradu topografije podmorja na Zemlji). Topografija se također može generirati i izračunavanjem iz optičkih slika (primjer je izrada topografije Fobosa).

Nedavno je pokazano da se modeliranjem stohastičkih procesa (Pauše, 1988) katalozi kratera mogu iskoristiti i za dodatne analize procesa koji su utjecali na distribuciju kratera (Salamunićcar, 2004, 2009), a ne samo za datiranje površine. Osnovni problem u daljnjim analizama u tom smjeru bio je relativno malen broj kratera koji je tada bio dostupan u katalozima. To je bila dodatna motivacija da se napravi algoritam za detekciju kratera (CDA – *Crater Detection Algorithm*), kako bi se što više kratera, posebno onih većih od željenog dijametra, katalogiziralo.

Analizom područja i dosadašnjih istraživanja, kako je detaljno opisano u idućem poglavlju, dolazi se do sljedećih zaključaka. Mnogi su pokušali razviti CDA s pretpostavkom da će to biti jednostavno napraviti koristeći već postojeće metode u obradi slike i strojnom učenju. No nitko do sada nije uspio razviti CDA koji neće imati bitno manje točnih detekcija ili bitno više pogrešnih detekcija od trenirane osobe koja ručno katalogizira kratere (određuje im koordinate centra i dijametar). Ovo je bila motivacija da se prvo pokuša napraviti detekcija iz topografskih slika, a ne detekcija iz optičkih slika koja je za implementaciju tehnički zahtjevnija, kako je također opisano u idućem poglavlju.

S druge strane, detekcija iz topografskih slika ima i prednost u tome što se detektiranim kraterima jednostavnije i točnije mogu mjeriti parametri, kao što je recimo omjer dubine i dijametra, a što je samo po sebi korisna informacija za znanstvenike iz područja lunarnih i planetarnih znanosti. Dodatna motivacija za detekciju kratera iz topografskih slika je i to što se neki krateri, koji su vremenom gotovo u cijelosti erodirali, odnosno zatrpani okolnim materijalom, mogu detektirati iz topografskih slika, dok isti nisu vidljivi na optičkim slikama, kako je u više detalja također opisano u idućem poglavlju.

U vrijeme kada se počelo raditi na ovom radu već su bili dostupni topografski MOLA (*Mars Orbiter Laser Altimeter*) podaci za Mars u horizontalnoj rezoluciji 1/64°. S obzirom da je polumjer Marsa ~3390 km, to je na ekvatoru ~924 m po slikovnom elementu, a što je dovoljno za detekciju kratera kojima je dijametar (u daljnjem tekstu: *D*) ~5 km ili veći. Vertikalna rezolucija podataka je ±1m, što je i više nego dovoljno za detekciju kratera u dijametru većih od nekoliko kilometara.

Tijekom izrade ovoga rada, postali su dostupni podaci za Mars i u horizontalnoj rezoluciji 1/128°, što je ~462m po slikovnom elementu. Za područja uz Sjeverni i Južni pol, postali su dostupni i podaci u horizontalnim rezolucijama 1/256° (~231m po slikovnom elementu) i 1/512° (~116m po slikovnom elementu). Tijekom ovoga rada postali su dostupni i topografski LOLA (*Lunar Orbiter Laser Altimeter*) podaci (Smith et al., 2010) u horizontalnoj rezoluciji 1/512° za Mjesec (vertikalna rezolucija im je ±50 cm no u ovome radu bilo je dovoljno koristiti ±1m), što je s obzirom na polumjer oko ~59 m po slikovnom elementu. Osim navedenih podataka, dostupni su postali i topografski podaci za Fobos (Wählisch et al., 2010), no svega u horizontalnoj rezoluciji 1/4° pa nisu bili posebno važni za vrednovanje rezultata ovoga rada. Također, na samom kraju korišteni su i topografski podaci za Veneru i Zemlju.

Velik broj kratera na Marsu i Mjesecu, njihova raznolikost, kao i prethodno navedeno uz detaljniju analizu danu u sljedećem poglavlju, bili su motiv za odabir globalnih topografskih slika za ulazne podatke CDA-ova ovoga rada. Da je navedeno bio dobar izbor, kasnije se pokazalo time što je upravo koristeći te podatke i CDA-ove ovoga rada sveukupno katalogizirano više kratera nego što ih je sveukupno do sada katalogizirano ručno (prethodni katalozi) i CDA-ovima drugih autora.

1.2. Struktura rada

Struktura rada je u skladu s međunarodnom IMRAD (*Introduction, Materials and Methods, Results and Discussion*) preporukom pisanja znanstvenih radova (Davis, 2005; Day i Gastel, 2006; Katz, 2009; Malmfors et al., 2004). Slika 1 prikazuje kako se rad u skladu s tom preporukom sastoji od uvoda (*introduction*), materijala i metoda (*materials and methods*), rezultata (*results*) i diskusije odnosno zaključka (*discussion*).

uvod:
1. Uvod
2. Pregled područja i dosadašnjih istraživanja
3. Okolina za razvoj algoritama za detekciju kratera

materijali i metode:
4. I. Korak: Temeljna metoda za detekciju kratera
5. II. Korak: Poboljšanje detekcije kratera interpolacijom prilagođenom obliku kratera
6. III. Korak: Poboljšanje detekcije kratera strojem s potpornim vektorima

rezultati:
7. Referentni katalog za vrednovanje algoritama za detekciju kratera
8. Metode za vrednovanje algoritama za detekciju kratera
9. Eksperimentalni rezultati i vrednovanje metoda za detekciju kratera

diskusija:
10. Zaključak

Slika 1. Struktura rada koja je u skladu s IMRAD preporukom pisanja znanstvenih radova.

U uvodnom dijelu daje se pregled dosadašnjih istraživanja, među ostalim i kako bi se rezultati ovoga rada mogli usporediti s rezultatima drugih. Jedan od problema bio je što na početku ovog istraživanja nije postojala okolina koja bi se mogla koristiti za razvoj CDA-ova. S obzirom da je ovaj korak, kao i proučavanje područja i dosadašnjih istraživanja, bilo potrebno napraviti prije početka rada na samim metodama za detekciju kratera, oboje je opisano u uvodnom dijelu.

U dijelu vezanom za materijale i metode daje se prijedlog nove metode za detekciju kratera. Rad na njoj odvijao se u tri faze. U prvoj fazi razvijen je temeljni CDA koji se koristio za katalogiziranje i pripremu u vrijeme objave najpotpunijeg kataloga kratera Marsa. U drugoj fazi primjenom interpolacije CDA se poboljšao, čime je davao bolje rezultate za topografske slike Marsa, ali i bio u potpunosti primjenjiv za topografske slike Mjeseca. Rezultat druge faze su najpotpuniji javno dostupni katalozi kratera Marsa i Mjeseca. U trećoj fazi primijenjeno je strojno učenje, čime su se svojstva CDA-a dodatno značajno poboljšala.

U dijelu vezanom za rezultate opisan je postupak i razvijene metode koje su bile potrebne kako bi se došlo do potrebnog referentnog kataloga za vrednovanje CDA-a. Tu su također opisane i metode razvijene kako bi vrednovanje bilo što raznovrsnije i sa što više korisnih informacija o samom CDA-u. I na kraju, u ovom dijelu opisani su i sami eksperimentalni rezultati te rezultati vrednovanja CDA-a.

U dijelu vezanom za diskusiju dan je sam zaključak kao i pregled najvažnijih rezultata ovoga rada te opisan njegov doprinos u kontekstu drugih istraživanja.

2. PREGLED PODRUČJA I DOSADAŠNJIH ISTRAŽIVANJA

U ovom poglavlju daje se pregled područja i dosadašnjih istraživanja algoritama za detekciju kratera te njihova klasifikacija na temelju nekoliko relevantnih kriterija, kroz sljedeća potpoglavlja:

- 2.1. Uvod;
- 2.2. Klasifikacija s obzirom na korištene podatke;
- 2.3. Klasifikacija s obzirom na korištene metode;
- 2.4. Klasifikacija s obzirom na mogućnost obrade globalnih podataka;
- 2.5. Klasifikacija s obzirom na vrednovanje rezultata;
- 2.6. Zaključak.

U uvodnom potpoglavlju 2.1. daje se pregled dostupne literature i opisuje dinamika istraživanja u zadnjih desetak godina. S obzirom da izbor metoda prilikom razvoja CDA-ova bitno ovisi o tome detektiraju li se krateri koristeći optičke, topografske ili neke druge slike (radarske, gravimetrijske, …), ova problematika opisuje se u potpoglavlju 2.2. U potpoglavlju 2.3. daje se osnovni pregled metodologije korištene prilikom razvoja CDA-ova. Među ostalim daje se i pregled korištenog iz područja strojnog učenja, s obzirom da strojno učenje ima posebnu važnost u nastojanjima da se postignu što bolje karakteristike CDA-ova. Količina podataka koje je potrebno obraditi, ako se žele katalogizirati krateri cijelog planetarnog tijela, poseban je izazov za CDA-ove te se stoga ova problematika opisuje u potpoglavlju 2.4. Vrednovanje rezultata potrebno je kako bi se različiti CDA-ovi mogli uspoređivati. Ova problematika opisana je u potpoglavlju 2.5. U potpoglavlju 2.6. naveden je zaključak vezan za pregled područja i dosadašnjih istraživanja te odnos prema istraživanju ovoga rada.

Imena kataloga kratera koja se koriste u nastavku ovoga rada sastoje se od tri dijela. Ime kataloga počinje s dvosložnom oznakom planetarnog tijela kojem pripada (MA – *Mars* za Mars, LU – *Lunar* za Mjesec, PH – *Phobos* za Fobos, VE – *Venus* za Veneru i EA – *Earth* za Zemlju). Nakon toga slijedi broj kratera u katalogu. Ime kataloga koji su rezultati ovoga rada završavaju s GT – *Ground Truth* – što je oznaka za referentni katalog, dok imena drugih autora završavaju sa slovom kratice (za Mars: *B* – Barlow, *R* – Rodionova, *C* – Boyce, *K* – Kuzmin, *N* – Nežić, *T* – Stepinski i Urbach; za Mjesec: *N* – NASA i McDowell, *R* – Rodionova, *H* – Head i Kadish). Prethodni katalozi Marsa opisani su u potpoglavlju 7.2., a prethodni katalozi Mjeseca u potpoglavlju 9.2.3.

2.1. Uvod

Tablica 1 prikazuje pregled 126 CDA-ova i njihovih osnovnih značajki. Izvori podataka korišteni pri izradi tablice su prethodni radovi (Salamunićcar i Lončarić, 2008d; Salamunićcar et al., 2011a), te dodatna analiza literature dostupne tijekom 2011. godine. Tablica sadrži osnovne značajke CDA-ova: (1) koriste li optičke slike, topografske slike (DEM – *Digital Elevation Model*) ili neke druge podatke; (2) obrađuju li podatke Zemlje, Mjeseca, Marsa, Venere ili nekog drugog planetarnog tijela; (3) je li u radu prikazana slika s primjerima detektiranih kratera; (4) obrađuju li globalne podatke za planetarno tijelo; (5) uspoređuju li rezultate s katalozima kratera MA42279B (B) i MA19308R (R) (opisani su u potpoglavlju 7.2.) ili s referentnim katalozima; (6) koriste li za vrednovanje postignutih rezultata F-ROC (*Free-response Receiver Operating Characteristics*) metodu opisanu u potpoglavlju 3.5. (Salamunićcar i Lončarić, 2008d) ili A-ROC (*Approximation-of Receiver Operating Characteristics*) (Salamunićcar et al., 2011a) metodu opisanu u potpoglavlju 8.5.

Tablica 1. Pregled područja i dosadašnjeg istraživanja CDA-ova te njihove osnovne značajke.

autori\značajke	**optičke slike, DEM, drugo**	**Zemlja, Mjesec, Mars, Venera, ...**	**vizualna usporedba**	**glo-bal-no**	**usporedba s katalozima**	**(*)-ROC**
Alekseev et al. (1993)	opt. sl.	Zemlja	da			
Alves (2003) *	opt. sl.	Mars	implicitno			
Asada et al. (2008a) *	DEM	Ma.,Mj.	implicitno			
Asada et al. (2008b) *	DEM	Ma.,Mj.	implicitno			
Bandeira et al. (2006a) *	opt. sl.	Mars	da			
Bandeira et al. (2006b) *	opt. sl.	Mars	da			
Bandeira et al. (2007a) *	opt. sl.	Mars	da			
Bandeira et al. (2007b) * (Salamunićcar et al., 2011c, 2011d)	opt. sl.	Mars, Fobos	da	da		
Bandeira et al. (2008a) *	opt. sl.	Mars	da			
Bandeira et al. (2008b) *	opt. sl.	Mars	da			
Bandeira et al., (2010a) *	opt. sl.	Mars	da			
Barata et al. (2004) *	opt. sl.	Mars	da			
Barata et al. (2010) *	opt. sl.	Venera	da			
Barni et al. (2000)	opt. sl.	nije def.	implicitno			
Bauer i Stepinski (2011) *	DEM	Mjesec	implicitno			
Bierhaus et al. (2001) *	opt. sl.	Mjesec	implicitno			
Bijaoui i Froeschle (1980)	opt. sl.	Mjesec	implicitno			
Brumby et al. (2003) *	opt. sl.	Mars	da			
Bruzzone et al. (2004) *	opt.+drugo	Zemlja	da			
Bue i Stepinski (2006) *	DEM	Mars	da		*B* dijelom	
Bue i Stepinski (2007) *	DEM	Mars	da		*B* dijelom	
Burl et al. (1999)	opt. sl.	nije def.	implicitno			
Burl et al. (2001) *	opt. sl.	Mjesec	da			da
Cheng et al. (2003) *	not spec.	nije def.	implicitno			

Cheng et al. (2004)	*	opt. sl.	Z.,Ma.	implicitno			
Cheng et al. (2005)	*	opt. sl.	Z.,Ma.	implicitno			
Cheng i Huertas (2010)	*	opt. sl.	Mjesec	da			
Chicarro et al. (2003)	*	opt.+drugo	Z.,Mj.,Ma.	da			
Cintala et al. (1976)		opt. sl.	Mj.,Ma.	implicitno			
Clerc et al. (2010)	*	opt. sl.	Mj.,Ma., (*Phoebe*)	da			
Cooper (2003)	*	opt. sl.	Zemlja	da			
Cooper i Cowan (2004)	*	opt.+drugo	Zemlja	da			
Costantini et al. (2002)	*	opt.+drugo	Z.,Mj.,Ma.	da			
Degirmenci i Ashyralyev (2010)	*	opt.+DEM	Mars	da		*B* dijelom	
Di Stadio et al. (2002)	*	opt.+drugo	Z.,Mj.,Ma.	da			
Ding et al. (2010)	*	opt. sl.	Mars	da			
Ding et al. (2011)	*	opt. sl.	Mars	da			
Dypvik et al. (2006)	*	DEM	Zemlja	implicitno			
Earl et al. (2005a)	*	opt.+DEM	Z.,Ma.	da			
Earl et al. (2005b)	*	opt.+DEM	Z.,Ma.	da			
Earl et al. (2005c)	*	opt.+DEM	Z.,Ma.	da			
Flores-Méndez (2003)	*	opt. sl.	Mars	da			
Flores-Méndez i Suarez-Cervantes (2009)	*	opt. sl.	Mars	da			
Furlanello et al. (2003)	*	opt. sl.	Zemlja	implicitno			
Hadad et al. (2001)	*	opt. sl.	Zemlja	implicitno			
Harada et al. (2007a)	*	DEM	Mars	da			
Harada et al. (2007b)	*	DEM	Mars	da			
Harada et al. (2007c)	*	DEM	Mars	implicitno			
Harada et al. (2007d)	*	DEM	Mars	da			
He et al. (2010)	*	opt. sl.	Mjesec	da			
Homma et al. (1997)		not spec.	nije def.	implicitno			
Honda i Azuma (2000)		opt. sl.	Mjesec	da			
Honda et al. (2000a)		opt. sl.	Mjesec	da			
Honda et al. (2000b)		opt.+DEM	Mj.,Ma.	da			
Honda et al. (2002)	*	opt. sl.	Mjesec	da			da
Jahn (1994)		opt. sl.	Mars	da			
Johnson et al. (2005)	*	opt. sl.	Z.,Ma.	implicitno			
Kim et al. (2001)	*	opt.+DEM	Mars	implicitno			
Kim i Muller (2003)	*	opt.+DEM	Mars	da			
Kim et al. (2004)	*	opt.+DEM	Mars	da			
Kim et al. (2005a)	*	opt.+DEM	Mars	da			
Kim et al. (2005b)	*	opt.+DEM	Mars	da		*B* dijelom	
Kim et al. (2006)	*	opt.+DEM	Mars	implicitno			
Kim et al. (2008)	*	DEM	Mars	implicitno			
Krøgli et al. (2007)	*	DEM	Zemlja	da			

Krøgli et al. (2008)	*	DEM	Zemlja	da			
Krøgli i Dypvik (2010)	*	gr.+aerom.	Zemlja	da			
Leroy et al. (2001)	*	opt. sl.	asteroid	da			
Li et al. (2002)	*	opt. sl.	Mars	implicitno			
Liu et al. (2011)	*	opt. sl.	Mars	da			
Maass et al. (2011)	*	opt. sl.	Mjesec, (*Lutetia*)	da			
Magee et al. (2003)	*	opt. sl.	Mars	da			
Maimone et al. (2004)	*	opt. sl.	Mars	da			
Martins et al. (2007)	*	opt. sl.	Mars	da			da
Martins et al. (2008)	*	opt. sl.	Mars	da			da
Martins et al. (2009)	*	opt. sl.	Mars	da			da
Matsumoto et al. (2005a)	*	DEM	Mj.,Ma.	da			
Matsumoto et al. (2005b)	*	DEM	Mj.,Ma.	implicitno			
Meng et al. (2008)	*	opt. sl.	Mjesec	da			
Meng et al. (2009a)	*	opt. sl.	Mjesec	da			
Meng et al. (2009b)	*	opt. sl.	nije def.	da			
Michael (2002)	*	DEM	Mars	da	da	*R*	
Michael (2003a)	*	DEM	Mars	da	da	*R*	
Michael (2003b)	*	DEM	Mars	implicitno	da	*R*	
Miller et al. (2011)	*	opt. sl.	Mars	da			
Pedrosa et al. (2011)	*	opt. sl.	Mars	da			
Pina et al. (2005)	*	opt. sl.	Mars	implicitno			
Plesko et al. (2001)	*	opt. sl.	Mars	da			
Plesko et al. (2003a)	*	opt. sl.	Mars	da			
Plesko et al. (2003b)	*	opt. sl.	Mars	implicitno			
Plesko et al. (2004)	*	opt. sl.	Mars	da			
Plesko et al. (2005a)	*	opt. sl.	Mars	da			
Plesko et al. (2005b)	*	opt.+DEM	Mars	implicitno			
Plesko et al. (2006)	*	opt. sl.	Mars	implicitno			
Portugal et al. (2004)	*	DEM	Zemlja	implicitno			
Rajput (2011)	*	DEM	Mars	da		MA130301GT	
Saraiva et al. (2006)	*	opt. sl.	Mars	da			
Saraiva et al. (2007)	*	opt. sl.	Mars	da			
Saraiva et al. (2008)	*	opt. sl.	Mars	implicitno			
Sawabe et al. (2003)	*	opt. sl.	Mjesec	implicitno			
Sawabe et al. (2004)	*	opt. sl.	Mjesec	implicitno			
Sawabe et al. (2006)	*	opt. sl.	Mjesec	da			
Simpson et al. (2008)	*	DEM	Mars	da			
Smirnov (2002)	*	opt. sl.	Mjesec	implicitno			
Stepinski i Mendenha. (2006a)	*	DEM	Mars	da		*B* dijelom	
Stepinski et al. (2006)	*	DEM	Mars	da		*B* dijelom	
Stepinski i Mendenhall (2006b)	*	DEM	Mars	implicitno		*B* dijelom	

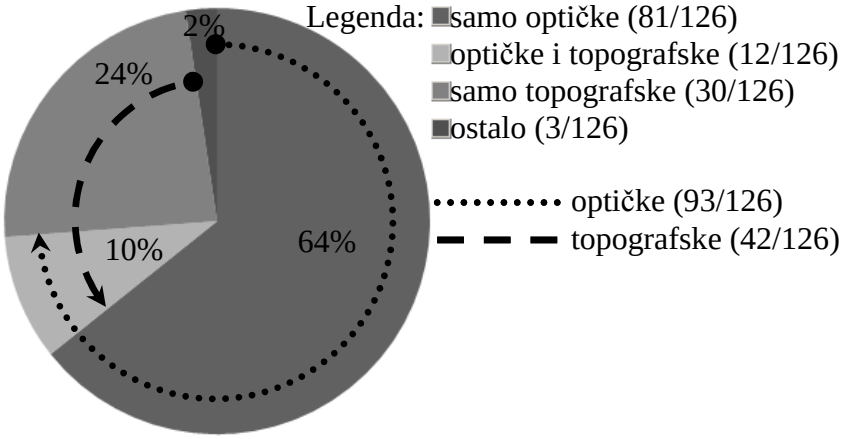
Stepinski et al. (2007a)	*	DEM	Mars	implicitno		*B* dijelom	
Stepinski et al. (2007b)	*	DEM	Mars	da		*B* dijelom	
Stepinski i Urbach (2007)	*	DEM	Mars	da			
Stepinski i Urbach (2008)	*	DEM	Mars	implicitno	da	*B*	
Stepinski i Urbach (2009)	*	DEM	Mars	implicitno	da	*B*	
Stepinski et al. (2009)	*	DEM	Mars	da		*B* dijelom	
Troglio et al. (2010)	*	opt. sl.	Mars	da			
Urbach (2007)	*	opt. sl.	Mars	da			
Urbach i Stepinski (2008)	*	opt. sl.	Mars	da			
Urbach i Stepinski (2009)	*	opt. sl.	Mars	da			
Vetro i Simovici (2010)	*	opt. sl.	Mars	da			
Vinogradova i Mjolsness (2001)	*	opt. sl.	Mars	implicitno			da
Vinogradova et al. (2002a)	*	opt. sl.	Mars	implicitno			
Vinogradova et al. (2002b)	*	opt. sl.	Mars	da			da
Wang et al. (2010)	*	opt. sl.	Mars	da			
Wetzler et al. (2005)	*	opt. sl.	Mars	da			da
Yamamoto et al. (1999)		opt. sl.	Mjesec	da			
Yang et al. (2011)	*	opt. sl.	Mars	da			
Yue et al. (2008)	*	opt. sl.	Mjesec	da			

Radovi koji su objavljeni unutar zadnjih 10 godina (2001. godine ili kasnije) označeni su zvjezdicom (*). Isti čine preko 90% ukupnog broja radova. Iz navedenog je vidljivo da se tijekom zadnjeg desetljeća dinamizirao razvoj CDA-ova, gdje brojni autori na različite načine pristupaju problemu detekcije kratera. Iz ovoga se dodatno potvrđuje da se sa stajališta znanstvenih istraživanja radi o zanimljivom području gdje se još uvijek nije pronašao dovoljno robustan CDA, s kojim bi znanstvena zajednica bila u glavnini zadovoljna i gdje daljnja istraživanja više ne bi bila ovog intenziteta. Primjer je katalogizacija kratera, gdje se CDA-ovi svojim karakteristikama još nisu približili rezultatima koje postiže trenirana osoba prilikom ručne katalogizacije kratera.

Tablica 1 daje nam dodatne informacije i o drugim važnim značajkama CDA-ova, kao što su podaci koje koriste i način na koji su vrednovani. Više o tome bit će dano u sljedećim potpoglavljima.

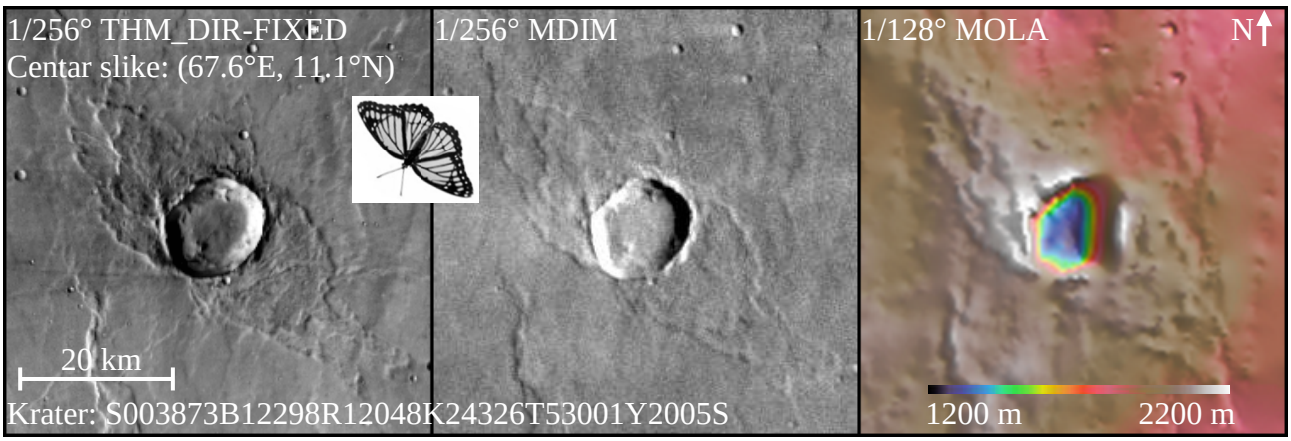
2.2. Klasifikacija s obzirom na korištene podatke

Klasifikacija s obzirom na detekciju kratera iz optičkih, topografskih ili nekih drugih slika (radarske, gravimetrijske) važna je jer to znatno utječe na izbor metoda koje će koristiti CDA. Slika 2, koja je napravljena na temelju podataka iz prethodne tablice, pokazuje kako najviše CDA-ova koristi optičke slike, kako puno CDA-ova koristi topografske slike ili i topografske i optičke, te kako samo neznatan broj CDA-ova koristi neke druge podatke. Najviše CDA-ova koristi optičke slike jer je najviše slika dostupno upravo u tom obliku, posebno onih u visokoj horizontalnoj rezoluciji gdje topografski podaci nisu dostupni.



Slika 2. Podjela na detekciju iz optičkih slika, optičkih i topografskih, topografskih, te ostalih (radarske, gravimetrijske). Brojevi u zagradama odgovaraju broju radova iz prethodne tablice.

Slika 3 prikazuje osnovu problematike detekcije iz optičkih slika. Kada se isti krater snimi različitim kamerama iz različitih satelita ili u različito vrijeme kada je položaj satelita i Sunca u odnosu na planetarno tijelo različit, onda i same slike izgledaju različito. Iako dvije prikazane optičke slike (lijevo – termovizijska; u sredini – vidljiv dio spektra) za ljudsko oko mogu izgledati gotovo pa jednake, može se primijetiti da su najsvjetliji dijelovi na prvoj slici najtamniji na drugoj. Razlog je u tome što je Sunce u odnosu na površinu pod različitim kutom, pa samim time i sjene padaju na različitu stranu. Za CDA-ove koji koriste optičke slike, ovakve različitosti predstavljaju problem koji je potrebno riješiti kako bi detekcija kratera bila uspješna. Kod topografskih slika nema ovih problema, već je oblik kratera neovisan o položajima satelita, Sunca i lunarnog odnosno planetarnog tijela u trenutku nastanka topografske slike, odnosno podataka koji su korišteni u njezinoj izradi.



Slika 3. Krater oblika leptira prikazan s dvije različite optičke i jednom topografskom slikom.

Kod optičkih slika dodatan problem je i što sama površina ne mora biti jednolike boje, pa tamniji odnosno svjetliji dijelovi algoritmu za detekciju mogu izgledati kao topografski niža odnosno topografski viša područja, iako to ne moraju biti. Ovih problema također nema kod topografskih slika.

S druge strane, postoje i dodatni problemi u detekciji koji su zajednički i optičkim i topografskim slikama, koji su opisani u nastavku ovog potpoglavlja.

Za Mars, Barlow et al. (2003) predložila je međunarodno prihvaćenu terminologiju za najuobičajenije oblike kratera. Na temelju nje krateri se klasificiraju kako na temelju njihove unutrašnje morfologije (*central peaks*, *peak rings*, *central pits*, *wall terraces*) tako i na temelju strukture izbačenog materijala (*pedestal*, *pancake*, *rampart*, *lobate*, *fluidized*, *radial or lunar-like*, *transitional or diverse*). Time dolazimo do zaključka da je prvi dodatni problem u detekciji raznolikost u oblicima kratera. Primjerice CDA-ovi ovoga rada detektiraju prvenstveno kratere kružnog oblika, koji su najuobičajeniji, dok se i krateri ostalih oblika potencijalno mogu detektirati zahvaljujući njihovoj sličnosti s kraterima kružnog oblika i robusnosti CDA-ova.

Uz ove uobičajene oblike, imamo i one manje uobičajene kao što je primjerice oblik leptira (*butterfly*), kako je prikazano na prethodnoj slici. Ovakvi oblici kratera najvjerojatnije su nastali kada je meteorit pod malim kutom udario u površinu gdje je materijal zbog veće količine vode (ili leda koji se otopio prilikom udara) bio u blatnom obliku (između suhog i tekućeg). Njihova zanimljivost sa stajališta CDA-ova je što su primjer oblika kratera koji imamo na Marsu, ali nemamo na Mjesecu. Time dolazimo do zaključka da je drugi dodatni problem u detekciji što na Marsu i Mjesecu imamo i kratere različitih oblika, odnosno da generalno možemo očekivati da na različitim planetarnim tijelima imamo kratere različitih oblika.

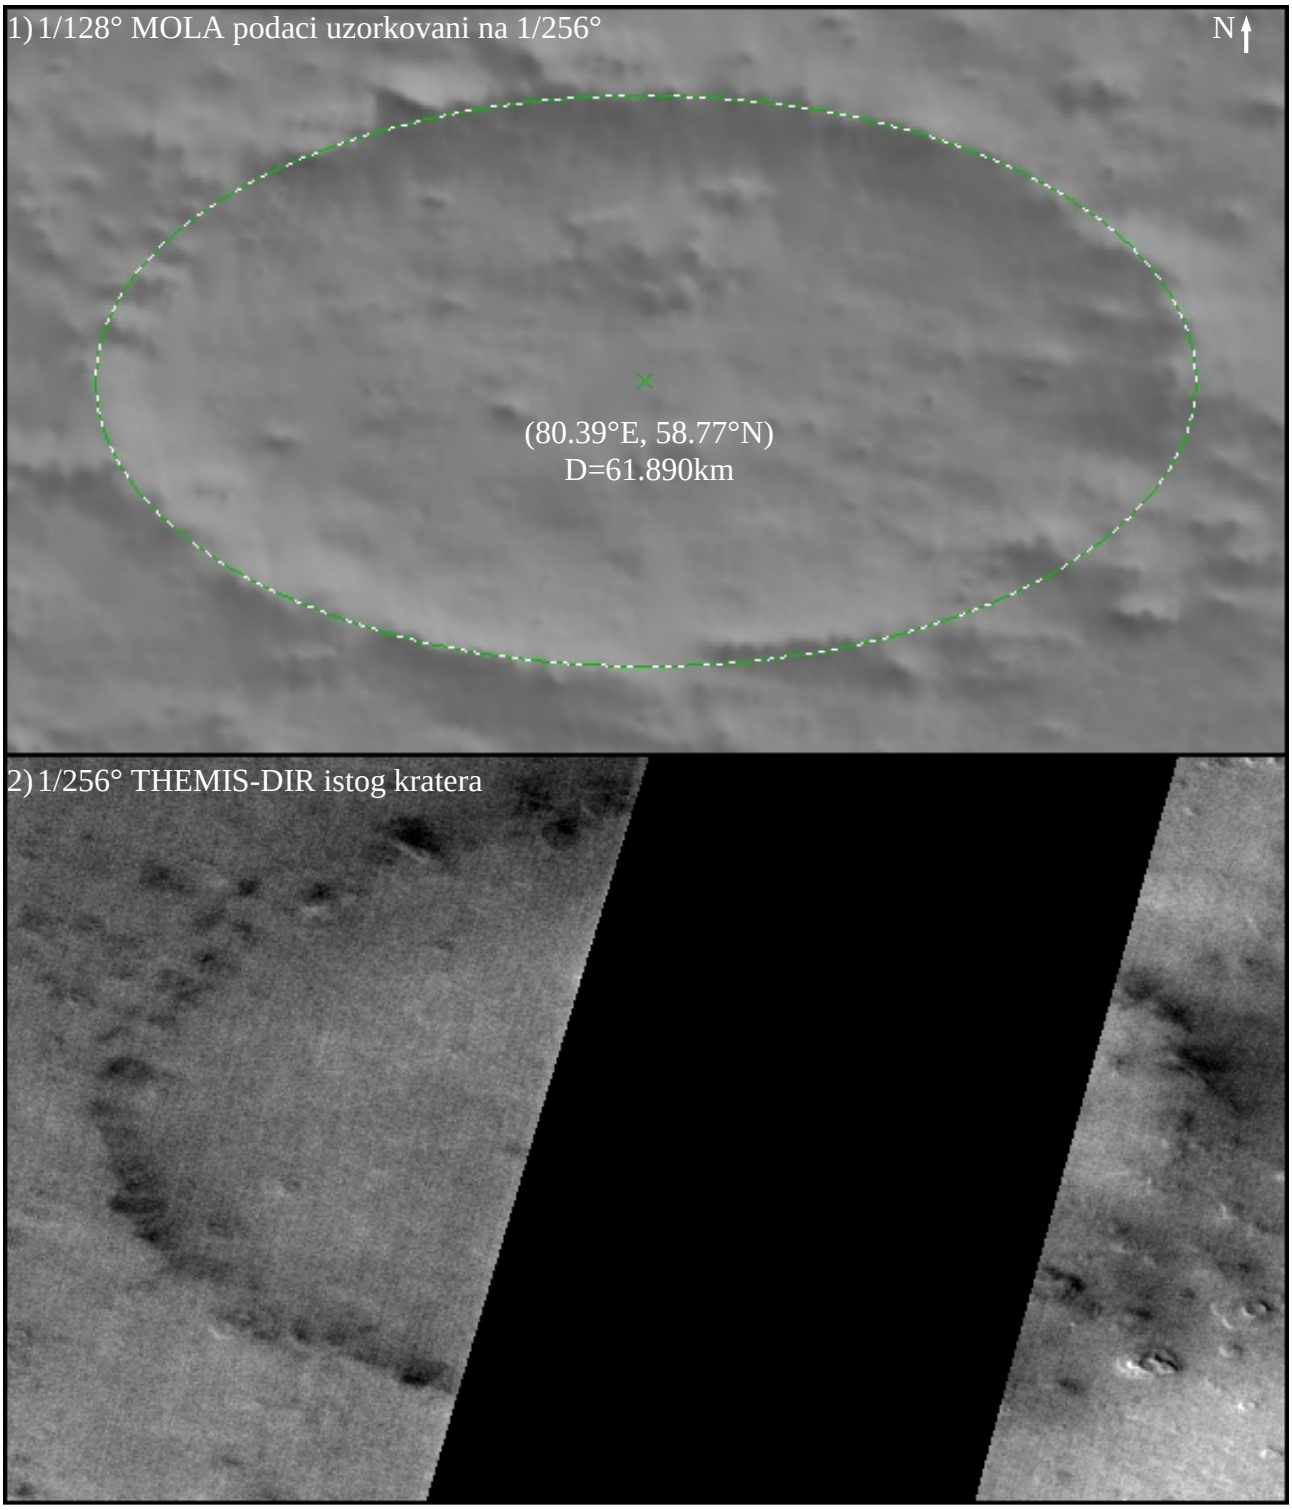
Također, poznato je da veliki krateri i mali krateri nisu istog oblika, kada se skaliraju na istu referentnu veličinu. Postoji kompleksno-jednostavni prijelaz (*complex-simple transition*) u obliku kratera (Melosh i Ivanov, 1999) iz najvećih kratera s višestrukim prstenima (*multi-ring impact craters*) prema najmanjim kraterima pravilnog kružnog oblika paraboličnog presjeka s bitno većim omjerom dubine i dijametra (*very circular bowl-shaped craters*). Time dolazimo do trećeg dodatnog problema u detekciji, a to je da su veliki i mali krateri generalno različitog oblika.

Različiti geološki procesi vremenom zatrpavaju i prekrivaju kratere, odnosno erodiraju njihov oblik. Među ostalim to mogu biti i nastanci novih kratera, gdje nije neuobičajeno da jedan krater u trenutku nastanka dijelom izbriše s površine u cijelosti ili jednim dijelom kratere koji su prethodno postojali u okolini udara u površinu. Time dolazimo do četvrtog dodatnog problema u detekciji, a to je da svaki od oblika kratera vremenom erodira i time dodatno mijenja oblik.

Može se zaključiti da je generalno gledano detekcija kratera iz topografskih slika lakša (Bue i Stepinski, 2007), jer kod detekcije iz topografskih slika nemamo problematiku koja je specifična samo za detekciju iz optičkih slika. Dodatna prednost detekcije iz topografskih slika je i u tome što se iz istih mogu detektirati vrlo erodirani krateri koji više nisu vidljivi na optičkim slikama. Primjer su istraživanja koje su vodili Frey et al. (2002), a gdje su u topografskim podacima pronađene brojne kružne depresije (*quasi-circular depressions*), za koje se pretpostavlja da se radi o gotovo u potpunosti erodiranim kraterima.

Slika 4 prikazuje upravo jedan takav primjer. Radi se o kružnoj depresiji koja nije bila vidljiva na MDIM (*Mars Global Digital Image Mosaic*) optičkoj slici, koju su koristeći topografske podatke (MOLA) otkrili Frey et al. (2002), a za koju je kasnije iz THEMIS-DIR (*THEMIS Day IR Global Mosaic*) slika (mogu se smatrati optičkim, no ustvari radi se o termovizijskim slikama u infracrvenom području) potvrđeno da se zaista radi o krateru (Salamunićcar i Lončarić, 2008e).

Iz ovog razmatranja dolazi se i do motivacije da se uz optičke i topografske slike koriste i ostali dostupni podaci, kako bi se otkrili i katalogizirali i oni krateri koji nisu vidljivi na optičkim i topografskim slikama.

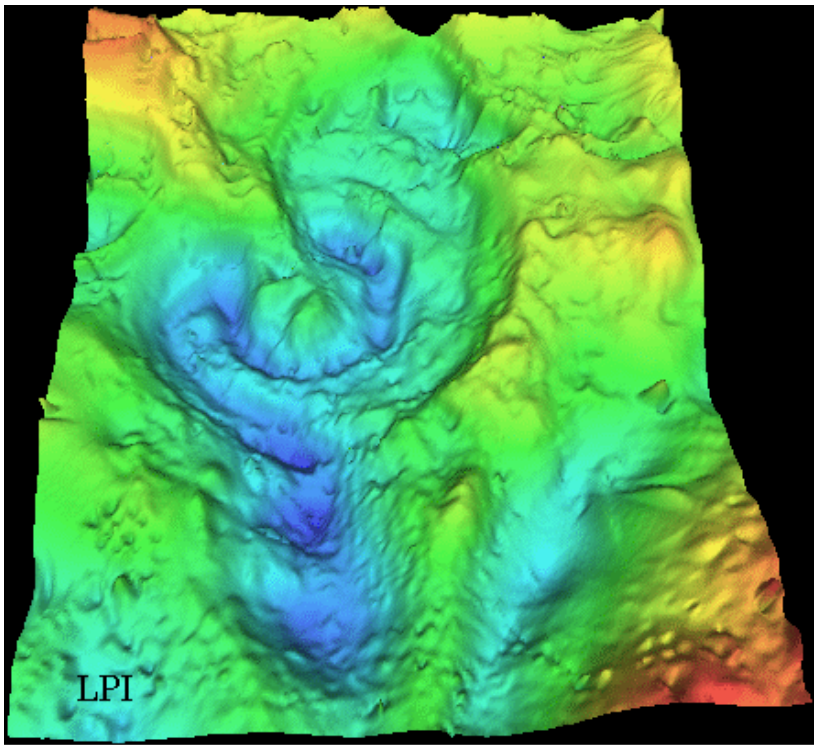


Slika 4. Prikaz kratera S042146C01833T74908Y2007S gdje THEMIS-DIR slika svega djelomično pokriva ovaj krater. Zanimljivo je da ova THEMIS-DIR slika pruža dokaz (jasno prikazan rub kratera) da je ova depresija kružnog oblika koju su otkrili Frey et al. (2002), a koja nije vidljiva na MDIM optičkoj slici, zaista krater. © 2008 Elsevier (Salamunićcar i Lončarić, 2008e).

Primjeri ostalih podataka su kako slijedi. Bruzzone et al. (2004), Costantini et al. (2002), Di Stadio et al., 2002 i drugi uz optičke slike koriste i slike dobivene radarom. Chicarro et al. (2003) uz optičke slike i slike dobivene radarom (*Synthetic Aperture Radar*) navode i gravimetrijske slike. Slika 5 prikazuje vizualizaciju podataka dobivenih radarom (*Synthetic Aperture Radar*) (Chicarro et al., 2003; NASA, 2005). Slika 6 prikazuje vizualizaciju podataka dobivenih iz gravimetrije (Chicarro et al., 2003; Hanks, 2011). Cooper i Cowan (2004) te Krøgli i Dypvik (2010) uz gravimetrijske koriste i zračnomagnetske (*aeromagnetic*) podatke, koji se obično dobivaju na način da se magnetometar stavi na zrakoplov te izvrše mjerenja.



Slika 5. Aorounga krater (D = 17 km), Čad, Afrika, radarska slika (NASA, 2005).



Slika 6. Chicxulub krater (D = 170 km), Meksiko, Sjeverna Amerika, gravimetrijska slika u kojoj slikovni elementi sadrže vrijednosti jakosti gravitacijskog polja (Hanks, 2011).

2.3. Klasifikacija s obzirom na korištene metode

Tijekom razvoja CDA-ova, autori su koristili mnogo raznorodnih metoda, te stoga postoji više mogućih klasifikacija CDA-ova na temelju toga koju metodologiju koriste u obradi slike i detekciji kratera.

Jedna moguća klasifikacija mogla bi biti na temelju razine obrade ulazne slike. Međutim, CDA-ove ne bi bilo jednostavno klasificirati na ovaj način, s obzirom da zbog raznorodnosti pristupu obrade ulazne slike neki od CDA-ova nemaju obrade na nekim razinama. Dodatno pitanje bi bilo i što s metodama koje se koriste na različitim razinama. Primjerice stroj s potpornim vektorima može se koristiti u završnom koraku obrade kako bi se samo bolje razlučile točne od netočnih detekcija, no isto tako se može koristiti i za samu detekciju na nekoj od početnih razina obrade slike.

S druge strane, neke od metoda se često koriste prilikom razvoja CDA-ova. Također, nekoga tko je već razvio CDA koji ima određene i prednosti i nedostatke, obično ne zanima kako razviti neki novi CDA na potpuno različiti način. Istog u principu zanima kako postojećem CDA-u što više poboljšati dobra svojstva u detekciji kratera i pronaći bolja rješenja za one njegove karakteristike gdje nije pokazao najbolje moguće rezultate. U tom smislu zanima ga što su sve drugi koristili prilikom razvoja CDA-a, te koliko je koja metoda doprinijela njegovim sveukupnim svojstvima.

S obzirom da je CDA koji je rezultat ovoga rada među ostalim temeljen i na detektoru ruba koristeći gradijent, izmijenjenoj Houghovoj transformaciji, te strojnom učenju koristeći stroj s potpornim vektorima, te metode su posebno zanimljive za ovo poglavlje. Ujedno, to su i metode koje su i drugi često koristili u svojim CDA-ovima. Stoga se u ovom potpoglavlju daje njihov pregled koji uključuje i kako su i drugi koristili tu metodologiju:

- 2.3.1. Podjela metoda s obzirom na korištenje detektora ruba;
- 2.3.2. Podjela metoda s obzirom na korištenje Houghove transformacije;
- 2.3.3. Podjela metoda s obzirom na korištenje strojnog učenja.

2.3.1. Podjela metoda s obzirom na korištenje detektora ruba

Razne grupe autora koriste raznorodne metode za detekciju ruba, kako bi postigli što bolje rezultate u sljedećim koracima CDA-a.

Honda i Azuma (2000) u svom radu koriste Robertsov (1965) detektor ruba. Jahn (1994) u svom radu koristi Robertsov (1965) i Sobelov (1978) detektor ruba. Flores-Méndez (2003) u svom radu koristi LoG-ov (*Laplacian of Gaussian*) detektor ruba (Pratt, 2001).

Canny (1986) je prvi koji je postavio kriterije uspješnosti detekcije ruba: (1) dobra detekcija - detektor ruba treba detektirati samo rubove i svi rubovi trebaju biti detektirani; (2) dobra lokalizacija - udaljenost između stvarnog ruba i ruba kojeg je pronašao detektor ruba treba biti minimalna; (3) minimalni odziv - detektor ruba ne smije višestruko detektirati rubove. Na temelju tih kriterija, došao je do optimalnog detektora ruba, za razliku od svih prethodnih autora koji su do svojih rezultata dolazili eksperimentalnim metodama. Osnovna razlika Cannyjevog detektora ruba u odnosu na prethodne je potiskivanje ne-maksimuma (*non-maximum suppression*) te filtriranje pragom histereze (*thresholding using hysteresis*) gdje se umjesto jednog koriste dva praga, prvi viši koji je potrebno zadovoljiti da se detektirani dio ruba uzme u obzir, i drugi niži koji određuje do koje vrijednosti gradijenta će se slikovni elementi ruba uzeti u obzir. Cannyjev (1986) detektor ruba u svom radu koriste Simpson et al. (2008), He et al. (2010) te Troglio et al. (2010).

Detektorom ruba koji je napravio Canny (1986) na prvi pogled proizlazi da nije moguće napraviti bolji operator, s obzirom da je optimalan. Međutim, ukoliko se definiraju neki drugi

kriteriji za detektor ruba, koji može biti važan u nekoj posebnoj primjeni, utoliko pronalazak optimalnog rješenja za novodefinirane kriterije može dovesti do operatora koji u tom slučaju daje bolje rezultate nego Cannyjev detektor ruba. Primjer je Shen-Castanov (1992) detektor ruba. Stoga nije iznenađujuće da se i u području CDA-ova aktivno istražuju detektori ruba, kako bi se postigli što bolji rezultati. Hadad et al. (2001) u svom radu uz Sobelov (1978), Prewittov (1970) i Cannyjev (1986) koriste i Shen-Castanov (1992) detektor ruba. Harada et al. (2007b, 2007d) u svom radu koriste brzu Furierovu transformaciju (*FFT*) i visokopropusni filtar, te Haar-Waveletovu transformaciju i visokopropusni filtar.

Bandeira et al. (2006b) u svom radu koriste Prewittov (Pratt, 2001), Sobelov (1978) i LoG-ov (Pratt, 2001) detektor ruba te metodu koju su sami razvili, a koja se temelji na analizi teksture slike. Kim et al. (2004) u svom radu također razvijaju vlastiti detektor ruba koji analizira teksturu slike. Bandeira et al. (2007a, 2007b) dolaze do zaključka kako Sobelov (1978) i Cannyjev (1986) detektor ruba ne daju dobre rezultate za optičke slike, jer se moraju ručno podešavati pragovi za različite slike, što je u suprotnosti sa željom da se cijeli proces može automatizirati. Do sličnih rezultata se dolazi i u radu (Bandeira et al., 2006a), gdje je razvijena vlastita metoda za detekciju ruba, te pokazano da daje bolje rezultate nego klasične metode kao što je Robertsov (1965), Prewittov (Pratt, 2001), Sobelov (1978), LoG-ov (Pratt, 2001) i Cannyjev (1986) detektor ruba. Magee et al. (2003) su također razvili vlastitu metodu za detekciju ruba, koja se temelji na Gaussovom operatoru i najbolje rezultate daje u smjeru svjetla. Sawabe et al. (2006) koriste posebnu metodu koja se temelji na jakosti ruba i analizi susjednih slikovnih elemenata.

S obzirom da su rubovi kratera gotovo uvijek dominantni među ostalim rubovima na lunarnim i planetarnim slikama, posebno tamo gdje ima puno kratera ili kratera s izrazito sačuvanim oblikom, bilo koji CDA u principu se može smatrati i metodom koja detektira rub. No pod detektorom ruba u principu se podrazumijeva metoda koja detektira sve značajnije rubove na slici, pripadali oni kraterima ili ne, gdje se onda dodatnom analizom slike određuje koji pripadaju kraterima. U tom smislu može se reći da postoje i oni CDA-ovi koji u svojem radu ne koriste detektore ruba, već drugim metodama detektiraju kratere. Primjer je metoda koju su razvili Bandeira et al. (2007a), a gdje i sami autori navode da iako njihova metoda izgleda kao detektor ruba, ona u biti to nije, već je metoda koja pronalazi parove polukružnih oblika koji su tamniji odnosno svjetliji od okoline, te ih uparuju kako bi dobili kandidate za kratere koji se naknadno obrađuju u nastavku metode. Navedeno u svom radu također koriste Urbach i Stepinski (2008), no oni parove kružnog oblika koji su tamniji odnosno svjetliji od okoline detektiraju filtrima oblika, za razliku od Bandeire et al. (2007a) koji u tu svrhu koriste analizu teksture. Metode koje pronalaze parove tamnijih i svjetlijih polukružnih oblika u svojim CDA-ovima koriste i drugi, kao primjerice Wang et al. (2010) i Clerc et al. (2010). Krøgli i Dypvik (2010) u svom radu navode i primjer slika magnetskog polja gdje detektori ruba ne daju dobre rezultate te navode kako oni kružne oblike prepoznaju analizom smjera gradijenta na pretpostavljenoj kružnici (prema odnosno od centra kružnice). Postoje i druge metode koje se mogu koristiti umjesto detektora ruba. Maass et al. (2011) analiziraju obradu slike uobičajenim detektorima ruba u kontekstu automatske navigacije satelita koristeći detekciju kratera, njihove dobre osobine i nedostatke, te predlažu alternativan pristup koji ne koristi detektor ruba. Dodatni primjer je izračunavanje radijalne konzistencije (mjera koliko je nešto kružnog oblika), koju su predložili Earl et al. (2005b).

Može se zaključiti da su detektori ruba značajan element u većem broju CDA-ova, no isto tako da postoji i značajan broj CDA-ova koji ne koriste detektor ruba. Također, može se primijetiti da jedni te isti detektori ruba u različitim okolnostima ne daju uvijek jednako zadovoljavajuće rezultate. Stoga je često potrebno operator prilagoditi, odnosno poboljšati dodatnom obradom slikovnih elemenata u blizini ruba, kako bi se postigli što bolji rezultati.

2.3.2. Podjela metoda s obzirom na korištenje Houghove transformacije

Razne grupe autora koriste Houghovu transformaciju (Hough, 1962) kako bi detektirali kratere. Pokazano je kako se Houghova transformacija može izvesti iz Radonove transformacije (Deans, 1981), pa se Houghova transformacija u literaturi označava i kao Radon/Hough transformacija. U ovome radu koristi se termin Houghova transformacija, s obzirom da je uobičajeniji u literaturi. Houghova transformacija opisana je u potpoglavlju 4.4.1.

Houghova transformacija prilikom razvoja CDA-ova se koristila na različite načine (Chicarro et al., 2003; Mjolsness i DeCoste, 2001; Di Stadio et al., 2002), a koristili su je Asada et al. (2008a, 2008b), Bandeira et al. (2008a), Bue i Stepinski (2006, 2007), Cooper (2003) te Cooper i Cowan (2004), Degirmenci i Ashyralyev (2010), Ding et al. (2010, 2011), Flores-Méndez (2003), Hadad (2001), Harada et al. (2007b, 2007c, 2007d), Honda i Azuma (2000), Honda et al. (2000b, 2002), Jahn (1994), Kim i Muller (2003), Magee et al. (2003), Matsumoto et al. (2005a, 2005b), Meng et al. (2009a), Michael (2002, 2003a), Portugal et al. (2004), Sawabe et al. (2003, 2004, 2006), Wetzler et al. (2005) i drugi.

Kao i kod detektora rubova, gdje imamo one CDA-ove koji koriste i one koje ne koriste neki od detektora rubova, uz one CDA-ove koje koriste Houghovu transformaciju u svom radu, postoje i drugi koji je ne koriste. Jedan primjer je podudaranje predloškom (*template matching*). Iako se podudaranje predloškom može smatrati kao daljnja generalizacija Houghove transformacije, u literaturi se uobičajeno koristi samo termin podudaranje predloškom. Podudaranje predloškom može se koristiti u kombinaciji s detektorom ruba kao što u svom radu koriste Magee et al. (2003), gdje se općenito gledano predložak kružnog oblika može koristiti za pretraživanje binarne slike koja sadrži rubove. Podudaranje predloškom može se koristiti i bez detektora ruba, gdje se predlošci često više različitih kratera koriste za pretraživanje uobičajeno izvornih optičkih slika, kao što u svom radu koriste Burl et al. (1999). Algoritam koji se temelji na statistici kako bi detektirao elipse koriste Meng et al. (2008). Kim et al. (2005b) koriste aproksimiranje konusnim odsječcima (*conic section fitting*) i organizaciju rubova temeljenu na grafovima (*graph based edge organization*). Dodatni primjer je, kao i za prethodnu klasifikaciju, računanje radijalne konzistencije kako su predložili Earl et al. (2005b).

2.3.3. Podjela metoda s obzirom na korištenje strojnog učenja

Razne grupe autora koriste razne metode strojnog učenja, pokušavajući na što jednostavniji, a u isto vrijeme i što efikasniji način, pristupiti problemu detekcije kratera (Mjolsness i DeCoste, 2001). Cilj je dobiti što bolji klasifikator, kako bi se što bolje mogli razlikovati točne detekcije (detektirani krateri) od pogrešnih.

Jačanje (*boosting*) je meta-algoritam strojnog učenja, gdje više slabih klasifikatora povezivanjem postaju bolji klasifikator. Pod slabim klasifikatorom podrazumijeva se klasifikator koji je slabo koreliran s točnom klasifikacijom, no ipak bolji od slučajnog pogađanja. Nasuprot tome, pod boljim klasifikatorom podrazumijeva se klasifikator koji je puno bolje koreliran s točnom klasifikacijom. Strojno učenje jačanjem u svojim radovima koriste Bandeira et al. (2008a), Ding et al. (2010, 2011), Furlanello et al. (2003), Martins et al. (2007, 2008, 2009) i drugi.

Odvajanje (*bagging*) je također meta-algoritam strojnog učenja, gdje više slabih klasifikatora povezivanjem postaju bolji klasifikator. Osnovna razlika jačanja i odvajanja je što odvajanje uzorkuje set za učenje dok jačanje koristi cijeli skup za učenje, ali s različitim težinskim faktorima, čime se dolazi do novog klasifikatora. Odvajanje u svom radu koriste Wetzler et al. (2005).

Stablo odlučivanja C4.5 (nadogradnja ID3 temeljnog algoritma) može raditi s numeričkim vrijednostima, vrijednostima koje nedostaju i podacima sa šumom, te uvodi načelo skraćivanja stabala, kako bi se izbjegla pretjerana podešenost na pripremni skup podataka (Pavlek, 2002). U

svom radu C4.5 koriste Bauer i Stepinski (2011), Stepinski et al. (2009), te Urbach i Stepinski (2008, 2009). Implementaciju C4.5 algoritma u Javi – J48 (Witten et al., 1999) koriste Stepinski i Mendenhall (2006a), kao i Wang et al. (2010).

Slučajna šuma (*Random Forest*) je klasifikacijski algoritam koji stvara skup stabla odlučivanja s kontroliranim varijacijama, gdje svaki klasifikator neovisno od drugih izvodi klasifikaciju, a primjeru se dodjeljuje ona klasa koju je dalo najviše klasifikatora (Repinc, 2009). Ovaj klasifikacijski algoritam koriste Bauer i Stepinski (2011).

GENIE algoritam strojnog učenja (razvijen u *Los Alamos National Laboratory* ustanovi) koristi tehnike iz genetskih algoritama i genetskog programiranja kako bi se klasificirali objekti. Algoritam GENIE u svom radu koriste Brumby et al. (2003), kao i Plesko et al. (2001, 2003a, 2003b, 2004, 2005a, 2005b, 2006).

Genetski algoritam višestruke populacije (*multi-population genetic algorithm*) temelji se na načelu lokalne selekcije i migracije, gdje se nekoliko populacija razvija izolirano kroz nekoliko generacija (kao što je genetski algoritam jedne populacije) prije nego što se jedna ili više jedinki razmjeni između populacija, čime genetski algoritam evoluira vrste sličnije načinu kako evoluiraju u prirodi nego što to može algoritam samo jedne populacije (Pohlheim, 2011). Genetski algoritam višestruke populacije koriste Degirmenci i Ashyralyev (2010).

Kohonenova samoorganizirajuća mapa (*self organizing map*) je vrsta neuronske mreže koja se temelji na principu povezanosti neurona u ljudskom mozgu, gdje su neki povezani na temelju učenja, a neki na temelju samoorganiziranja (Turhan Taner, 1997). Kohonenovu samoorganizirajuću mapu koriste Honda i Azuma (2000) te Honda et al. (2000b, 2002). Neuronsku mrežu s povratnom vezom (*a back propagation neural network*) koriste Kim et al. (2005b).

Stroj s potpornim vektorima (*Supported Vectors Machine*) daje vrlo dobre rezultate u različitim primjenama kao što su prepoznavanje teksta, prepoznavanje lica i slično (Vapnik, 2000; Hearst et al., 1998). Stroj s potpornim vektorima opisan je u potpoglavlju 6.3.1. Koriste ga Wetzler et al. (2005), Wang et al. (2010), Bauer i Stepinski (2011) te drugi.

Postoji i nekoliko radova koji uspoređuju više različitih tehnika strojnog učenja, kako bi najbolju odabrali za svoj CDA. Bauer i Stepinski (2011) uspoređuju C4.5 stablo odlučivanja, slučajnu šumu i stroj s potpornim vektorima, te zaključuju da C4.5 u njihovom slučaju daje najbolje rezultate. Wetzler et al. (2005) također uspoređuju više različitih sustava za učenje, odvajanje i jačanje (*AdaBoost*) s neuronskim mrežama s unaprijednom spregom (*feed-forward neural networks*) kao osnovnim klasifikatorom, strojeve s potpornim vektorima, te kontinuirano skalabilne modele predložaka (*continuously scalable template models*) koje su opisali Burl et al. (2001). U tom radu dolazi se do zaključka da u korištenoj primjeni najbolje rezultate daju strojevi s potpornim vektorima s radijalnom jezgrom. Ding et al. (2010, 2011) uspoređuju jačanje (*AdaBoost*) s C4.5 kao osnovnim klasifikatorom, stroj s potpornim vektorima s linearnom jezgrom i jačanje s prijenosom znanja (*TrAdaBoost*) s C4.5 kao osnovnim klasifikatorom, te zaključuju da je prijenos znanja (*Transfer Learning*) važan za dobru klasifikaciju kratera kod raznorodnih slika.

Na temelju navedenog može se zaključiti da razne grupe autora pokušavaju primijeniti razne metode strojnog učenja i da iste metode ne daju uvijek najbolje rezultate. CDA-ovi svojim rezultatima još uvijek dosta zaostaju u odnosu na rezultate koje postiže trenirana osoba. Iz te činjenice proizlazi zaključak da se još uvijek radi o poprilično neistraženom području te da primjena postojećih metoda (*off the shelf components*) bez dodatnih izmjena, odnosno poboljšanja, sama po sebi ne daje zadovoljavajući rezultat.

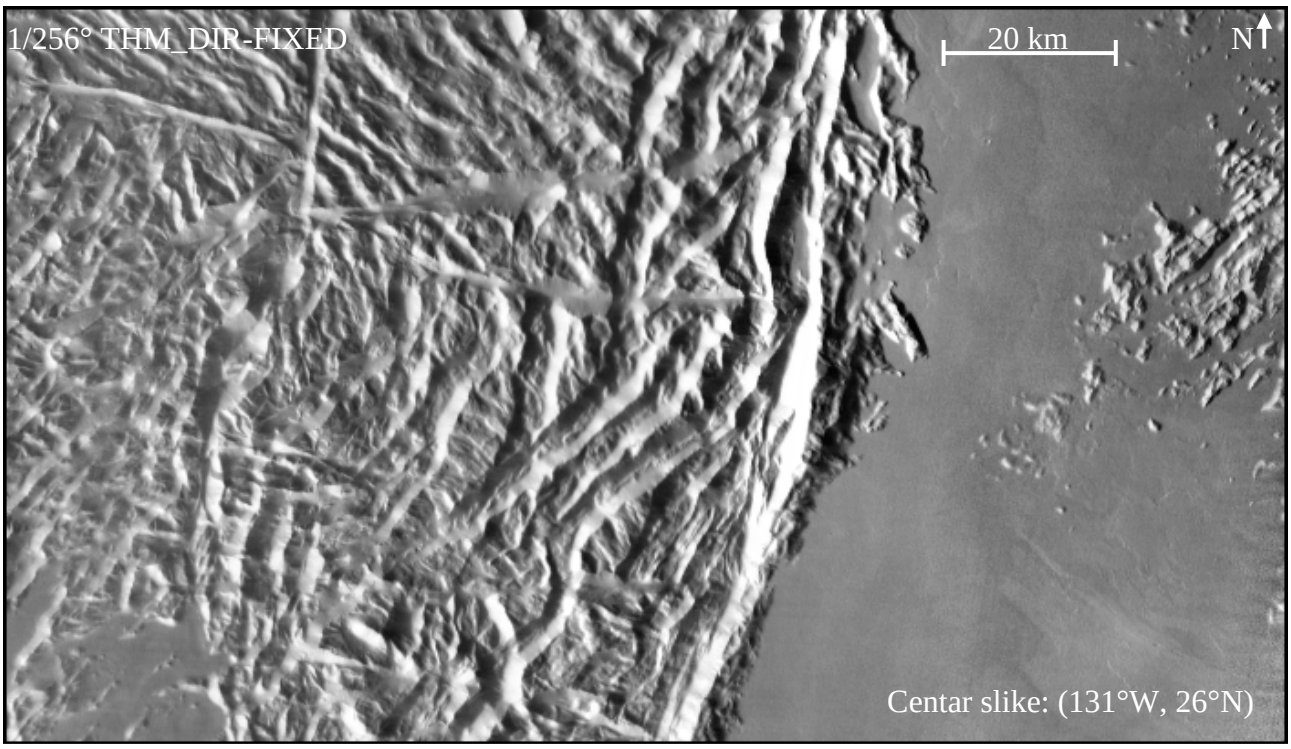
Do sličnih zaključaka se dolazi i kada se analiziraju ostale metode koje se koriste kod CDA-ova, kao što su raznovrsni detektori ruba, primjerice Cannyjev i Shen-Castanov (1992), te raznovrsne implementacije Houghove transformacije.

Kao što je bila moguća podjela metoda za detekciju kratera na one koje koriste i ne koriste detektore ruba, te na one koje koriste i ne koriste Houghovu transformaciju, metode za detekciju kratera možemo podijeliti i na one koje koriste strojno učenje te na one koje ga ne koriste. Metode koje ne koriste strojno učenje uobičajeno koriste neku drugu metodu čiji rezultat je polje brojila, a gdje lokalni maksimumi obično odgovaraju detekcijama kratera. Jedan primjer je Houghova transformacija koju koristi puno CDA-ova, kako je prethodno opisano. Podudaranje predloškom, kao što u svom radu koriste Magee et al. (2003) te Burl et al. (1999), također je jedna od mogućnosti kako detektirati kratere, a da se ne koristi strojno učenje. Dodatni primjer je i izračunavanje radijalne konzistencije (mjera koliko je nešto kružnog oblika), koju su predložili Earl et al. (2005b), a koja se također može koristiti za detekciju pri čemu se krater detektira tamo gdje je radijalna konzistencija najveća. Sve ove tehnike alternativne strojnom učenju mogu se koristiti i u kombinaciji sa strojnim učenjem, kako bi se dobili bolji rezultati nego što to navedene metode osiguravaju same po sebi.

2.4. Klasifikacija s obzirom na mogućnost obrade globalnih podataka

Između algoritma za detekciju koji je pokazao zadovoljavajuće rezultate na jednoj slici ili manjem broju slika te algoritma koji može obraditi globalne podatke za cijelo planetarno tijelo, postoje dvije suštinske razlike.

Prva suštinska razlika između onih CDA-ova koji mogu i onih koji ne mogu obraditi globalne podatke je u tome što uspješna demonstracija performansi algoritma za detekciju na manjem broju slika ne znači da će isti biti uspješan i na onim slikama koje sadrže značajke zbog kojih algoritam na njima ne detektira kratere dobro. Slika 7 prikazuje jedan primjer, dio površine Marsa, gdje algoritmi za detekciju kratera uobičajeno "detektiraju" puno kratera na dijelu koji je pun neravnina, iako ih uopće ne mora biti. Ove slike gotovo nikada ne uzimaju u obzir autori CDA-ova, s obzirom da iste ne sadrže puno ili uopće ne sadrže kratere. Međutim, ako se želi razviti CDA koji će uspješno detektirati kratere po cijelom planetarnom tijelu, onda se i ove slike moraju uzeti u obzir. To je važno kako bi se pokazalo da na njima CDA-ovi ne detektiraju kratere tamo gdje ih nema, odnosno da ih barem ne detektiraju puno. Sličan primjer su i kanjoni koji ne moraju sadržavati kratere, ali zbog svog nepravilnog oblika sadrže brojna mjesta koja su topografske depresije i kružnog oblika, što za CDA-ove predstavlja izazov u razlikovanju istih od pravih kratera.



Slika 7. Primjer kontrasta između kaotičnog i gotovo savršeno ravnog terena na Marsu.

Druga suštinska razlika između onih CDA-ova koji mogu i onih koji ne mogu obraditi globalne podatke je u učinkovitosti u obradi podataka koju CDA mora zadovoljiti. Pretpostavimo da želimo sistematično pretražiti sve moguće LLR (*Longitude Latitude Radius*) kombinacije planetarne dužine (*longitude*), širine (*latitude*) i radijusa (*radius*), koristeći 1/128° podatke (23040x46080 slikovnih elemenata) i radijuse između 2 i 28 slikovnih elemenata (najviše što se koristilo u ovome radu), kao i sve uzorkovane podatke između horizontalnih rezolucija 1/64° i 4° i radijuse između 14 i 28 slikovnih elemenata (ostalo je pokriveno prethodnim koracima), sveukupno imamo za provjeriti 33 973 842 150 kombinacija (Salamunićcar i Lončarić, 2010b). Za svaku od tih kombinacija predloženi CDA mora obraditi odgovarajuće područje slike kako bi donio odluku nalazi li se tu krater ili ne, te ako se nalazi, CDA treba procijeniti vjerojatnost da detektirani objekt

zaista i je krater. Sve to nameće važan zahtjev za vrlo učinkovito (brzo) računanje koje je potrebno za svaku moguću LLR kombinaciju. Recimo da CDA unutar jedne sekunde može obraditi 1000 LLR kombinacija, što se na prvi pogled čini poprilično brzo. No s obzirom na broj LLR kombinacija, jednostavnom računicom dolazimo do toga da bi obrada za cijelo planetarno tijelo u tom slučaju trajalo duže od godinu dana. Dodatni problem je zahtjev za radnom memorijom. Ako CDA za svaki slikovni element treba svega četiri bajta tijekom svog rada, to je sveukupno nešto manje od 4GB radne memorije za horizontalnu rezoluciju 1/128°, odnosno 16GB za horizontalnu rezoluciju 1/256° i 64GB za horizontalnu rezoluciju 1/512°. Jedna mogućnost je da se ulazna slika obrađuje dio po dio, no CDA je ponekad potrebno proširiti da bi tako mogao obrađivati slike, a i obrada tada dulje traje jer je potrebno određeno preklapanje generiranih potslika kako bi se osigurala cjelovita obrada (recimo da se ne dogodi da je pola nekog kratera na jednoj potslici, a pola na drugoj, pa ostane nedetektiran). Međutim, time se dodatno produžuje vrijeme obrade, koje je samo po sebi problem.

S obzirom na ovu problematiku, nije iznenađujuće da je do sada svega nekoliko CDA-ova pokazalo da može obraditi globalne podatke za neko planetarno tijelo.

Prvi CDA je razvio Michael (2003a) kako bi se krateri iz kataloga MA19308R (opisan u potpoglavlju 7.2.), registrirali s 1/64° MOLA topografskom slikom Marsa. Rezultat ovog CDA-a nije neki novi katalog ili dopuna novim kraterima nekog postojećeg kataloga, no bez obzira na to je važan, s obzirom da je to prvi CDA koji je predložio rješenje za prethodno navedenu problematiku detekcije iz globalnih podataka za cijelo planetarno tijelo.

Stepinski i Urbach (2008) razvili su CDA koji je rezultirao MA75919T katalogom (opisan u potpoglavlju 7.2.). I taj CDA koristio je MOLA podatke, no u nešto višoj horizontalnoj rezoluciji 1/128°. To je bio prvi CDA koji je koristio podatke u horizontalnoj rezoluciji 1/128°, ali i prvi CDA koji je rezultirao katalogom koji je bio dovoljno dobar da se može koristiti i za druga znanstvena istraživanja, osim vrednovanja samih CDA-ova.

Prvi katalog koji je nastao na temelju rezultata i CDA-a koji je obradio optičke slike za cijelo planetarno tijelo je katalog Fobosa PH504GT objavljen 2011. godine (Salamunićcar et al., 2011c), a gdje se uz CDA koji je rezultat ovoga rada i koji obrađuje topografske slike koristio i CDA za optičke slike (Bandeira et al., 2007b). Iako su za Fobos dostupne optičke slike samo do horizontalne rezolucije 1/16°, ovo je svakako važan korak u istraživanju CDA-ova, u smislu detekcije kratera s lunarnih i planetarnih tijela asteroidnog oblika te u kombiniranju CDA-ova koji detektiraju kratere iz topografskih i optičkih slika.

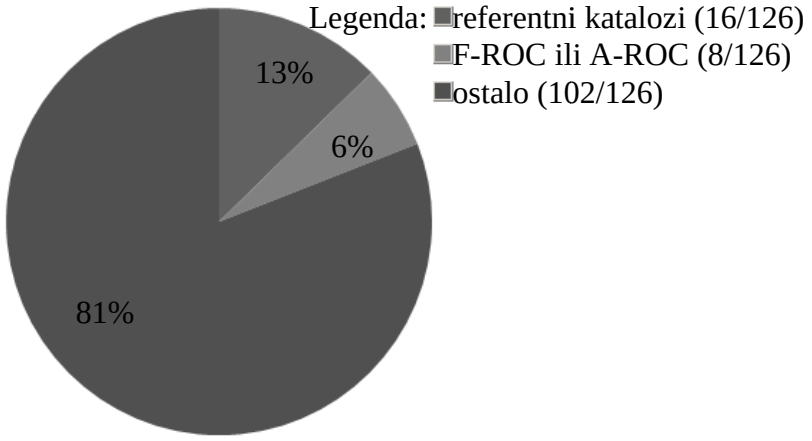
Ukratko, može se rezimirati: (1) obrada globalnih podataka za cijelo planetarno tijelo je zahtjevan zadatak za CDA; (2) do sada je razvijeno svega nekoliko CDA-ova koji su pokazali da mogu obraditi globalne podatke.

2.5. Klasifikacija s obzirom na vrednovanje rezultata

Kako bi se usporedila dva algoritma za detekciju kratera, potrebne su: (1) slike koje će obraditi tijekom vrednovanja; (2) referentni katalog; (3) mjera udaljenosti između kratera; (4) algoritam za registraciju (ili ručna registracija) kandidata za kratere koji su rezultat CDA-a i kratera iz referentnog kataloga; (5) mjera kvalitete CDA-a.

Ukoliko autori dva različita CDA-a koriste isto i (1) i (2) i (3) i (4) i (5), utoliko su njihovi rezultati usporedivi. No ako je različito samo (1) dok je sve drugo isto, različito samo (2) dok je sve drugo isto, ili različito samo (3), (4) ili (5), ne može se zaključiti jesu li razlike u rezultatima vrednovanja posljedica različitih svojstava CDA-ova ili posljedica različitih svojstava okruženja za vrednovanje.

Slika 8, koja je napravljena na temelju podataka iz prethodne tablice dane u potpoglavlju 2.1., prikazuje da je svega 13% autora za vrednovanje CDA-ova koristilo neki poznati referentni katalog. Svi ostali su konstruirali svoj vlastiti referentni katalog (ukoliko su uopće evaluirali referentnim katalogom), koji u pravilu nije javno dostupan te ga ostali koji se bave istraživanjem CDA-ova ne mogu koristiti. Također, svega 6% autora je za vrednovanje CDA-ova koristilo F-ROC ili A-ROC krivulje, dok su ostali koristili raznorodne mjere koje u praksi nisu ili su vrlo teško usporedive.



Slika 8. Podjela na evaluacije uz korištenje referentnih kataloga, F-ROC i A-ROC krivulja, te ostalo (neko drugo vrednovanje ili se vrednovanje uopće niti ne koristi). Brojevi u zagradama odgovaraju broju radova iz prethodne tablice.

Time se dolazi do zaključka da rezultati navedenih CDA-ova u praksi nažalost jednostavno nisu usporedivi u objavljenom obliku, a da se ti rezultati mogu koristiti kako bi se samo približno procijenilo koliko je koji CDA dobar u detekciji kratera. Stoga se u ovome radu posebna pažnja posvetila i ovoj problematici, a kako bi se rezultati ovoga rada mogli na zadovoljavajući način usporediti s rezultatima koje su postigli drugi. Za to je naravno preduvjet da se i drugi drže prethodno navedenih smjernica.

2.6. Zaključak

Problem detekcije kratera je kompleksan i rješavanju istog pristupilo je više grupa znanstvenika iz raznih institucija širem svijeta, a sa svrhom automatske katalogizacije kratera iz svakim danom sve veće količine optičkih, topografskih i drugih slika gdje više nije zadovoljavajuće sve ručno obrađivati. Ova istraživanja posebno su se intenzivirala tijekom zadnjeg desetljeća, kada je zahvaljujući brojnim novim lunarnim i planetarnim misijama postalo dostupno za redove veličine više podataka nego što ih je bilo ranije. No još uvijek ne postoje CDA-ovi koji se sa svojim rezultatima detekcije mogu mjeriti s rezultatima ručnog katalogiziranja kratera.

Postoji i dosta srodnih istraživanja kojima je bio cilj iz lunarnih i planetarnih slika detektirati vulkane (Burl et al., 1998), pješčane dine (Bandeira et al., 2010b), poligone (Pina et al., 2006) i slično, no niti to nije bitno doprinijelo postignuću zaista učinkovite metode za detekciju kratera.

Dodatan problem je raznolika moguća primjena CDA-ova, tako da relativno dobro rješenje za jednu vrstu problema, kao što je datiranje planetarne površine (Bijaoui i Froeschle, 1980; Sawabe et al., 2006), nije nužno dobro za ostale, kao što je autonomno slijetanje na planete (Cheng et al., 2004, 2005; Johnson et al., 2005) ili asteroide (Leroy et al., 2001). Primjerice kod slijetanja na planete i asteroide bitan je rad algoritma u realnom vremenu, a je li detektiran objekt krater ili to nije, manje je važno od robusnosti algoritma i ponovljivosti njegovih rezultata.

Iz ovoga se može zaključiti da područje istraživanje algoritama za detekciju kratera ne samo da je bilo vrlo zanimljivo za ovaj rad, nego da će vrlo izgledno biti zanimljivo i za buduća znanstvena istraživanja.

Detekcija kratera važna je za lunarna i planetarna istraživanja, ali je isto tako važna i za Zemlju. Pretpostavlja se da ima još dosta kratera koji nisu pronađeni (Stewart, 2011), i automatska pretraga dostupnih topografskih i drugih slika potencijalno može doprinijeti tome da se otkriju. Važnost ovih istraživanja je i u tome što se između ostalog i na temelju postojeće populacije poznatih kratera na Zemlji procjenjuje i vjerojatnost udara meteora određene veličine u određenom vremenskom razdoblju (na primjer unutar sljedećih 10, 100 ili 1000 godina), a ovisno o tim procjenama i određuju se sredstva za istraživanje efikasnog sprječavanja udara (uništavanje meteora eksplozijom, promjena putanje na vrijeme kako ne bi udario u Zemlju, itd.).

3. OKOLINA ZA RAZVOJ ALGORITAMA ZA DETEKCIJU KRATERA

U ovom poglavlju opisuje se okolina za razvoj CDA-ova, kroz sljedeća potpoglavlja:

- 3.1. Uvod;
- 3.2. Početni referentni katalog s 17 582 kratera;
- 3.3. Kriteriji za odabir topografskih slika Marsa za razvojni poligon;
- 3.4. Mjera udaljenosti između kratera;
- 3.5. Površina ispod F-ROC krivulje kao mjera za vrednovanje;
- 3.6. Zaključak.

U potpoglavlju 3.1. daje se uvod u problematiku vrednovanja CDA-ova i opisuju osnovni problemi koji su ujedno bili i motivacija za rad na okruženju za razvoj i vrednovanje CDA-ova. S obzirom da je jedan od osnovnih uvjeta kvalitetnog vrednovanja CDA-a zadovoljavajući referentni katalog, u potpoglavlju 3.2. opisuje se kako je napravljen referentni MA17582GT katalog. U potpoglavlju 3.3. obrazlaže se odabir topografskih slika Marsa za ulazne podatke CDA-ova. Mjera udaljenosti između kratera definira se u potpoglavlju 3.4. i ukratko uspoređuje s mjerama koje su se koristile u prethodnim radovima. U potpoglavlju 3.5. obrazloženo je kako se konstruira F-ROC krivulja te kako se površina ispod iste može koristiti kao mjera za vrednovanje. U potpoglavlju 3.6. naveden je zaključak o postignutom s okolinom za razvoj CDA-ova, te odnos prema nastavku istraživanju ovoga rada.

3.1. Uvod

Kako je opisano u prethodnom poglavlju, postoji dosta radova vezanih za problematiku CDA-ova, no rezultate nije moguće upotrijebiti ili usporediti na jednostavan način.

Uobičajeni primjeri su kada autori nekog rada: (1) izaberu slike za vrednovanje njihovog CDA-a koje nisu prethodno bile korištene za vrednovanje nekog drugog CDA-a; (2) naprave svoj referentni katalog koji nije dostupan drugima koji rade na CDA-ovima; ili (3) registraciju između rezultirajućeg i referentnog kataloga naprave ručno ili algoritmom koji nije javno objavljen. Vrlo često uopće ne postoji neko formalno vrednovanje rezultata, nego se samo prikaže slika koja prikazuje kratere koje je CDA na njoj pronašao. Tablica 1 prikazuje i slučajeve kada niti to nije dostupno (CDA-ovi gdje pod vizualnom usporedbom nije upisano “da” nego “implicitno”).

U vrijeme kada je istraživanje CDA-ova bilo na samom početku, to je bilo prihvatljivo i razumljivo, jer se smatralo da je razviti CDA i nakon toga ga vrednovati relativno jednostavan zadatak. No vremenom se pokazalo, iako je već postojalo dosta radova vezano za CDA-ove, da se gotovo nijedan od njih ne koristi u praksi. Razlog su bili prilično lošiji rezultati CDA-ova od onih koje postiže trenirana osoba tijekom ručne katalogizacije kratera. Uobičajen primjer je CDA koji na nekoj slici relativno dobro detektira većinu kratera s relativno malim brojem pogrešnih detekcija, a onda na nekoj drugoj slici koja je zbog prirode instrumenta bitno tamnija, svjetlija, ili ima različite artefakte kao što su izraziti šum i izobličenja, ne daje gotovo nikakve upotrebljive rezultate.

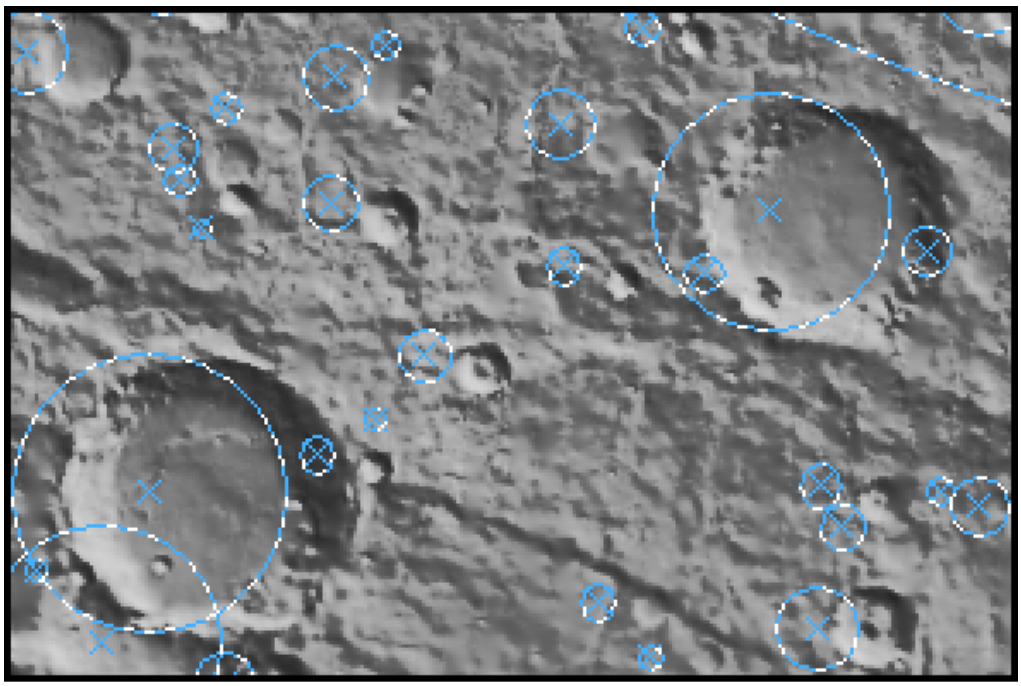
Time je bio logičan zaključak da postojeća praksa u vrednovanju CDA-ova nije zadovoljavajuća i da je vrednovanje CDA-ova samo po sebi znanstveno pitanje kojemu je potreban odgovarajući pristup.

U ovome poglavlju bit će opisani rezultati temeljnih istraživanja vrednovanja CDA-ova, a gdje je okolina za razvoj CDA-ova logični rezultat tih istraživanja, s obzirom da je prilikom razvoja CDA-a uvijek poželjno imati odgovarajuću metodologiju za njegovo vrednovanje kako bi se moglo vidjeti kako koja promjena metode ili uključivanja neke nove metode utječe na sveukupna svojstva CDA-a.

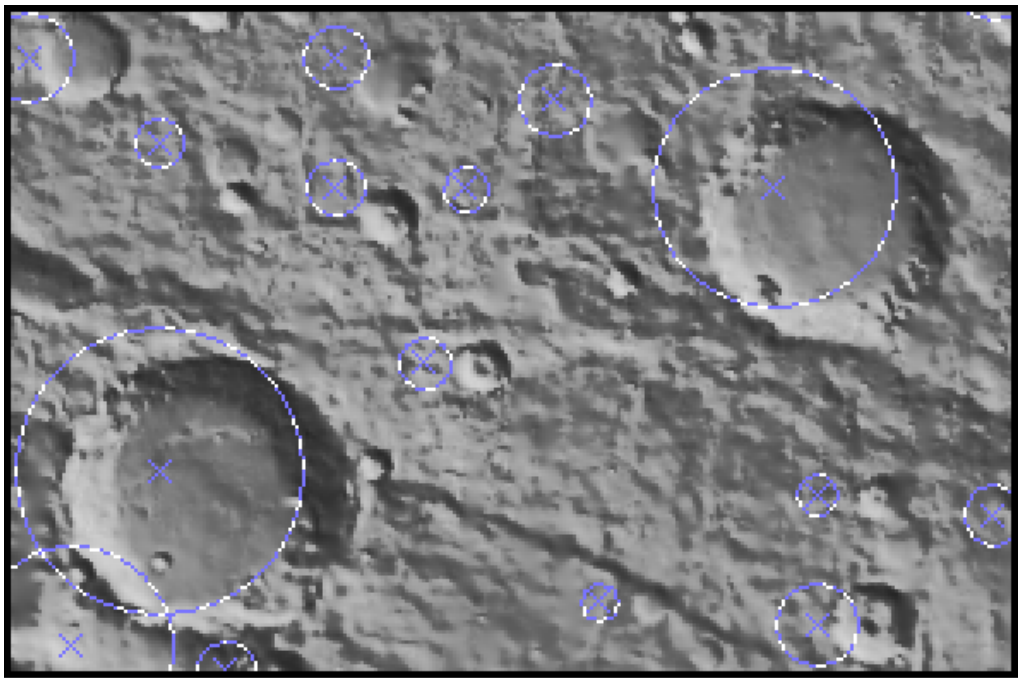
Sama okolina za razvoj uspješno je korištena u nastavku ovoga rada, što je jedan od pokazatelja i njezine praktične primjene.

3.2. Početni referentni katalog s 17 582 kratera

Referentni katalog preduvjet je da bi se mogao vrednovati i razvijati CDA. Za vrednovanje se nisu mogli koristiti već dostupni katalozi MA42279B i MA19308R (opisani su u potpoglavlju 7.2.). Slika 9 pokazuje kako krateri iz MA42279B nisu poravnati s MOLA podacima. Slika 10 prikazuje da poravnati nisu niti krateri iz MA19308R. Razlog neporavnatosti su optičke slike (neregistrirane s MOLA podacima) iz kojih su nastali ti katalozi. To je poseban problem za male kratere.

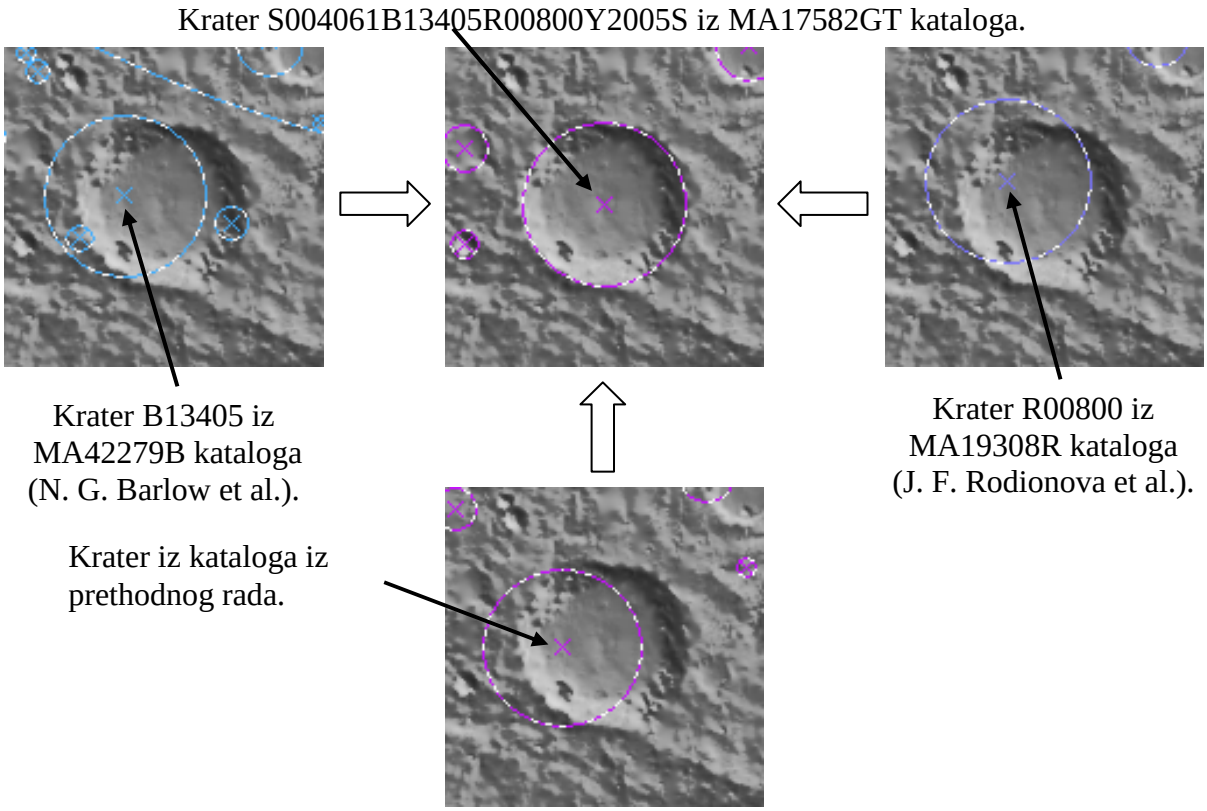


Slika 9. Neporavnatost kratera iz MA42279B i MOLA podataka. © 2008 Elsevier (Salamunićcar i Lončarić, 2008d).



Slika 10. Neporavnatost kratera iz MA19308R i MOLA podataka. © 2008 Elsevier (Salamunićcar i Lončarić, 2008d).

Katalog kratera za svaki krater sadrži barem koordinate centra i radijus. Koordinate centra i radijus predstavljaju kružnicu koja se može prikazati na slici preko kratera. Za kružnicu prikazanu na slici možemo reći da je pridijeljena krateru s obzirom da je širina ruba kratera uobičajeno veća od širine jednog slikovnog elementa koja definira širinu kružnice. Poravnatost kratera podrazumijeva da krateru pridijeljena kružnica prelazi po sredini ruba kratera koji se nalazi na slici, a primjer je prikazan na sljedećoj slici (sredina gornjeg retka). Kod neporavnatosti kratera to nije slučaj, a primjeri su također prikazani na sljedećoj slici (sve osim sredine gornjeg reda). Neporavnatost kratera uzrokuje problem koji bi se javio prilikom vrednovanja CDA-ova, jer zbog neporavnatosti ne bi bilo moguće automatskom procedurom precizno uparivati kratere iz referentnog kataloga s rezultatima CDA-a, kako bi se vrednovale njegove karakteristike. Ovaj problem riješen je registracijom kratera iz MA42279B i MA19308R kataloga (te kataloga prethodnog rada) u MA17582GT katalog. Slika 11 prikazuje postupak registracije kratera s MOLA podacima. Postupak registracije odradio se ručno kako bi se izbjeglo da eventualne pogreška kod pojedine automatske registracije dovede do pogreške u referentnom katalogu te time i do pogreške prilikom vrednovanja CDA-ova. Rezultat registracije je poravnatost kratera, koja uz pomak pridijeljene kružnice podrazumijeva po potrebi i korekciju njenog radijusa. Također, ime rezultirajućeg kratera sadrži imena kratera korištenih prilikom registracije, kako bi se za svaki krater iz referentnog kataloga znalo na temelju kojih je kratera iz korištenih kataloga registriran. Na ovaj način registrirali su se samo oni krateri koji su se nalazili i u MA42279B katalogu i u MA19308R katalogu, kako bismo imali dvostruku potvrdu da su se zaista samo krateri registrirali u rezultirajući katalog. Rezultat je registracija 17 582 kratera u MA17582GT katalog.

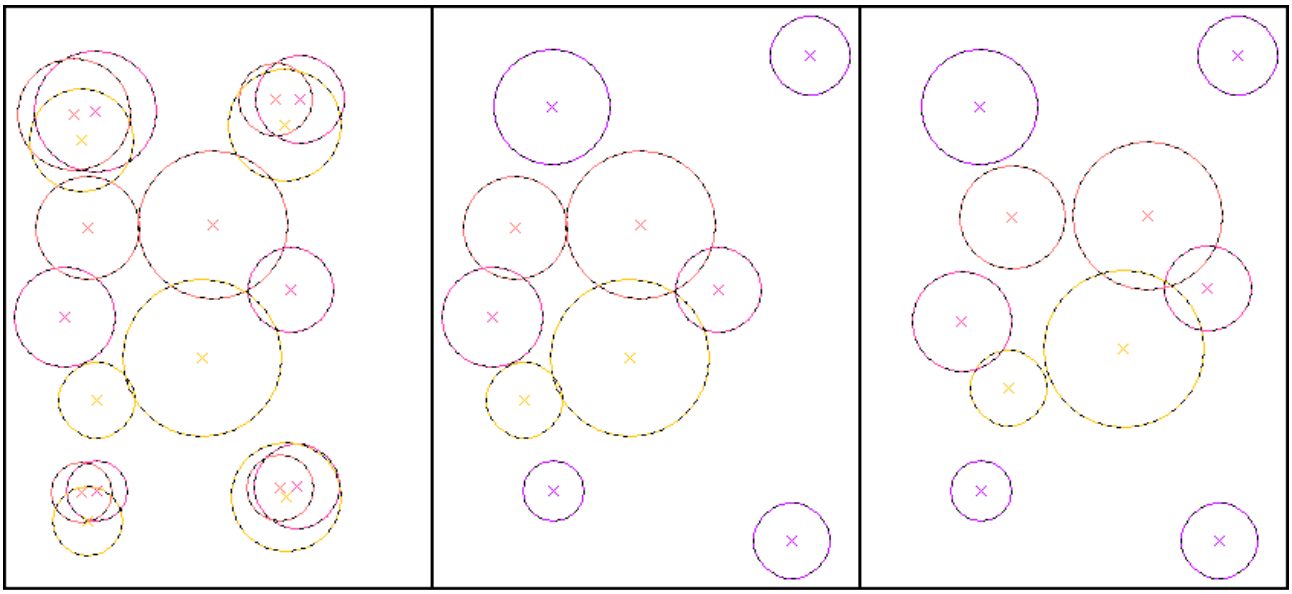


Slika 11. Registracija kratera u MA17582GT katalog. © 2008 Elsevier (Salamunićcar i Lončarić, 2008d).

S obzirom da se prethodni postupak registracije odrađivao ručno, postojala je mogućnost da su preostali krateri koji se nalaze i u MA42279B, i u MA19308R katalogu.

Kako bi se to izbjeglo, razvijena je metoda za automatsko pomicanje još neregistriranih kratera ovisno o položaju već registriranih. Slika 12 prikazuje primjer automatskog pomicanja kratera. U lijevom dijelu slike prikazani su neregistrirani krateri. U srednjem dijelu prikazan je međukorak gdje su četiri kratera u uglovima registrirani, dok su ostali još uvijek na prethodnim lokacijama. U desnom dijelu prikazan je rezultat algoritma koji je pomaknuo još neregistrirane kratere. Različite boje predstavljaju kratere koji potječu iz različitih kataloga, stoga se pomak kratera koji su registrirani računa zasebno za svaki od kataloga, kako bi se preostali krateri automatskom procedurom mogli pomaknuti na, po mogućnosti, najtočniju novu lokaciju.

Cilj ove metode je da se još uvijek neregistrirani krateri iz kataloga MA42279B i MA19308R bolje poravnaju s MOLA podacima. To je posebno pomoglo tijekom registracije svih preostalih kratera iz kataloga MA42279B i MA19308R u sljedeće verzije referentnog kataloga, kada se vršila i registracija onih kratera iz MA42279B kataloga koji se ne nalaze u katalogu MA19308R, i obrnuto. Postupak registracije preostalih kratera olakšao se boljim (ali ne još sasvim potpunim) poravnanjem kratera: (1) time je manja potreba za njihovo pomicanje kod registracije, pa je sam postupak išao brže; i (2) bilo je lakše razaznavati kojem krateru sa slike odgovara koja pridijeljena kružnica iz korištenih kataloga. Ovo posljednje posebno je pomoglo kod vrlo malih kratera te kada je više kratera bilo blizu jedan drugom.

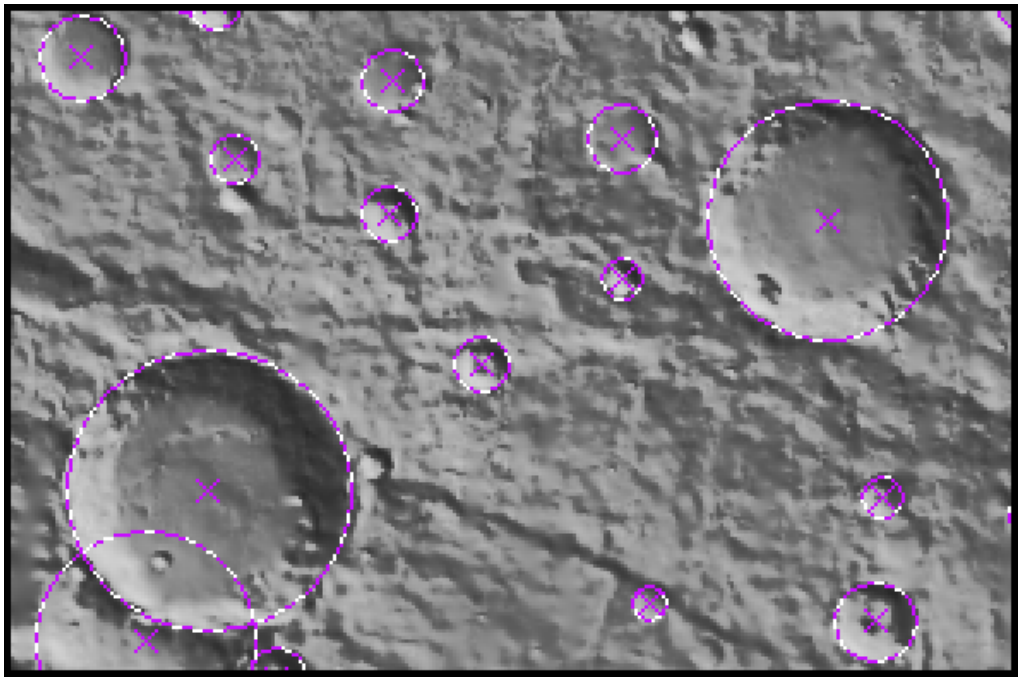


Slika 12. Automatsko pomicanje kratera prilikom registracije. © 2008 Elsevier (Salamunićcar i Lončarić, 2008d).

Rezultat registracije je MA17582GT katalog. Slika 13 prikazuje dio kataloga i MOLA globalne topografske slike. Krateri su poravnati s MOLA topografskom slikom, i time se mogu koristiti kao referentni katalog za vrednovanje CDA-ova. Također se može primijetiti da je katalog potpun za veće kratere (D > 10km). To znači da nema puno kratera koji se ne nalaze u njemu, što bi rezultiralo manje točnim vrednovanjem CDA-ova. Dodatna prednost ovog kataloga je višestruka provjerenost svih kratera (kako prilikom prve registracije u početne kataloge tako i tijekom registracije u MA17582GT), a što je također važno za kvalitetno vrednovanje CDA-ova.

Preostali krateri iz MA42279B i MA19308R kataloga, koji nisu bili registrirani u MA17582GT katalog, kasnije su registrirani u njegovu sljedeću verziju, kako je opisano u potpoglavlju 7.5. No to nije bilo presudno za daljnji razvoj CDA-ova ovoga rada, s obzirom da je katalog MA17582GT obuhvaćao skoro sve kratere veće od 10 km u dijametru te sa statističkog stajališta dovoljan broj kratera za razvoj svih modula CDA-ova na zadovoljavajući način. S druge strane, za što kvalitetnije vrednovanje CDA-ova posebno je važan što potpuniji referentni katalog.

To je ujedno bila i osnovna motivacija za dodatne registracije i proširenja referentnog kataloga prethodno neregistriranim kraterima.

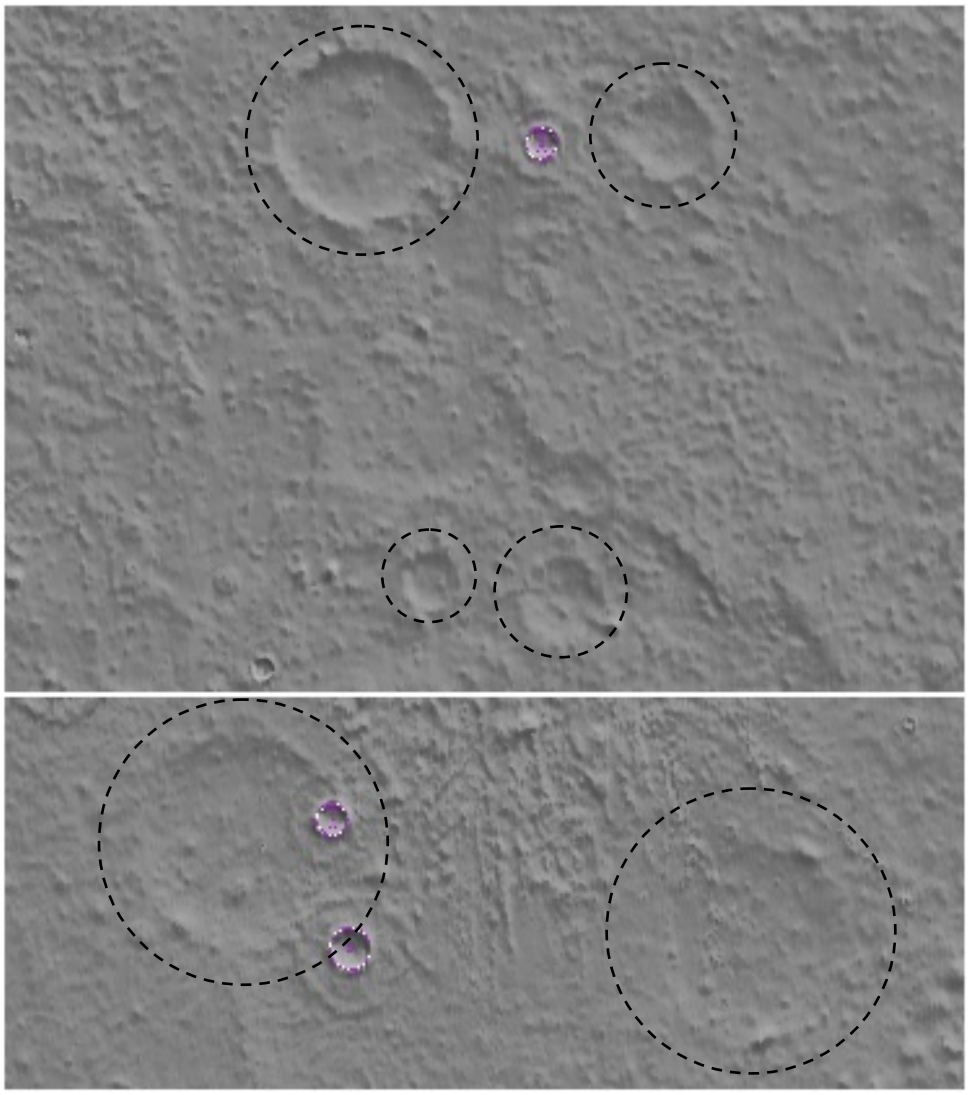


Slika 13. Krateri iz rezultirajućeg kataloga MA17582GT koji su poravnati s MOLA globalnom topografskom slikom. © 2008 Elsevier (Salamunićcar i Lončarić, 2008d).

3.3. Kriteriji za odabir topografskih slika Marsa za razvojni poligon

Iz iznesenog u prethodna dva poglavlja mogu se revidirati kriteriji za odabir topografskih slika Marsa za razvojni poligon: (1) topografske slike potrebne su za vrednovanje CDA-ova koji detektira kratere upravo iz topografskih slika, a u vrijeme ustroja okruženja za razvoj i vrednovanje CDA-ova one su postojale samo za Mars u horizontalnim rezolucijama do 1/64°; (2) Mars ima raznolike kratere zbog raznovrsnih geoloških procesa kroz njegovu povijest, pa je stoga prikladniji za vrednovanje CDA-ova od topografskih slika planetarnih tijela s manje raznovrsnih kratera; (3) koristeći katalogizirane kratere i topografske slike na relativno jednostavan način mogu se za svaki krater izmjeriti neke značajke, primjerice omjer dubine i dijametra, kako bi se koristile u lunarnim i planetarnim znanstvenim istraživanjima; (4) vrlo je izgledno da će CDA-ovi pronaći prethodno nekatalogizirane kratere.

Primjer posljednjeg su kružne depresije koje je pronašao Frey et al. (2002). Slika 14 prikazuje tri kratera iz MA17582GT i šest kratera koji nisu bili katalogizirani u tom katalogu. To je također zanimljivo sa stajališta CDA-a, jer postoji mogućnost za njegovu praktičnu primjenu, za traženje još nekatalogiziranih kratera kako bi se upotpunio referentni katalog.



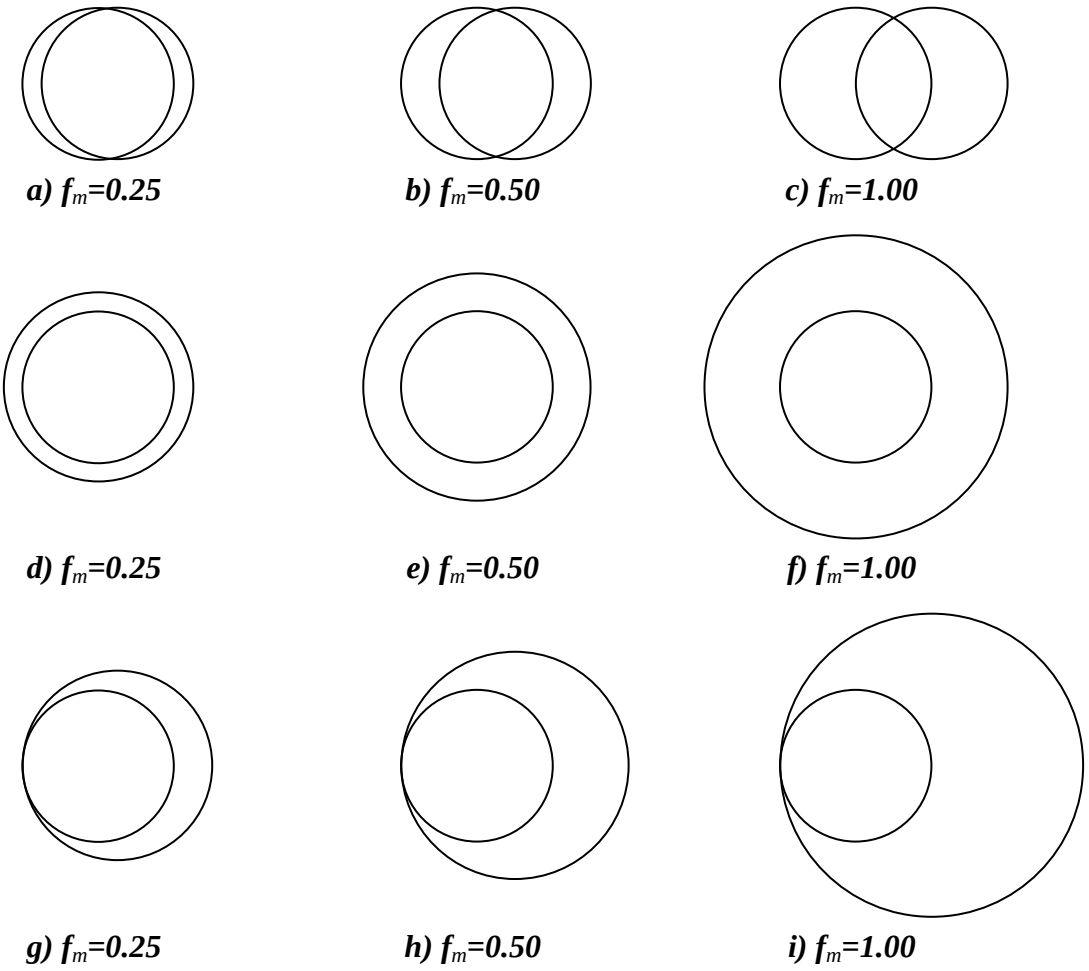
Slika 14. Tri kratera katalogizirana u MA17582GT i šest kružnih depresija koje su pronašli Frey et al. (2002), a koje još nisu bile katalogizirane u tom katalogu. © 2008 Elsevier (Salamunićcar i Lončarić, 2008d).

3.4. Mjera udaljenosti između kratera

Definicija mjere udaljenosti također je jedan od preduvjeta za vrednovanje CDA-a. Mjera udaljenosti do koje se došlo analizom kratera iz dostupnih kataloga i iz eksperimentalnih rezultata dana je formulom (1) (Salamunićcar i Lončarić, 2008d). Neka su r_1 i r_2 polumjeri dva kratera, gdje je $r_1 \geq r_2$, neka je d udaljenost između centra prvog i drugog kratera, i neka je $f_c \geq 0$ granična konstanta. Tada se za dva zapisa iz kataloga kratera (odnosno dvije kružnice gdje je svaka definirana koordinatama centra i radijusom) smatra da pripadaju istom krateru ako i samo ako je zadovoljena formula (1) i $f_m < f_c$. Ova mjera slična je mjerama koje su u svojim radovima koristili Burl et al. (2001) te Wetzler et al. (2005), koji su koristili omjer površine presjeka dva kruga i površine većeg kruga, gdje su krugovi određeni kružnicama pridijeljenim kraterima. Prednost mjere ovoga rada je mogućnost njezina korištenja i kada nema presjeka površine, što se zbog pogrešaka u podacima ili katalozima može dogoditi, i to prvenstveno kod malih kratera.

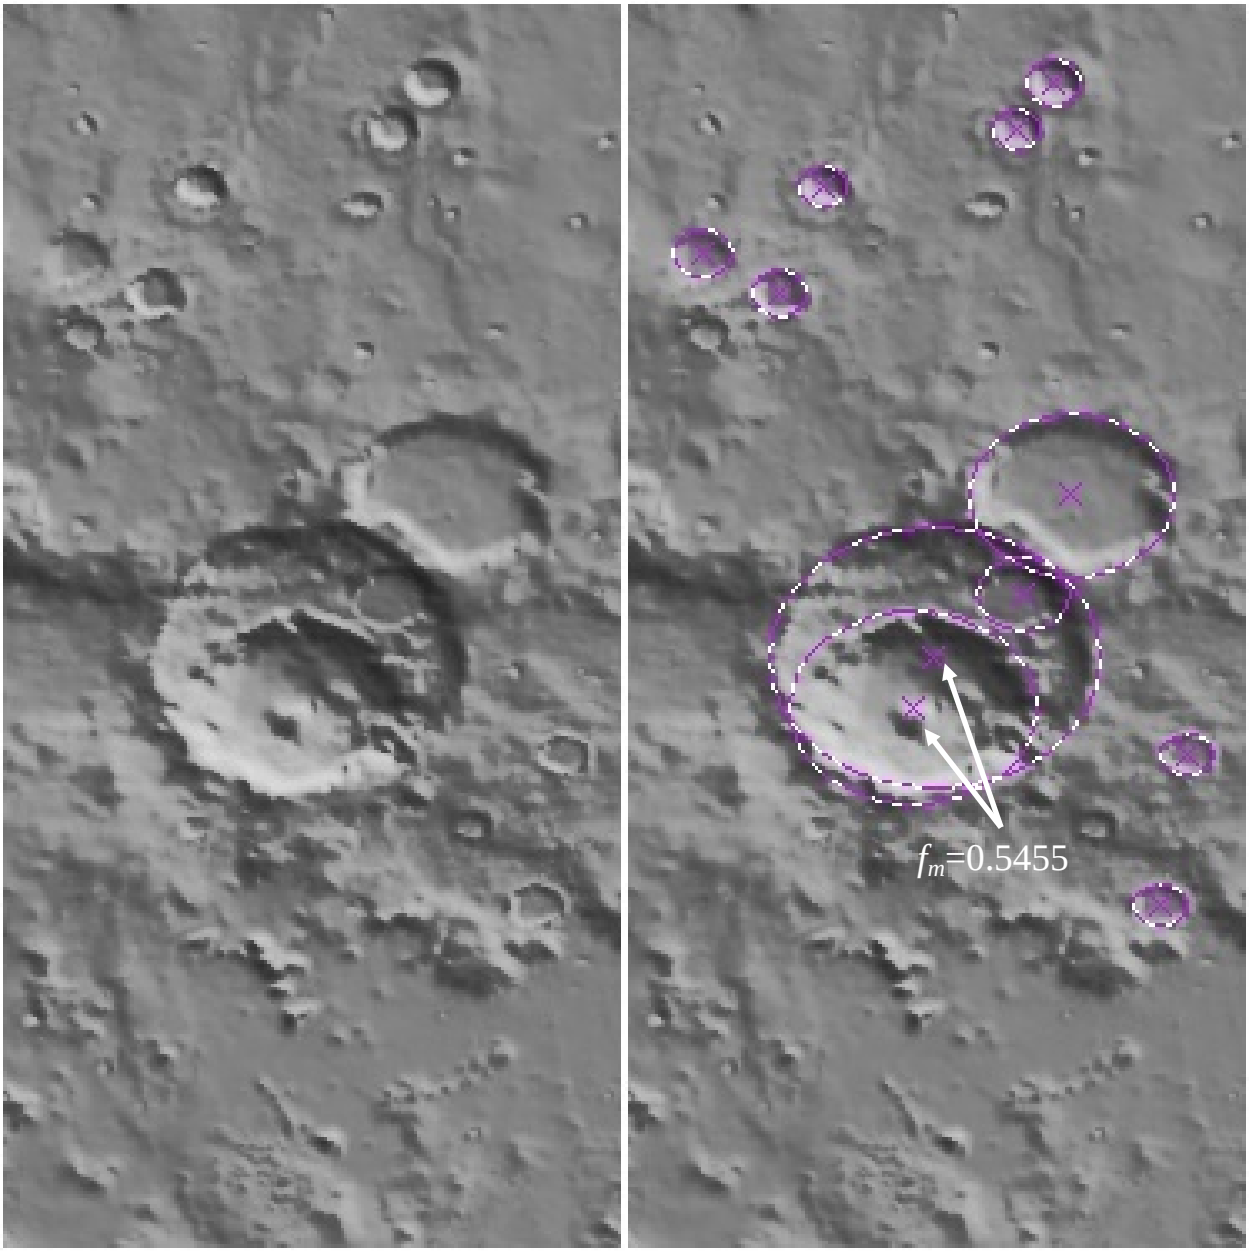
$$f_m = maks(\frac{r_1}{r_2} - 1, \frac{d}{r_2}) \tag{1}$$

Slika 15 prikazuje nekoliko primjera kružnica koje predstavljaju kratere i izmjerenu udaljenost između istih. Kao što se iz slike vidi, male vrijednosti f_m znače da su krateri dobro poravnati, a velike da nisu.



Slika 15. Slučajevi za f_m = 0.25 (*a*, *d* i *g*), f_m = 0.50 (*b*, *e* i *h*) i f_m = 1.00 (*c*, *f* i *i*). Za slučajeve *g*, *h* i *i* je zadovoljeno $f_m = r_1/r_2 - 1 = d/r_2$. © 2008 Elsevier (Salamunićcar i Lončarić, 2008d).

Uz to što se mjera udaljenosti može koristiti za uparivanje kratera koji su rezultat CDA-a s kraterima iz referentnog kataloga tijekom vrednovanja CDA-a, ona se može koristiti i za provjeru konzistentnosti kataloga. Slika 16 prikazuje topografiju prije i nakon registracije kratera iz MA17582GT kataloga, te dva kratera iz MA17582GT s najmanjom međusobnom udaljenosti f_m. Ta dva kratera pronađena su izračunom mjere udaljenosti za sve moguće parove kratera iz MA17582GT kataloga pri čemu se izdvojila najmanja. Time su se pronašla ona dva kratera koji su u LLR prostoru najbliži jedan drugom kada je mjera udaljenosti definirana formulom (1). Ista je svega neznatno veća od 0.5. Stoga ako unutar kataloga postoje parovi kratera gdje je f_m manji od 0.5, najvjerojatnije se radi o duplim unosima za isti krater. Na temelju ove analize došlo se do zaključka da se i kod vrednovanja CDA-ova rezultati detekcije uparuju s kraterima iz referentnog kataloga upravo do $f_c = 0.5$. Iako je ista svega neznatno manja od najmanje izmjerene iz MA17582GT kataloga (0.5455, kako je prikazano na sljedećoj slici), vrijednost od 0.5 se pokazala dobrom odlukom i nakon što su katalozi za Mars postali bitno potpuniji i nakon što su se počeli katalogizirati i krateri drugih planetarnih tijela (Mjesec, Fobos, Venera, Zemlja).



Slika 16. Dva kratera iz MA17582GT između kojih je najmanji f_m. © 2008 Elsevier (Salamunićcar i Lončarić, 2008d).

3.5. Površina ispod F-ROC krivulje kao mjera za vrednovanje

Krivulja F-ROC (odziv CDA-a) jedna je od metoda koje se mogu koristiti za vrednovanje CDA-ova. Horizontalna os sadrži broj pogrešnih detekcija, a vertikalna os broj točnih detekcije. Do broja pogrešnih i točnih detekcija dolazi se usporedbom odziva CDA-a (rezultirajući katalog) s referentnim katalogom. Pritom se svakom krateru iz rezultirajućeg kataloga traži odgovarajući iz referentnog, za koji je udaljenost definirana formulom (1) najmanja. Ukoliko je $f_m < f_c$, pri čemu je $f_c = 0.5$, utoliko se smatra da je detektirani krater točna detekcija, a u protivnom da je pogrešna. Pritom se svaki krater iz rezultirajućeg kataloga uparuje s najviše jednim kraterom iz referentnog, s tim da ovo pravilo mora biti zadovoljeno i u suprotnom smjeru.

Imamo dva karakteristična slučaja: (1) kada je jedna krivulja (odziv) uvijek lijevo i gore od druge, i (2) kada se krivulje (odzivi) međusobno sijeku.

Ukoliko je jedna krivulja (odziv) uvijek lijevo i gore od druge, utoliko se smatra da je CDA kojem pripada bolji. Razlog je što u tom slučaju za bilo koji broj pogrešnih detekcija imamo više točnih detekcija, te je stoga bolji CDA koji ima ova svojstva u odnosu na neki drugi.

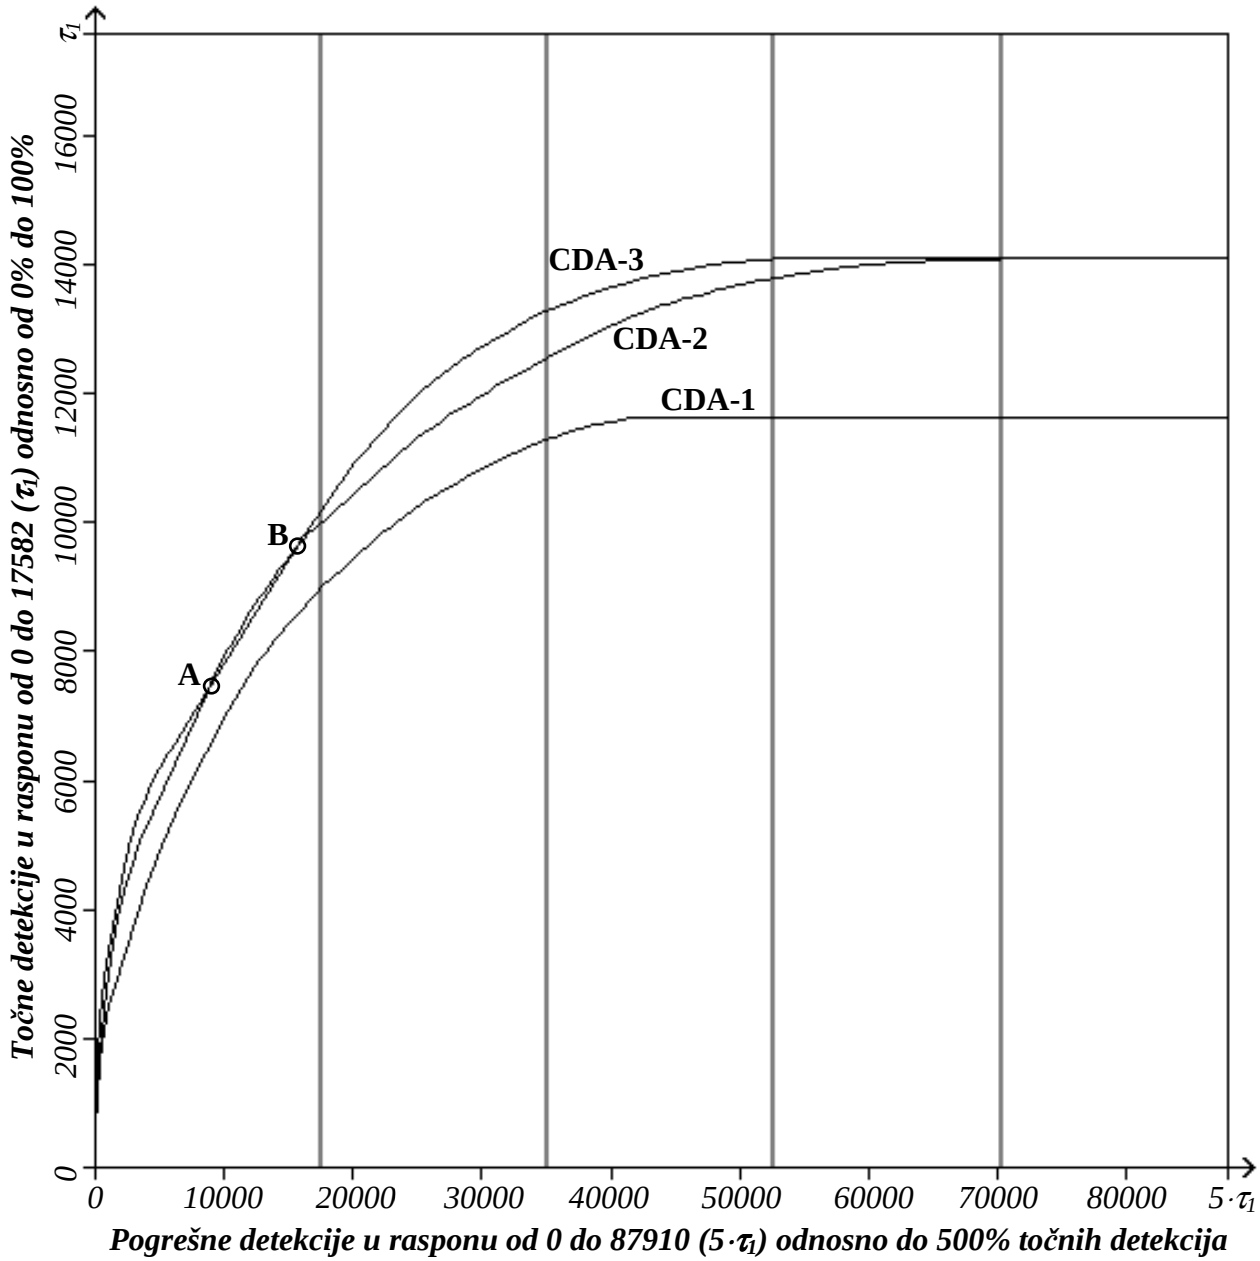
Ako su dva CDA-a otprilike podjednakih svojstava, krivulje (odzivi) se mogu međusobno presijecati, jednom ili više puta. To znači da postoji režim rada u kojem je prvi CDA bolji od drugog, kao i režim u kojem je drugi bolji od prvog. Primjerice može se dogoditi, ako nas zanima režim rada gdje je malen broj pogrešnih detekcija, da je bolji prvi CDA, a ako nas zanima režim rada gdje je cilj detekcija što većeg broja kratera, da je bolji drugi CDA. Kako bi se u takvim slučajevima mogla definirati mjera koja će kao rezultat dati odgovor na pitanje koji CDA je sveukupno bolji, u tu svrhu uvodi se površina ispod F-ROC krivulje.

Ukoliko se računa površina, koja se može izraziti kao postotak ukupne površine (duljina horizontalne osi pomnožena s visinom vertikalne), utoliko je važno uzeti u obzir da ona kod F-ROC krivulje ovisi o tome koliki dio horizontalne osi se uzme u obzir. Vertikalna os definirana je brojem kratera u referentnom katalogu, što je najviše 17 582 točnih detekcija za MA17582GT. Horizontalna os nije ograničena, jer što je prag detekcije CDA-a niži, to on u principu može detektirati više kandidata za kratere, pri čemu je i postotak pogrešnih detekcija veći. No režim rada u kojem je broj pogrešnih detekcija veći, odnosno bitno veći od broja točnih detekcija, nas ne zanima. Razlog je što se u tom režimu CDA neće niti koristiti. S druge strane, ukoliko se prikaže odziv samo do 17 582 pogrešnih detekcija, utoliko se može dogoditi da se time prikaže samo dio odziva, što možda nije dovoljno ako nas zanima i mogućnost daljnjih poboljšanja CDA-a.

Svakom detektiranom krateru CDA ne mora pridruživati vjerojatnost da je detektiran objekt zaista krater. Tada F-ROC odziv u principu ima definiran samo jedan slikovni element, koji je određen brojem točnih i pogrešnih detekcija. Jedan način da se takav CDA usporedi s nekim drugim koji je rezultirao krivuljom je provjera položaja tog slikovnog elementa, to jest nalazi li se on iznad i lijevo (ne može biti iznad i desno ili ispod i lijevo jer je F-ROC monotono rastuća krivulja) od krivulje drugog CDA-a. No ako su nam potrebne površine, to nije dovoljno, pa se može konstruirati krivulja koja ide: (1) od ishodišta do tog slikovnog elementa; i (2) od tog slikovnog elementa horizontalno do desnog ruba grafa. Bolji pristup može se postići tako da se uzme u obzir da CDA u principu točnije detektira veće kratere jer su detaljnije prikazani u ulaznoj slici. To se može iskoristiti tako da se kraterima (prije F-ROC vrednovanja) umjesto vjerojatnosti da su točne detekcije (koja u tom slučaju nije poznata) pridijeli vrijednost koja je proporcionalna njihovoj veličini. Na taj način se dobiva veća površina ispod F-ROC krivulje i prirodniji odziv za takav CDA, odnosno realističnija usporedba dva CDA-a.

Slika 17 prikazuje rezultate vrednovanja koristeći F-ROC krivulju, odnosno površinu ispod iste. Iz slike se odmah vidi da je CDA-2 bolji nego CDA-1, te da je i CDA-3 također bolji nego CDA-1. Također, iz slike se odmah vidi i da je CDA-3 bolji nego CDA-2 u području od ishodišta

do slikovnog elementa *A*, da je CDA-2 bolji nego CDA-3 od slikovnog elementa *A* do slikovnog elementa *B*, te da je CDA-3 opet bolji od slikovnog elementa *B* do kraja prikazanog grafa. No to nam i ne daje odgovor je li sveukupno gledano bolji CDA-3 ili je ipak bolji CDA-2. Odgovor na to pitanje može nam dati površina ispod F-ROC krivulje kao nepristran kriterij. Kako je prethodno napomenuto, tada prije svega treba definirati do kuda se računa površina, vezano za horizontalnu os. Tri korisna pokazatelja su površina do $1 \cdot \tau_1$ (jer je to područje izvan kojeg je broj pogrešnih detekcija sigurno viši od točnih za sve CDA-ove), $2 \cdot \tau_1$ (jer time imamo uvid u dva puta veći odziv) i $5 \cdot \tau_1$ (jer time imamo uvid u pet puta veći odziv), dok odziv iza $5 \cdot \tau_1$ u praksi nije zanimljiv jer je broj pogrešnih detekcija prevelik u odnosu na broj točnih detekcija. Ako se promatra površina do $1 \cdot \tau_1$, CDA-3 je bolji nego CDA-2, kao i ako se promatra površina do $2 \cdot \tau_1$ i $5 \cdot \tau_1$. Time za sva tri predefinirana τ područja zaključujemo da je CDA-3 bolji nego CDA-2. Iznos τ_1 može se označiti kao 100% točnih detekcija, no horizontalna os nije ograničena, pa se pogrešne detekcije mogu izražavati samo kao postotak točnih detekcija, što je neuobičajeno. Vrednovanje kod kojeg obje osi idu od 0% do 100% koristilo se kasnije, kako je opisano u potpoglavlju 8.5.



Slika 17. Primjer korištenja F-ROC krivulje i MA17582GT kataloga za usporedbu CDA-ova.

3.6. Zaključak

Rezultati okruženja za razvoj CDA-ova uključuju: (1) izradu referentnog kataloga MA17582GT (Salamunićcar i Lončarić, 2006a); (2) radnu verziju CDA-a koji je temeljen na Frei-Chenovom (1977) detektoru ruba i Houghovoj transformaciji (Salamunićcar i Lončarić, 2006b), koji je bio potreban kako bi se eksperimentalno provjerilo funkcioniranje okruženja; (3) metodu koja automatski uparuje kratere iz rezultirajućeg i referentnog kataloga te prikazuje F-ROC krivulju i računa površinu ispod nje, kako bi se CDA-ovi mogli uspoređivati (Salamunićcar i Lončarić, 2006c).

Metode i pripadni podaci koji su razvijeni kako bi se osiguralo okruženje potrebno za razvoj CDA-ova (Salamunićcar i Lončarić, 2008d), uključuju: (1) globalne topografske slike (1/64° MOLA podaci) koje se koriste tijekom vrednovanja; (2) MA17582GT referentni katalog; (3) definiciju mjere udaljenosti između kratera definiranu formulom (1); (4) metodu za automatsku registraciju rezultirajućeg kataloga koji je rezultat CDA-a i kratera iz referentnog kataloga; (5) površinu ispod F-ROC krivulje kao mjeru CDA kvalitete.

Ovime je osigurana okolina za razvoj CDA-ova koja se koristila tijekom ovoga rada. Prije svega, koristila se prilikom razvoja temeljne metode za detekciju te pronalaženja optimalnih parametara svih korištenih detektora ruba i same metode. Također, navedena okolina koristila se kod daljnjih usavršavanja metode za detekciju kratera ovoga rada. U prvom koraku koristila se za vrednovanje metode za detekciju kratera temeljene na interpolaciji prilagođenoj obliku kratera i prethodnoj temeljnoj metodi za detekciju kratera. U drugom koraku koristila se za vrednovanje metode za detekciju kratera temeljene na stroju s potpornim vektorima i prethodnoj interpolacijskoj metodi za detekciju kratera. I na samom kraju, navedena okolina koristila se kao osnova za kasnije ustrojeno naprednije okruženje za vrednovanje CDA-ova.

4. I. KORAK: TEMELJNA METODA ZA DETEKCIJU KRATERA

U ovom poglavlju opisuje se temeljna metoda za detekciju kratera, koja je rezultat ovoga rada, i to kroz sljedeća potpoglavlja:

- 4.1. Uvod;
- 4.2. Predložena metoda;
- 4.3. Modul 1: Detekcija ruba i analiza gradijenta;
- 4.4. Modul 2: Izmijenjena Houghova transformacija;
- 4.5. Modul 3: Analiza morfometrije i parametarskog prostora;
- 4.6. Modul 4: Adaptivna korekcija vjerojatnosti;
- 4.7. Modul 5: Podešavanje kandidata za kratere pomicanjem;
- 4.8. Klasifikacija parametara i njihova zavisnost;
- 4.9. Primjer za topografsku sliku Marsa;
- 4.10. Zaključak.

U potpoglavlju 4.1. daje se uvod u problematiku i opisuje motivacija za rad na CDA-u, kao i ciljevi koji se njime žele postići. U potpoglavlju 4.2. opisuje se dijagram toka nove metode za detekciju kratera te ukratko opisuju njenih pet glavnih modula koji se detaljnije opisuju u potpoglavljima 4.3., 4.4., 4.5., 4.6. i 4.7. Klasifikacija parametara koji se koriste za konfiguriranje CDA-a, te izračunavanje njihovih optimalnih vrijednosti, opisano je u potpoglavlju 4.8. Primjer detekcije iz topografske slike Marsa dan je u potpoglavlju 4.9. U potpoglavlju 4.10. naveden je zaključak o postignućima temeljne metode za detekciju kratera.

4.1. Uvod

Prilikom izrade kataloga MA17582GT, pri čemu su se u njega unosili samo oni krateri koji se nalaze i u katalogu MA42279B i u katalogu MA19308R (opisani su u potpoglavlju 7.2), primijećeno je dosta slučajeva u kojima se neki krater nalazi u MA42279B, a ne nalazi u MA19308R, odnosno u kojima se nalazi u MA19308R, ali se ne nalazi u MA42279B. Za to mogu postojati dva razloga, ili zbog ljudske pogreške krater nije katalogiziran u oba kataloga, ili je zbog ljudske pogreške u jednom od kataloga završio zapis koji ne odgovara stvarnom krateru.

U oba slučaja dobar CDA može biti vrlo koristan alat osobi koja radi na takvim katalozima. U prvom slučaju on se može koristiti kako bi sistematično pretraživao površinu planetarnog tijela, kako bi autora kataloga upozorio na one kratere koje je previdio. Time dolazimo do kataloga koji je potpuniji, odnosno gdje je manji broj kratera određene veličine koji se ne nalaze u katalogu. U drugom slučaju on se može koristiti kako bi autor dodavao u katalog samo one kratere za koje je i CDA svojom detekcijom potvrdio da su krateri. Time dolazimo do kataloga koji sadrži manje pogrešnih unosa koji ne odgovaraju stvarnim kraterima.

Prethodni katalog, MA19308R, sadrži kratere gdje je $D > 10$ km, a MA42279B kratere gdje je $D > 5$ km. Iz ovoga bi se moglo zaključiti da će CDA pronaći relativno malo do sada nekatalogiziranih kratera gdje je $D > 10$ km, nešto više kratera gdje je $10 \text{ km} > D > 5$ km, i najviše kratera gdje je $D < 5$ km. No treba uzeti u obzir da su se prethodni katalozi, MA42279B i MA19308R, radili isključivo koristeći optičke slike. S obzirom na to da CDA koristi topografske slike, izvjesno je da će pronaći dosta i onih kratera koji nisu vidljivi na optičkim slikama zbog svoje velike erodiranosti. To je dodatna motivacija za rad na CDA-u koji će se koristiti u ove svrhe.

Kako je detaljnije opisano u potpoglavlju 2, postoji svega nekoliko CDA-ova koji mogu obraditi globalne podatke za cijelo planetarno tijelo. Jedini koji je bio napravljen prije početka rada na CDA-u iz ovog poglavlja je Michaelov (2003a) CDA. Njegov CDA je koristio topografske podatke, no koristio se samo za registraciju kratera iz MA19308R s MOLA podacima i nije rezultirao nekim novim katalogom. Jedini koji je napravljen paralelno s radom na CDA-u opisanom u ovom poglavlju je Stepinskov i Urbachov (2008) CDA. Njihov CDA je jedini alternativni CDA koji je pokazao da može obraditi globalne topografske podatke i rezultirao katalogom kratera - MA75919T. Time je opravdan razvoj novih metoda, odnosno poboljšavanje postojećih, što je dodatna motivacija za rad opisan u ovom poglavlju.

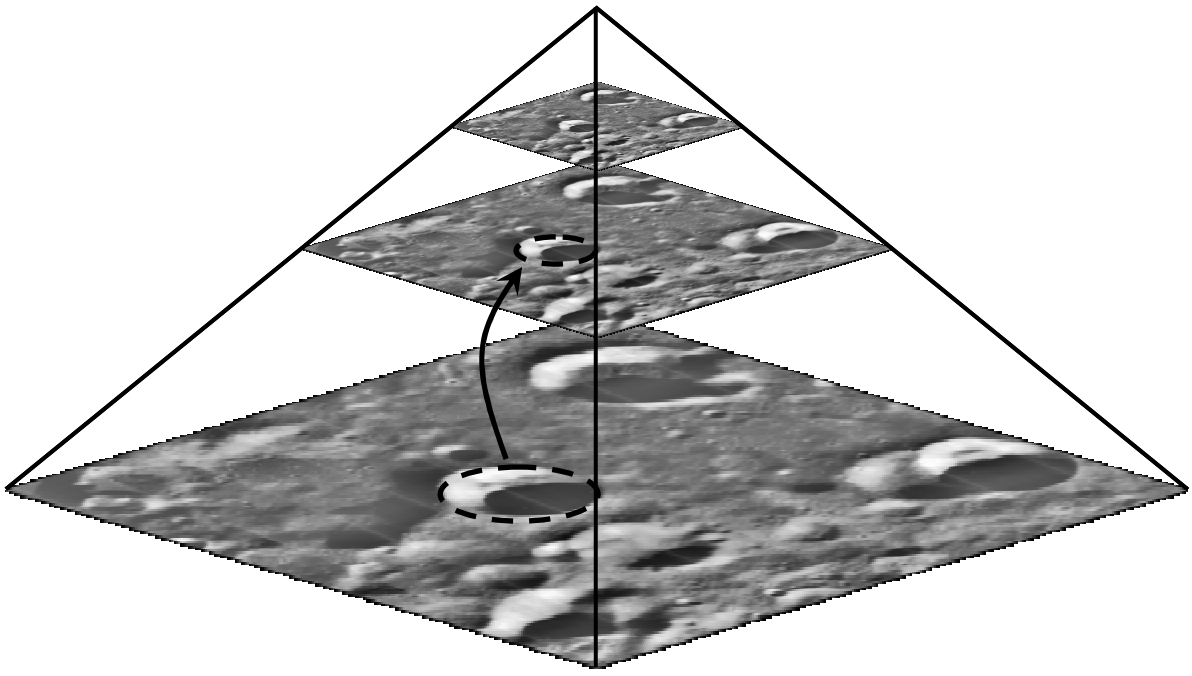
Prilikom razvoja CDA-a treba uzeti u obzir: (1) veliku raznolikost tipova kratera na Marsu s obzirom na njihovu unutrašnju morfologiju i strukturu izbačenog materijala (Barlow et al., 2003); (2) različitost oblika velikih i malih kratera (Melosh i Ivanov, 1999); (3) krateri mogu biti u različitim stanjima erodiranosti, od onih najmlađih koji su gotovo pa savršeno očuvani do danas, do onih najstarijih koji su gotovo u potpunosti izbrisani ili zatrpani drugim kraterima i geološkom procesima; (4) slučajeve kada se krateri preklapaju, kada je jedan djelomično izbrisao drugi ili se nalazi unutar njega, a veličinom su podjednaki; (5) važnost učinkovitosti algoritma kako bi se topografske slike za cijelo planetarno tijelo mogle obraditi u prihvatljivom vremenu.

Dodatni ciljevi su: (1) što manje pogrešnih i što više točnih detekcija, s time da ostane što manje nedetektiranih kratera; te (2) da se lokacije i dijametri kratera što preciznije odrede. No ovi ciljevi nisu toliko kritični kao prethodno navedeni, s obzirom na to da se svaki kandidat kojeg predloži CDA ručno provjerava prije nego što se obriše u slučaju pogrešne detekcije, ili doda u katalog u slučaju točne detekcije, s tim da mu se pritom (ako je potrebno) ručno korigiraju koordinate lokacije i iznos dijametra. No dobra svojstva i u ovim segmentima važna su, jer bitno skraćuju vrijeme osobi koja katalogizira kratere.

4.2. Predložena metoda

Ulaz metode su XML datoteka koja sadrži parametrizaciju CDA-a i ime datoteke koja sadrži globalnu topografsku sliku, a izlaz je XML datoteka koja sadrži popis detektiranih kratera, te za svaki koordinate, polumjer i procijenjenu vjerojatnost da je detekcija zaista krater.

Koristi se višestruko rezolucijska piramidalna obrada slika. Stoga su među ostalim ulazni parametri u CDA r_1 i r_2. CDA prvo na cijeloj slici traži sve kratere kojima je radijus (u daljnjem tekstu: r) jednak r_1 slikovnih elementa, nakon toga sve kratere kojima je r od r_1 veći za 1 slikovni element, pa za 2 slikovna elemenata, i na kraju tako sve do onih kratera kojima je r jednak r_2 slikovnih elementa. Početno se koristio algoritam koji bi prvo za danu lokaciju pretraživao područje od r_1 do r_2, pa za susjedni slikovni element isto, i tako za cijelu sliku. No taj algoritam se pokazao neučinkovit jer zahtijeva više radne memorije. Nakon što se na početnom DEM-u obrade sve potencijalne detekcije gdje je $r_1 \leq r \leq r_2$, DEM se smanji na polovicu horizontalne rezolucije, r se postavi na polovicu od r_2, i cijeli postupak se nakon toga ponavlja. Na ovaj način sistematično se pretražuju krateri svih veličina, jer krater koji je na nekom DEM-u velik r_2 slikovnih elemenata, nakon što se smanji horizontalna rezolucija na pola, velik je upravo $r_2/2$ slikovnih elemenata. Na početku razvoja CDA-a, koristilo se područje za r_1 i r_2, od 5 do 10 slikovnih elemenata. Nakon što se u potpunosti razvio CDA prikazan na prethodnoj slici, kao i svi pripadni moduli, te optimizirali i svi ostali korišteni parametri, pokazalo se da su optimalne vrijednosti za r_1 i r_2, od 2 do 28 slikovnih elemenata. Smanjivanjem r_1 s 5 na 2 slikovna elemenata postigla se detekcija daleko manjih kratera. Daljnje smanjivanje r_1 nema smisla, jer su već i krateri, kojima je r samo 2 slikovna elemenata, toliko mali da niti osoba koja katalogizira kratere ne može biti sigurna jesu li detekcije točne ili pogrešne, dok ne pogleda optičku sliku u višoj horizontalnoj rezoluciji. Povećavanjem r_2 s 10 na 28 slikovnih elemenata, postigla se bolja detekcija jer se morfometrijska mjerenja obavljaju nad podacima koji su uzorkovani u višoj horizontalnoj rezoluciji. Daljnje povećavanje r_2 se pokazalo nepotrebno, jer se kvaliteta detekcije tek neznatno poboljšava, dok se izvršavanje algoritma bitno usporava. Slika 18 prikazuje višestruko rezolucijsku piramidalnu obradu slike koja se koristi za detekciju kružnica (kratera) bez obzira na njihovu veličinu. Pritom se zanemaruje različitost oblika kratera.



Slika 18. Višestruko rezolucijska piramidalna obrada slike.

Slika 19 prikazuje dijagram toka predložene metode za detekciju kratera. Koraci višestruko rezolucijske piramidalne obrade slika definirani su varijablom *r*, kako je prethodno opisano. Na slici su prikazani i svi razvijeni moduli, koji su detaljnije opisani u sljedećim odlomcima.

Modul 1 – detekcija ruba i analiza gradijenta, detaljno je opisan u potpoglavlju 4.3. U ovom koraku se detektira rub te vrši dodatna analiza gradijenta kako bi se iznos i smjer istog dodatno mogli proslijediti izmijenjenoj Houghovoj transformaciji. Radi što učinkovitijeg računanja, obrada detekcije ruba odvija se samo jednom za topografsku sliku (DEM) u danoj horizontalnoj rezoluciji, tako da se ponavljanje algoritma od r_1 do r_2 odvija bez ponovnog računanja ruba. Kod primjerice Cannyjevog detektora ruba, ako parametre Gaussove funkcije koja se koristi za detekciju ruba optimiziramo za što bolju detekciju velikih kratera, izvjesno je da isti parametri neće biti optimalni i za male kratere, i obrnuto. No u praksi se pokazalo da se, nakon što se dobro podese pragovi detektora ruba, isti može zadovoljavajuće koristiti za cjelokupno područje za r_1 i r_2, od 2 do 28 slikovnih elemenata.

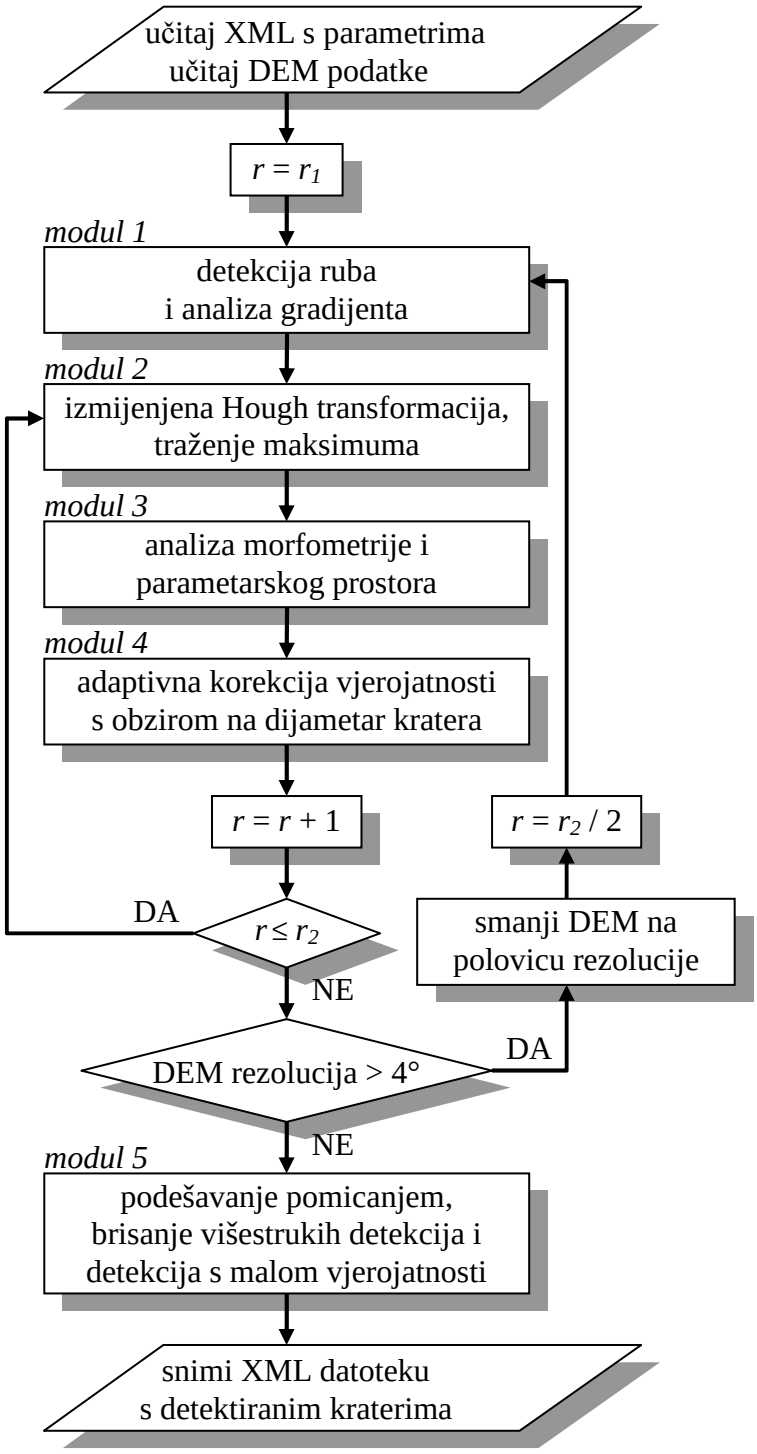
Modul 2 – izmijenjena Houghova transformacija, detaljno je opisan u potpoglavlju 4.4. Ulazni podaci su detektirani rubovi i pridruženi gradijenti, a izlaz je parametarski prostor gdje maksimumi iznad odgovarajućeg praga odgovaraju centrima detektiranih kratera. Maksimum je najizraženiji upravo kada *r* odgovara polumjeru kratera, a udaljavanjem *r* od polumjera, oblik kojeg tvore vrijednosti u parametarskom prostoru prelazi iz stošca u kružni vijenac, gdje maksimum prestaje biti jedini lokalni maksimum u danoj okolini i ima manji iznos. Problem detekcije kratera i za nešto manji odnosno veći radijus od stvarnog, rješava se analizom parametarskog prostora (modul 3) te podešavanjem pomicanjem (modul 5). Ovaj problem rješava se i automatskim uklanjanjem duplih detekcija, gdje se od više detekcija s udaljenosti u LLR prostoru manjom od 0.5, izračunatom formulom (1), uzima samo ona s najvećom pridijeljenom vjerojatnosti.

Modul 3 – analiza morfometrije i parametarskog prostora, detaljno je opisan u potpoglavlju 4.5. Ako se uz sam krater uspije detektirati i njegov rub, odnosno centralno uzvišenje, veća je vjerojatnost da je detektiran objekt krater. Isto tako, što je oblik detektiranog kratera cirkularniji, to je veća vjerojatnost da je detektiran objekt krater. Istraživanje je pokazalo da je vjerojatnost da je detektiran objekt krater veća kada je oblik koji tvore vrijednosti u parametarskom prostoru cirkularniji oko lokalnog maksimuma, pa se i tu provode pripadna mjerenja. Ovim korakom iznos maksimuma u parametarskom prostoru dodatno se korigira ovisno o rezultatu analize morfometrije i parametarskog prostora. Ako se primjerice uspije detektirati rub kratera ili njegovo centralno uzvišenje, povećava se pridijeljena vjerojatnost da je detektiran objekt krater, a u protivnom se smanjuje. Također, pridijeljena vjerojatnost da je detektiran objekt krater povećava se ako su vrijednosti topografske slike cirkularne u odnosu na središte detekcije, a u protivnom se smanjuje. Na isti način se uzima u obzir i cirkularnost vrijednosti u parametarskom prostoru te ostale analize morfometrije. Time se dodatno poboljšavaju sveukupna svojstva CDA-a.

Modul 4 – adaptivna korekcija vjerojatnosti, detaljno je opisan u potpoglavlju 4.6. Ovim korakom obrade se kalibrira CDA ovisno o tome želimo li prvenstveno detektirati velike, srednje ili male kratere. Ovime se može i dodatno uzeti u obzir činjenica da CDA ne može kratere velike svega nekoliko slikovnih elemenata detektirati jednako uspješno kao i one prikazane daleko većim brojem slikovnih elemenata, te se kalibracijom u tom smislu dodatno usklađuju svojstva CDA-a u detekciji velikih i malih kratera. Ovim korakom obrade dodatno se korigira pridijeljena vjerojatnost da je detektiran objekt krater, dok se ostale značajke detektiranih kratera ne mijenjaju. U osnovi, ovaj korak obrade za najveće kratere ne mijenja pridijeljenu vjerojatnost da je detektiran objekt krater, dok za srednje i male kratere iznos vjerojatnosti smanjuje to više što je detektiran objekt manjeg radijusa. Sama kalibracija vrši se odabirom faktora za koji će se pridijeljena vjerojatnost smanjivati, a gdje sam faktor ovisi o dijametru detektiranog kratera.

Modul 5 – podešavanje kandidata za kratere pomicanjem, detaljno je opisan u potpoglavlju 4.7. Ovim korakom obrade se što preciznije određuju položaj (koordinate) i dijametar detektiranog

kratera. Algoritam ispituje mogućnost da je bolja detekcija nešto manji ili veći krater, na danoj ili susjednoj lokaciji, i to iterativno ispituje dok ne nađe lokalni maksimum, odnosno optimum. Samo ispitivanje sastoji se od ponovne analize morfometrije kratera, kao što su njegov rub, centralno uzvišenje, cirkularnost, i slično, za nešto izmijenjene koordinate centra ili iznos radijusa kratera. Usporedbom analize za izvorne i nove vrijednosti koordinata središta i dijametra donosi se odluka o uzimaju novih vrijednosti ili prekidu iterativnog postupka. Rezultat su preciznije određene koordinate i dijametar, čime se olakšava kasnija ručna katalogizacija kratera, a ujedno se i poboljšavaju sveukupna svojstva detekcije.



Slika 19. Dijagram toka temeljnog algoritma za detekciju kratera ovoga rada. © 2010 IEEE (Salamunićcar i Lončarić, 2010b).

4.3. Modul 1: Detekcija ruba i analiza gradijenta

U ovom radu, implementirano je više različitih detektora ruba, kako bi se ispitala njihova svojstva i odabrao najbolji. Bilo je izgledno da će Cannyjev (1986) detektor ruba dati bolje rezultate nego detektori ruba koji su mu prethodili, no hoće li bolje rezultate dati Cannyjev (1986) detektor ruba ili Shen-Castanov (1992) detektor ruba koji je napravljen nakon Cannyjevog (1986) detektora ruba i za koga se pokazalo da je po nekim kriterijima bolji, najjednostavnije je bilo provjeriti eksperimentalnim putem, koristeći pritom prethodno napravljenu okolinu za razvoj algoritama za detekciju kratera. Dok su svi prethodni detektori rubova bili napravljeni za optičke slike, naši koriste topografske slike, pa im je algoritme, odnosno njihove implementacije, trebalo prilagoditi. Stoga je bilo jednostavnije u prvom koraku implementirati neke osnovne detektore ruba, a u drugom Cannyjev i Shen-Castanov detektore ruba. Shen-Castanov detektor ruba bitno je različit od svih ostalih, pa je zato zasebno opisan. Detekcija ruba i analiza gradijenta opisani su u sljedećim potpoglavljima:

- 4.3.1. Iznos i smjer gradijenta;
- 4.3.2. Izračunavanje iznosa gradijenta;
- 4.3.3. Izračunavanje smjera gradijenta;
- 4.3.4. Razlika u odnosu na klasične detekcije ruba;
- 4.3.5. Zasebni pristup za Shen-Castanov detektor ruba;
- 4.3.6. Zapis prilagođen daljnjim koracima obrade i višeprocesorskim sustavima.

Prvo je implementirana radna verzija CDA-a (Salamunićcar i Lončarić, 2006b) koja je temeljena na Frei-Chenovom (1977) detektoru ruba. Taj CDA koristio se i prilikom izrade okruženja za razvoj i vrednovanje CDA-ova (Salamunićcar i Lončarić, 2008d). Sljedeća radna verzija CDA-a (Novosel et al., 2007) dodatno je podržavala i detektore ruba temeljene na razlici slikovnih elemenata (*Pixel-Difference*) (Pratt, 2001), odvojenoj razlici slikovnih elemenata (*Separated-Pixel-Difference*) (Pratt, 2001) te klasičnim Robertsovim (1965), Prewittovim (Pratt, 2001) i Sobelovim (1978) detektorima ruba s matricama 3x3. Nakon toga, radna verzija CDA-a (Knežević et al., 2008) dodatno je proširena s Prewittovim (Pratt, 2001) (s matricama od 3x3 do 9x9), Abdouovim (1978) (s matricama od 5x5 do 9x9), Argylejevim (1971), Macleodovim (1972), DoG-ovim (*Derivative-of-Gaussian*) (Pratt, 2001) i Cannyjevim (1986) detektorima ruba, a gdje su Argylejev, Macleodov, DoG-ov i Cannyjev detektor ruba implementirani matricama koje se dinamički računaju iz Gaussove funkcije na temelju zadanih parametara kako bi sama detekcija ruba bila što brža. Uz to implementirani su i kompas verzije klasičnih detektora rubova, Kirschov (1971) (matrice 3x3), Prewittov (Pratt, 2001) (matrice 3x3), Robinsonov s 3 nivoa (Pratt, 2001) (matrica od 3x3 do 9x9), Robinsonov s 5 nivoa (Pratt, 2001) (matrice 3x3) i Nevatia-Babuov (1980) (matrice 5x5) detektor ruba. Naposljetku je implementiran i Shen-Castanov (1992) detektor ruba. Svaki detektor implementiran je kao zasebna klasa u C++u, gdje je razlika između različitih klasa sam algoritam detektora ruba, dok je ostatak CDA-a isti i naslijeđen iz temeljnih klasa.

4.3.1. Iznos i smjer gradijenta

Neka su x i y dva okomita smjera. Ako se koriste gradijentni detektori ruba, njihov rezultat je iznos gradijenta G_x u smjeru x i iznos gradijenta G_y u smjeru y. Tada je iznos gradijenta G_i definiran formulom (2), a smjer gradijenta G_α formulom (3). Kada iznos gradijenta G_x postaje 0, iznos gradijenta G_i poprima vrijednost $\pi/2$ ako je G_y pozitivan, odnosno $3\cdot\pi/2$ ako je G_y negativan. Ako se koriste kompas detektori ruba, kao iznos gradijenta od izračunatih za sve matrice uzima se onaj koji je po apsolutnom iznosu najveći, dok je rednim brojem matrice definiran smjer gradijenta. U ovome radu koriste se i gradijentni i kompas detektori ruba, kako je opisano u poglavlju 4.3.2.

$$G_i = \sqrt{{G_x}^2 + {G_y}^2} \tag{2}$$

$$G_\alpha = arctg\left(\frac{G_y}{G_x}\right) + \beta \begin{vmatrix} G_x \geq 0, \beta = 0 \\ G_x < 0, \beta = \pi \end{vmatrix} \tag{3}$$

4.3.2. Izračunavanje iznosa gradijenta

Kada se koriste gradijentni detektori ruba, iznosi gradijenta G_x i G_y, računaju se tako da se vrijednosti slikovnih elemenata pomnože s vrijednostima iz matrica G_X i G_Y, te se tako dobivena vrijednost pomnoži s korekcijskim faktorom f_K i s rezolucijskim faktorom f_R, koji su opisani u sljedeća dva paragrafa. Tablica 2 prikazuje navedene matrice i pripadne korekcijske faktore za jednostavnije korištene gradijentne detektore rubova.

Množenje korekcijskim faktorom f_K rezultira otprilike uvijek istim iznosom gradijenta, bez obzira koji detektor ruba se koristi. Time su optimalne vrijednosti praga, koje definiraju minimalni potrebni iznos da bi slikovni element bio rub, otprilike iste za sve detektore rubova.

Prilikom računanja iznosa gradijenta, dodatno se treba uzeti u obzir i horizontalna rezolucija. U protivnom bi vrijednost praga ovisila o korištenoj horizontalnoj rezoluciji. Ako je horizontalna rezolucija topografske slike *A* dva puta veća od horizontalne rezolucije topografske slike *B*, tada razlika vrijednosti dva slikovna elementa slike *A* mora biti dva puta manja od razlike vrijednosti dva slikovna elementa slike *B*, kako bi izmjereni kut u odnosu na horizontalu bio isti. Kako bi se osiguralo da se iste vrijednosti praga mogu koristiti za slike različite horizontalne rezolucije, vrši se množenje rezolucijskim faktorom f_R, koji je obrnuto proporcionalan korištenoj horizontalnoj rezoluciji.

Tablica 2. Korekcijski faktor te matrice u *x* i *y* smjeru jednostavnijih korištenih gradijentnih detektora ruba (Novosel et al., 2007): (1) razlika slikovnih elemenata; (2) odvojena razlika slikovnih elemenata; (3) Robertsov; (4) Prewittov; (5) Sobelov; i (6) Frei-Chenov.

detektor ruba	**1)**			**2)**			**3)**			**4)**			**5)**			**6)**		
f_K	1			1/2			$1/\sqrt{2}$			1/6			1/8			$1/(4+2\sqrt{2})$		
G_X	0	0	0	0	0	0	0	0	+1	–1	0	+1	–1	0	+1	–1	0	+1
	0	–1	+1	–1	0	+1	0	–1	0	–1	0	+1	–2	0	+2	$-\sqrt{2}$	0	$+\sqrt{2}$
	0	0	0	0	0	0	0	0	0	–1	0	+1	–1	0	+1	–1	0	+1
G_Y	0	+1	0	0	+1	0	0	+1	0	+1	+1	+1	+1	+2	+1	+1	$+\sqrt{2}$	+1
	0	–1	0	0	0	0	0	0	–1	0	0	0	0	0	0	0	0	0
	0	0	0	0	–1	0	0	0	0	–1	–1	–1	–1	–2	–1	–1	$-\sqrt{2}$	–1

Vrijednosti slikovnih elemenata topografske slike su cijeli brojevi, kao i vrijednosti matrica svih gradijentnih detektora ruba iz prethodne tablice, osim za Frei-Chenov detektor ruba. No ako kod Frei-Chenovog detektora ruba u matricama 1 zamijenimo s 5741, a $\sqrt{2}$ zamijenimo s 8119, dobiva se skoro identičan rezultat (naravno uz dodatnu korekciju f_K). Time je prije svega pojednostavljeno pisanje ostalog koda, s obzirom na to da ne ovisi o tome koji detektor ruba se

koristi. Također, samo računanje je brže s obzirom na to da računalu uobičajeno treba manje vremena za množenje cjelobrojnih vrijednosti od množenja brojeva s pomičnim zarezom, iako kod novijih računala ova razlika u brzini ne mora biti značajna s obzirom na to da ona i brojeve s pomičnim zarezom množe gotovo jednako učinkovito kao i cjelobrojne. Dodatna motivacija da se za elemente matrica koriste samo brojevi u području od -9999 do 9999 je i: (1) nema potrebe za većom preciznosti jer ista, kako je provjereno, ne utječe na konačne rezultate; i (2) elemente velikih matrica je relativno lakše prikazati korisniku koji primjerice eksperimentira s različitim detektorima ruba i parametrima. I na kraju, ako matrica koja se dinamički računa korištenjem primjerice Gaussove funkcije ima u prvom i zadnjem retku te prvom i zadnjem stupcu sve nule (isto nikada nije nula kod korištenja brojeva pomičnog zareza), ovom jednostavnom provjerom, bez definiranja nekog zasebnog praga, ista se može reducirati na manji broj elemenata. To u konačnici vodi do znatnog ubrzanja rada samog detektora ruba.

Složeniji gradijentni detektori ruba koriste i veće matrice od 3x3. Neki od detektora koriste i Gaussovu funkciju, prikazanu formulom (4), kako bi se dinamički definirala matrica korištenjem parametra σ. Formulama (5), (6) i (7) definirani su i Argylejev, Macleodov i DoG-ov detektor ruba. Cannyjev detektor ruba, uz potiskivanje ne-maksimuma i filtriranje pragom histereze, također koristi DoG-ovu matricu. Tablica 3 prikazuje pripadne matrice.

$$Gauss(x,\sigma) = \frac{1}{\sigma \cdot \sqrt{2 \cdot \pi}} \cdot e^{-\frac{x^2}{2 \cdot \sigma^2}} \tag{4}$$

$$\text{Argyle}(x,y,\sigma) = s \cdot Gauss(x,\sigma) \cdot Gauss(y,\sigma) \begin{cases} x<0, s=-1 \\ x=0, s=0 \\ x>0, s=1 \end{cases} \tag{5}$$

$$\text{Macleod}(x,y,\sigma) = \left(Gauss(x-\sigma,\sigma) - Gauss(x+\sigma,\sigma)\right) \cdot Gauss(y,\sigma) \tag{6}$$

$$\text{DoG}(x,y,\sigma) = x \cdot Gauss(x,\sigma) \cdot Gauss(y,\sigma) \tag{7}$$

Tablica 3. Matrice u *x* smjeru složenijih korištenih gradijentnih detektora ruba (Knežević et al., 2008): (1) Prewittov (matrice od 3x3 do 9x9); (2) Abdouov (matrice od 5x5 do 9x9); (3) Argylejev (za σ = 0.5); (4) Macleodov (za σ = 0.5, prva i zadnja tri retka sadrže samo nule); (5) DoG-ov (za σ = 0.5); i (6) Cannyjev (za σ = 0.5).

1)

-1 0 1	… 0 1 1	… 0 1 1 1	… 0 1 1 1 1
-1 0 1	… 0 1 1	… 0 1 1 1	… 0 1 1 1 1
-1 0 1	… 0 1 1	… 0 1 1 1	… 0 1 1 1 1
	… 0 1 1	… 0 1 1 1	… 0 1 1 1 1
	… 0 1 1	… 0 1 1 1	… 0 1 1 1 1
		… 0 1 1 1	… 0 1 1 1 1
		… 0 1 1 1	… 0 1 1 1 1
			… 0 1 1 1 1
			… 0 1 1 1 1

2)

-1 -1 0 1 1	… 0 1 1 1	… 0 1 1 1 1
-1 -2 0 2 1	… 0 2 2 1	… 0 2 2 2 1
-1 -2 0 2 1	… 0 3 2 1	… 0 3 3 2 1
-1 -2 0 2 1	… 0 3 2 1	… 0 4 3 2 1
-1 -1 0 1 1	… 0 3 2 1	… 0 4 3 2 1
	… 0 2 2 1	… 0 4 3 2 1
	… 0 1 1 1	… 0 3 3 2 1
		… 0 2 2 2 1
		… 0 1 1 1 1

3)

…	0000 0003 0000	
…	0000 1353 0003	
…	0000 9999 0025	
…	0000 1353 0003	
…	0000 0003 0000	

4)

…	0000 0003 0002 0001 0000 0000	
…	0000 1353 0932 0211 0017 0001	
…	0000 9999 6885 1561 0128 0004	
…	0000 1353 0932 0211 0017 0001	
…	0000 0003 0002 0001 0000 0000	

5)

…	0000 0003 0000	
…	0000 1353 0007	
…	0000 9999 0050	
…	0000 1353 0007	
…	0000 0003 0000	

6)

Kompas detektori ruba imaju više od dvije matrice. Osnovna ideja je da za svaki od *n* smjerova postoji već unaprijed pripremljena matrica, pa se prema onoj koja po apsolutnoj

vrijednosti daje najveći rezultat definira i iznos i smjer gradijenta. Tablica 4 prikazuje korištene kompasne detektore ruba. Iako se Cannyjev detektor ruba uobičajeno implementira kako je prikazano prethodnom tablicom za gradijentne detektore ruba, koristeći princip kompasnih detektora ruba, uz gradijentnu verziju implementirana je i kompas verzija Cannyjevog detektora ruba. S obzirom na to da se u kasnijim koracima obrade smjer gradijenta digitalizira u jednu od 16 vrijednosti (kako je opisano u potpoglavlju 4.3.4), ovdje se koristilo upravo 16 kompasnih maski, kako bi se osiguralo optimalno izračunavanje kao kompromis između preciznosti i brzine. Kasnije je pokazano da kompas verzija Cannyjevog detektora ruba daje gotovo identične rezultate gradijentnoj verziji Cannyjevog detektora ruba, pa se dalje koristila gradijentna koja je uobičajenija, a uz to se i brže izračunava.

Tablica 4. Matrice korištenih kompasnih detektora ruba: (1) Kirschov; (2) Prewittov; (3) Robinsonov s 3 nivoa (matrica od 5x5, 7x7 i 9x9 nisu prikazane); (4) Robinsonov s 5 nivoa; (5) Nevatia-Babuov (prva matrica 1/10 sadrži {-100, -100, 0, +100, +100} u svim recima, prikazane su matrice 2/10 i 3/10, a ostale nisu prikazane); i (6) Cannyjev (za $\sigma = 0.5$, prikazane su matrice od 1/16 do 4/16).

1)

-3	-3	5	-3	5	5	5	5	-3	5	-3	-3	-3	-3	-3	-3	-3	-3	-3	-3	-3	-3	-3	-3	-3	-3
-3	0	5	-3	0	5	-3	0	-3	5	0	-3	5	0	-3	5	0	-3	-3	0	-3	-3	0	5	-3	0	5
-3	-3	5	-3	-3	-3	-3	-3	-3	-3	-3	-3	5	-3	-3	5	5	-3	5	5	5	-3	5	5	-3	5	5

2)

-1	1	1	1	1	1	1	1	1	1	1	1	1	1	-1	1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	1
-1	-2	1	-1	-2	1	1	-2	1	1	-2	-1	1	-2	-1	1	-2	-1	1	-2	1	-1	-2	1	-1	-2	1
-1	1	1	-1	-1	1	-1	-1	-1	1	-1	-1	1	1	-1	1	1	1	1	1	1	1	1	1	1	1	1

3)

-1	0	1	0	1	1	1	1	1	1	1	0	1	0	-1	0	-1	-1	-1	-1	-1	-1	-1	0	-1	-1	0
-1	0	1	-1	0	1	0	0	0	1	0	-1	1	0	-1	1	0	-1	1	0	-1	0	0	0	-1	0	1
-1	0	1	-1	-1	0	-1	-1	-1	0	-1	-1	1	0	-1	1	1	0	1	1	1	1	1	1	0	1	1

4)

-1	0	1	0	1	2	1	2	1	2	1	0	1	0	-1	0	-1	-2	-1	-2	-1	-2	-1	0	-2	-1	0
-2	0	2	-1	0	1	0	0	0	1	0	-1	2	0	-2	1	0	-1	0	0	0	-1	0	1	-1	0	1
-1	0	1	-2	-1	0	-1	-2	-1	0	-1	-2	1	0	-1	2	1	0	1	2	1	0	1	2	0	1	2

5)

-100	+32	+100	+100	+100	-100	-78	+92	+100	+100	-100	-100	0	+100	+100	-100	-100	-92	+78	+100	-100	-100	-100	-32	+100	
+100	+100	+100	+100	+100	-32	+78	+100	+100	+100	-100	-92	0	+92	+100	-100	-100	-100	-78	+32	-100	-100	-100	-100	-100	

6)

+0000	-0003	+0000	+0003	+0000	-0007	-1353	+0000	+1353	+0007	-0050	-9999	+0000	+9999	+0050	-0007	-1353	+0000	+1353	+0007	+0000	-0003	+0000	+0003	+0000	
+0000	-0001	+0019	+0006	+0000	-0005	-0732	+3826	+1768	+0007	-0046	-9238	+0000	+9238	+0046	-0007	-1768	-3826	+0732	+0005	+0000	-0006	-0019	+0001	+0000	
+0000	+0002	+0035	+0007	+0000	-0002	+0000	+7070	+1914	+0007	-0035	-7070	+0000	+7070	+0035	-0019	-3826	+0000	+3826	+0019	+0000	-0007	-0035	-0002	+0000	
+0000	+0005	+0046	+0007	+0000	+0001	+0732	+9238	+1768	+0006	-0019	-3826	+0000	+3826	+0019	-0006	-1768	-9238	-0732	-0001	+0000	-0007	-0046	-0005	+0000	

U svim slučajevima, radi što učinkovitijeg izračunavanja rubova na globalnim topografskim slikama, sve matrice se računaju samo jednom, kod inicijalizacije odabranog detektora ruba, i nakon toga samo se koriste. Također, G_i se ne računa u skladu s formulom (2), nego se koristi prethodno izračunat G_i^2. Time se kod svakog slikovnog elementa izbjegava izračunavanje drugog korijena, što je računalno značajno zahtjevnija operacija od množenja. Umjesto toga izračuna se kvadrat praga, i to također samo jednom, kod inicijalizacije.

4.3.3. Izračunavanje smjera gradijenta

Smjer gradijenta može se izračunati formulom (3). No to bi značilo da za svaki slikovni element treba izračunavati inverznu funkciju od tangensa, što je također (kao i izračunavanje drugog korijena) računalno daleko zahtjevnije od primjerice samo jednog množenja. No kako bi se to

izbjeglo, činjenica da se u kasnijim koracima obrade smjer gradijenta digitalizira u jednu od 16 vrijednosti (kako je opisano u potpoglavlju 4.3.4) koristi se kao apriori znanje. Primjerice ako je smjer gradijenta između -11.25° i 11.25°, svrstavamo ga u prvi razred, ako je između 11.25° i 33.75°, u drugi, itd. To znači da nas ne zanima koji je stvarni kut gradijenta izračunat na određeni broj decimala, nego samo je li on veći ili manji od nekih rubnih, kako bi ga svrstali u jedan od 16 razreda. Kako bi se to napravilo računalno što učinkovitije, koriste se predefinirane konstante tangensa od 11.25° i 33.75°. Pomnožiti te vrijednosti s G_x i usporediti je li dobiveno veće ili manje od G_y, odnosno pomnožiti s G_y i usporediti je li dobiveno veće ili manje od G_x, uz provjeru jesu li G_x i G_y pozitivni ili negativni, može se pokazati dovoljnim za klasifikaciju u jedan od 16 razreda. Sama implementacija algoritma u C++ jeziku nalazi se u prilogu, kao i sve ostalo vezano za detektore ruba.

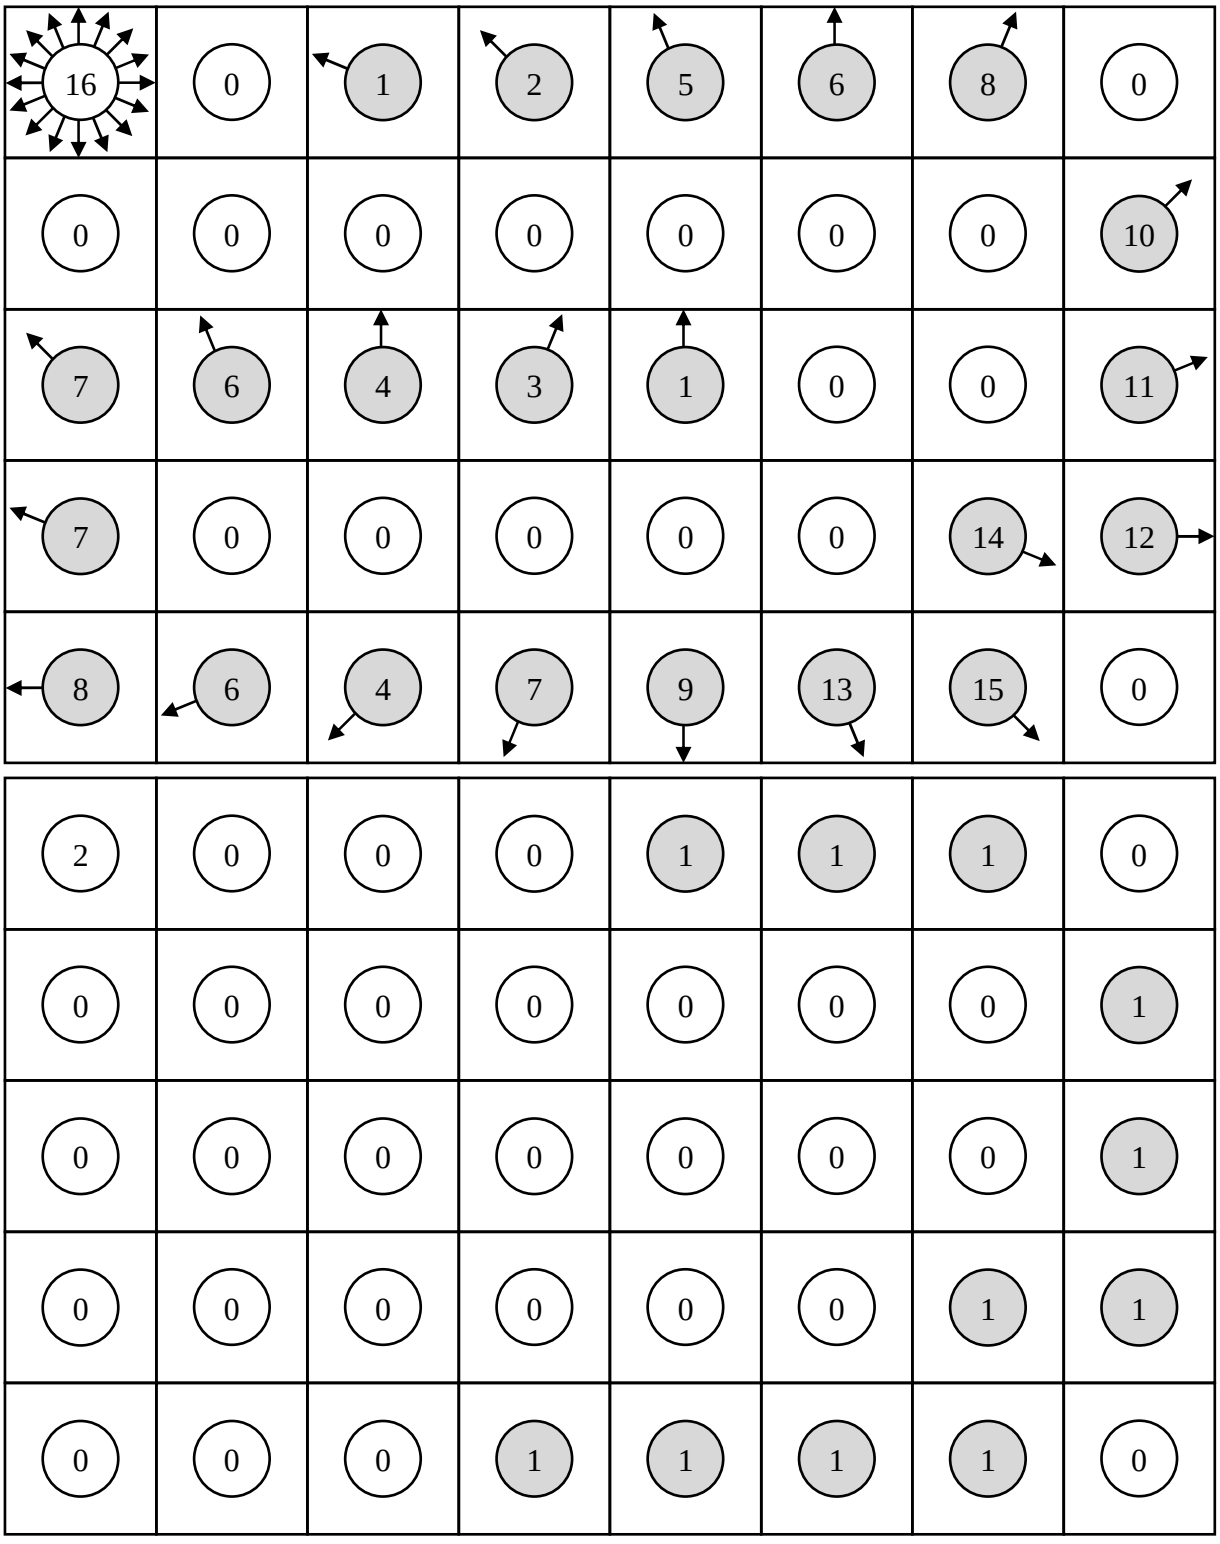
Kod Cannyjevog detektora ruba, za potiskivanje ne-maksimuma potrebno je izračunati i iznose gradijenta za dva susjedna slikovna elementa. Svaki slikovni element ima osam susjednih slikovnih elemenata, što znači da je potrebna diskretizacija smjera u jedan od 8 razreda. Za to se koristi algoritam iz prethodnog paragrafa. Nakon toga, za svaki slikovni element, iznos gradijenta dodatno se računa za samo još ta dva susjedna slikovna elementa. Na taj način se dodatno ubrzava izračunavanje. Alternativni pristup izračunavanja gradijenata svih slikovnih elemenata u prvom koraku, kako bi se u drugom koristili za potiskivanje ne-maksimuma, nije zadovoljavajući. Razlog je mogućnost postojanja vrlo sličnog iznosa i smjera gradijenta dva susjedna slikovna elementa, pa zapis gdje se za pohranu i iznosa i smjera gradijenta koristi samo 1 bajt po slikovnom elementu (kako je obrazloženo u potpoglavlju 4.3.4), iznimno za ovaj korak ne bi bilo dostatno.

Vezano za Cannyjev detektor ruba, zanimljivo je i da filtriranje pragom histereze, gdje se koriste dva praga, u ovom okruženju ne daje primjetno bolje rezultate nego kada se koristi samo jedan, iako je sveukupno izračunavanje zbog potrebe za iterativnom implementacijom primjetno duže. Vjerojatan razlog je što korištenje i iznosa i smjera gradijenta daljnjim koracima obrade prenosi više korisnih informacija o samom rubu nego sama informacija ima li ruba ili ga nema, bez obzira je li posljednje dobiveno korištenjem samo jednog praga ili filtriranjem pragom histereze.

4.3.4. Razlika u odnosu na klasične detekcije ruba

Kod klasične detekcije ruba izlazna slika je binarna, gdje vrijednost slikovnog elementa 0 znači da nema ruba, a 1 da postoji rub. U detektoru ovoga rada svaki izlazni slikovni element sadrži dvije vrijednosti, gdje prva sadrži iznos, a druga smjer gradijenta za određeni slikovni element. Za pohranu ovih podataka se koristi samo 1 bajt po slikovnom elementu, kako bi CDA trebao što manje radne memorije, od toga 4 bita za iznos i 4 bita za smjer gradijenta. Ako je vrijednost bajta 0, to znači da je iznos gradijenta također jednak nuli, odnosno da u tom slikovnom elementu nema ruba. Slika 20 prikazuje primjer detekcije ruba.

Za detektore ovoga rada, korištenjem okoline za razvoj CDA-ova, utvrđeno je da je optimalna vrijednost praga između 20‰ i 40‰. Jedan 1‰ je definiran kao 1 m promjene u vertikalnom smjeru (visini) kroz 1 km promjene u horizontalnoj udaljenost. Također je utvrđeno da gradijenti koji su za više od 10‰ veći nego što su iznosi gradijenata korišteni za pragove, obično ne pripadaju kraterima nego drugim geološkim oblicima (primjerice izrazito strm rub kanjona). Stoga se maksimalna vrijednost gradijenta koja se pohranjuje za svaki slikovni element limitira na vrijednost koja je za 1% veća od optimalnog gradijenta korištenog kao prag. Kako bi se vrijednost iz tog područja pohranila koristeći samo 4 bita, područje se dijeli na 16 jednakih potpodručja, kako bi se bilo koja vrijednost mogla preslikati u odgovarajuće potpodručje. Po sličnom principu smjer gradijenta se pohranjuje koristeći samo 4 bita tako da se ukupno područje od 360° podijeli na 16 jednakih kutova, kako bi se bilo koja vrijednost mogla preslikati u odgovarajuće potpodručje.



Slika 20. Cannyjeva detekcija ruba s analizom gradijenta (gore) i klasična Cannyjeva detekcija istog ruba gdje su pragovi histereze 5 i 10 (dolje).

Praksa je pokazala da viša preciznost od 1 bajta po slikovnom elementu značajno ne doprinosi poboljšanju rezultata. S druge strane, kodiranje koje bi koristilo samo jedan bit, odnosno 0 kada nema ruba, također nije računalno učinkovito. Tada bi dohvat pojedinog slikovnog elementa bio sporiji, s obzirom na to da ne bismo imali istu dužinu zapisa u bitovima po svakom slikovnom elementu, pa bi se za dohvat određenog trebalo računati njegova adresa u memoriji. Ni ušteda memorije ne bi bila znatna, s obzirom na to da na slici rubova ima znatno više kada se umjesto

samo 2 koristi 16 vrijednosti iznosa gradijenta, pa se bolji rezultati postižu kada se kao rub detektiraju i one promjene gradijenta koje su znatno manje od uobičajenih.

4.3.5. Zasebni pristup za Shen-Castanov detektor ruba

Shen i Castan (1992) su u svom radu došli do sličnog detektora ruba kao što je i Canny (1986), no drugom funkcijom koju su optimizirali došli su do zaključka da je optimalni niskopropusni filtar upravo beskonačni simetrijski eksponencijalni filtar (*infinite symmetric exponential filter*), te da je derivacija Gaussove funkcije koju je koristio Canny (1986) samo aproksimacija njihove funkcije. Pokazali su da njihov detektor ima bolja svojstva kod prisutnosti šuma, te da daje bolju lokalizaciju ruba.

Osnovna razlika prilikom implementacije Shen-Castanovog (1992) detektora ruba u odnosu na prethodne su dva koraka u odvijanju same detekcije, gdje se u prvom računaju određene značajke, a u drugom iste te značajke koriste kako bi se u određenoj mjeri pojedine vrijednosti parametara prilagodile slici i osigurale što bolju detekciju ruba. U odzivu ta razlika vidljiva je ako se neki neizražen dio ruba u jednom dijelu slike nalazi daleko od izraženih rubova, a u drugom dijelu slike blizu nekih drugih izraženih rubova. U prvom slučaju neizražen dio ruba bit će detektiran kao rub, s obzirom na to da je dominantan u svojoj okolini na slici, dok u drugom neće jer će biti potisnut dominantnijim rubom.

Sam algoritam Shen-Castanovog (1992) detektora ruba znatno je različit i složeniji od ostalih, pa je zasebno implementiran na različit način od prethodnih detektora rubova (ne koriste se matrice za izračun iznosa gradijenta, različit pristup koristi se i za izračun smjera gradijenta, itd.).

S obzirom da je Shen-Castanov (1992) detektor ruba u konačnici dao lošije rezultate od Cannyjevog detektora ruba, a uz to je i puno složeniji, ovdje nije detaljno opisan. No kao i za sve ostale detektore ruba, njegova implementacija u C++ jeziku nalazi se u prilogu rada.

4.3.6. Zapis prilagođen daljnjim koracima obrade i višeprocesorskim sustavima

Svi detektori ruba, kao i svi ostali dijelovi CDA-a kojima je potrebno duže izračunavanje, napisani su da se mogu paralelno izvoditi na računalima s višejezgrenim procesorima, više procesora, ili oboje. To je od dodatne važnosti, uz samu učinkovitost algoritma i potrošnju memorije, kako bi se osiguralo što brže ukupno izvođenje algoritma.

U ovome radu koristi se zapis slikovnog elementa topografske slike koji sadrži cjelobrojne vrijednosti u iznosu od -32768 do 32767, za što se koriste dva bajta memorije po slikovnom elementu. Za gradijent koristi se dodatni bajt memorije, što je ukupno tri bajta po slikovnom elementu. Za rezultate izmijenjene Houghove transformacije pokazalo se da je također dovoljan jedan bajt po slikovnom elementu, što predstavlja diskretizaciju mogućih vrijednosti u jedan od 256 razreda. Sveukupno, to je svega 4 bajta po slikovnom elementu potrebnih tijekom rada CDA-a.

Dodatno, sva četiri bajta pridružena slikovnom elementu nalaze se u memoriji jedan do drugog. Time pristup samoj vrijednosti ili gradijentu odmah dohvaća i lokaciju za pohranu rezultata izmijenjene Houghove transformacije, odnosno osigurava vrlo visoku učinkovitost i kod računala s više višejezgrenih procesora.

Na taj način, na računalu s dva procesora od kojih svaki ima četiri centralne procesorske jedinice (*central processing units*), postignuto je gotovo osam puta kraće vrijeme potrebno za izvođenje cjelokupnog CDA-a.

S ovim završnim korakom, detekcija ruba korištenjem gradijenta završava i podaci se prosljeđuju izmijenjenoj Houghovoj transformaciji na daljnju obradu.

4.4. Modul 2: Izmijenjena Houghova transformacija

U prvom dijelu ovog potpoglavlja opisani su osnovni principi Houghove transformacije, odnosno njena modifikacija kojom umjesto pravaca detektira kružnice, dok su u drugom dijelu opisana poboljšanja temeljena na detekciji ruba s analizom gradijenta:

- 4.4.1. Osnovni principi Houghove transformacije;
- 4.4.2. Poboljšanja korištenjem detekcije ruba s analizom gradijenta.

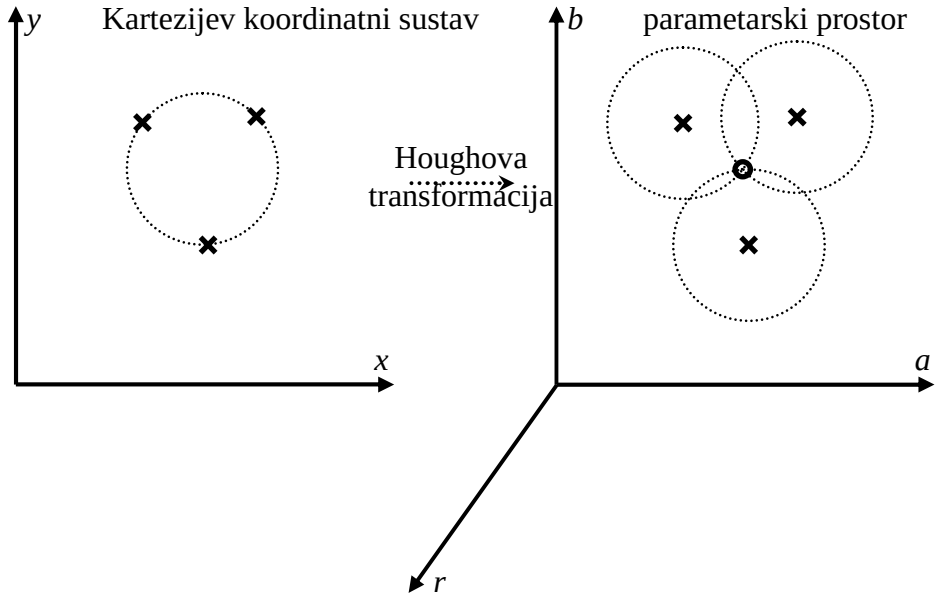
4.4.1. Osnovni principi Houghove transformacije

Houghovu transformaciju patentirao je Hough (1962), a kasnije je pokazano da se ista može izvesti i iz Radonove transformacije (Deans, 1981). Houghova transformacija u najjednostavnijem slučaju služi za detekcije pravaca definiranih formulom (8). Za svaki slikovni element iz Kartezijevog koordinatnog sustava (x, y) imamo pramen pravaca koji prolazi kroz njega i preslikava se u sinusoidu u parametarskom prostoru (ρ, φ). Time pravcu iz Kartezijevog koordinatnog sustava odgovara slikovni element u parametarskom prostoru gdje se sinusoide sijeku. Traženjem lokalnih maksimuma u parametarskom prostoru detektiraju se pravci iz Kartezijevog koordinatnog sustava.

$$x \cdot \cos(\varphi) + y \cdot \sin(\varphi) = \rho \tag{8}$$

Prethodni princip Houghove transformacije može se generalizirati, kako bi se mogli detektirati razni oblici. Slika 21 prikazuje primjer detekcije kružnice definirane formulom (9). Za svaki slikovni element iz Kartezijevog koordinatnog sustava (x, y) imamo pramen kružnica koje prolaze kroz njega. Centri kružnica svakog pramena preslikavaju se u kružnicu u parametarskom prostoru (a, b, r). Time kružnici iz Kartezijevog koordinatnog sustava odgovara slikovni element u parametarskom prostoru gdje se kružnice iz parametarskog prostora najviše puta sijeku. Kružnice iz Kartezijevog koordinatnog sustava detektiraju se traženjem maksimuma u parametarskom prostoru.

$$(x-a)^2 + (y-b)^2 = r^2 \tag{9}$$

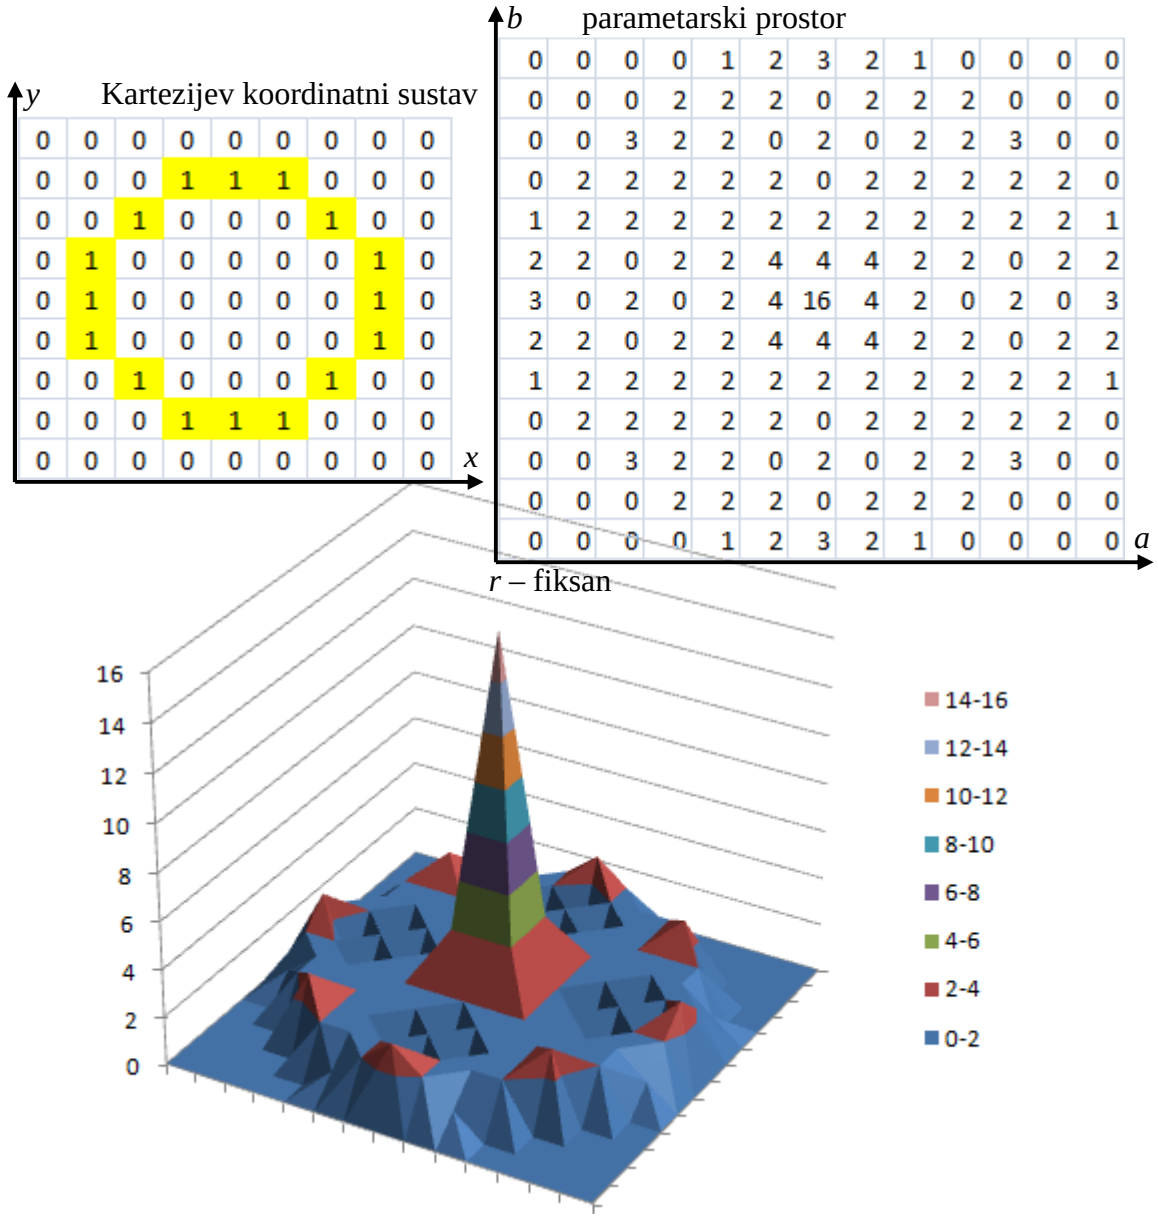


Slika 21. Princip detektiranja kružnice Houghovom transformacijom preslikavanjem iz Kartezijevog koordinatnog sustava u parametarski prostor.

Duda i Hart (1972) prilagodili su Houghovu transformaciju za pronalaženje pravaca i krivulja u digitalnim slikama. U tu svrhu, u sljedećem koraku diskretizira se Kartezijev koordinatni sustav kao i parametarski prostor. Time kontinuirane varijable, x, y, a, b i r, prelaze u diskretne varijable koje mogu poprimati samo diskretne vrijednosti izražene u broju slikovnih elemenata, u intervalima od x_1 do x_2, od y_1 do y_2, od a_1 do a_2, od b_1 do b_2 i od r_1 do r_2. Premala rezolucija diskretizacije vodi do kružnica koje su detektirane s nedovoljno precizno određenim radijusom ili koordinatama središta. Prevelika rezolucija diskretizacije rezultira prevelikim zahtjevima za računalne resurse (memorija, potrebno vrijeme za računanje). Rezolucija diskretizacije varijabli Kartezijevog koordinatnog sustava određena je digitalnom ulaznom topografskom (ili optičkom) slikom, pa vrijednosti $x_2 - x_1$ i $y_2 - y_1$ odgovaraju upravo broju slikovnih elemenata u dva ortogonalna smjera. Prilikom ručnog označavanja kružnica u Kartezijevom koordinatnom sustavu, preciznost određivanja radijusa i centra je ±1 slikovni element. Time nema potrebe za višom preciznosti u parametarskom prostoru, dok niža ne bi mogla davati jednako precizne rezultate kao što se postižu prilikom ručne detekcije (crtanja) kružnica u Kartezijevom koordinatnom sustavu.

Višestruko rezolucijska piramidalna obrada slika s prve slike detektira sve kratere kojima je radijus između r_1 i r_2 slikovnih elementa, a u sljedećim slikama manjih horizontalnih rezolucija između $r_2/2$ i r_2 slikovnih elementa. Razlog je što krater koji na prethodnoj slici ima radijus velik r_2 slikovnih elementa na sljedećoj slici (dvostruko manje horizontalne rezolucije) ima radijus velik $r_2/2$. Ovime za fiksni r_n svakom slikovnom elementu iz Kartezijevog koordinatnog sustava odgovara jedan i samo jedan slikovni element u parametarskom prostoru. Prethodnim pristupom smanjuje se broj dimenzija parametarskog prostora Houghove transformacije s 3 na 2. Time se osigurava jednak broj slikovnih elemenata parametarskog prostora i Kartezijevog koordinatnog sustava. Ovo je posebno važno prilikom detekcije kratera iz globalnih topografskih slika u visokim horizontalnim rezolucijama, s obzirom na to da značajno smanjuje količinu memorije koja je potrebna za izračunavanje Houghove transformacije.

Prethodnim koracima osiguralo se obuhvaćanje kratera svih veličina, koji se s dane slike mogu detektirati, a ujedno da u pojedinom koraku Houghovom transformacijom detektiramo samo one kratere koju su u radijusu veliki točno r slikovnih elemenata. Time smo algoritamski smanjili broj dimenzija parametarskog prostora s 3 na 2, te osigurali da se prethodno opisan postupak detekcije kružnica Houghovom transformacijom može implementirati na dva načina. Prvi način je: (1) algoritam prolazi kroz sve slikovne elemente u ulaznoj slici (x, y); (2) ako je vrijednost slikovnog elementa u ulaznoj slici 0, ignorira se; (3) ako je vrijednost slikovnog elementa u ulaznoj slici 1, za 1 se povećava vrijednost svih slikovnih elemenata u parametarskom prostoru koji se nalaze na kružnici radijusa r i centra $a = x$ i $b = y$. Drugi način je: (1) algoritam prolazi kroz sve slikovne elemente u parametarskom prostoru (a, b); (2) vrijednosti slikovnog elementa u parametarskom prostoru pridjeljuje se broj slikovnih elemenata u ulaznoj slici koji imaju vrijednost 1 i nalaze se na kružnici radijusa r i centra $x = a$ i $y = b$. Primjećujemo da u svim slučajevima oba načina daju isti rezultat. Slika 22 prikazuje rezultat za ulaznu sliku kada umjesto samo tri slikovna elementa sadrži potpunu kružnicu. Ono što na kraju dobijemo vrijednosti su u parametarskom prostoru, gdje maksimum odgovara centru detektirane kružnice. Pritom je važno ne uzeti u obzir eho-maksimume (na sljedećoj slici prikazani su kao lokalni maksimumi koji su kružno raspoređeni oko glavnog maksimuma), što se može osigurati odgovarajućim pragom.

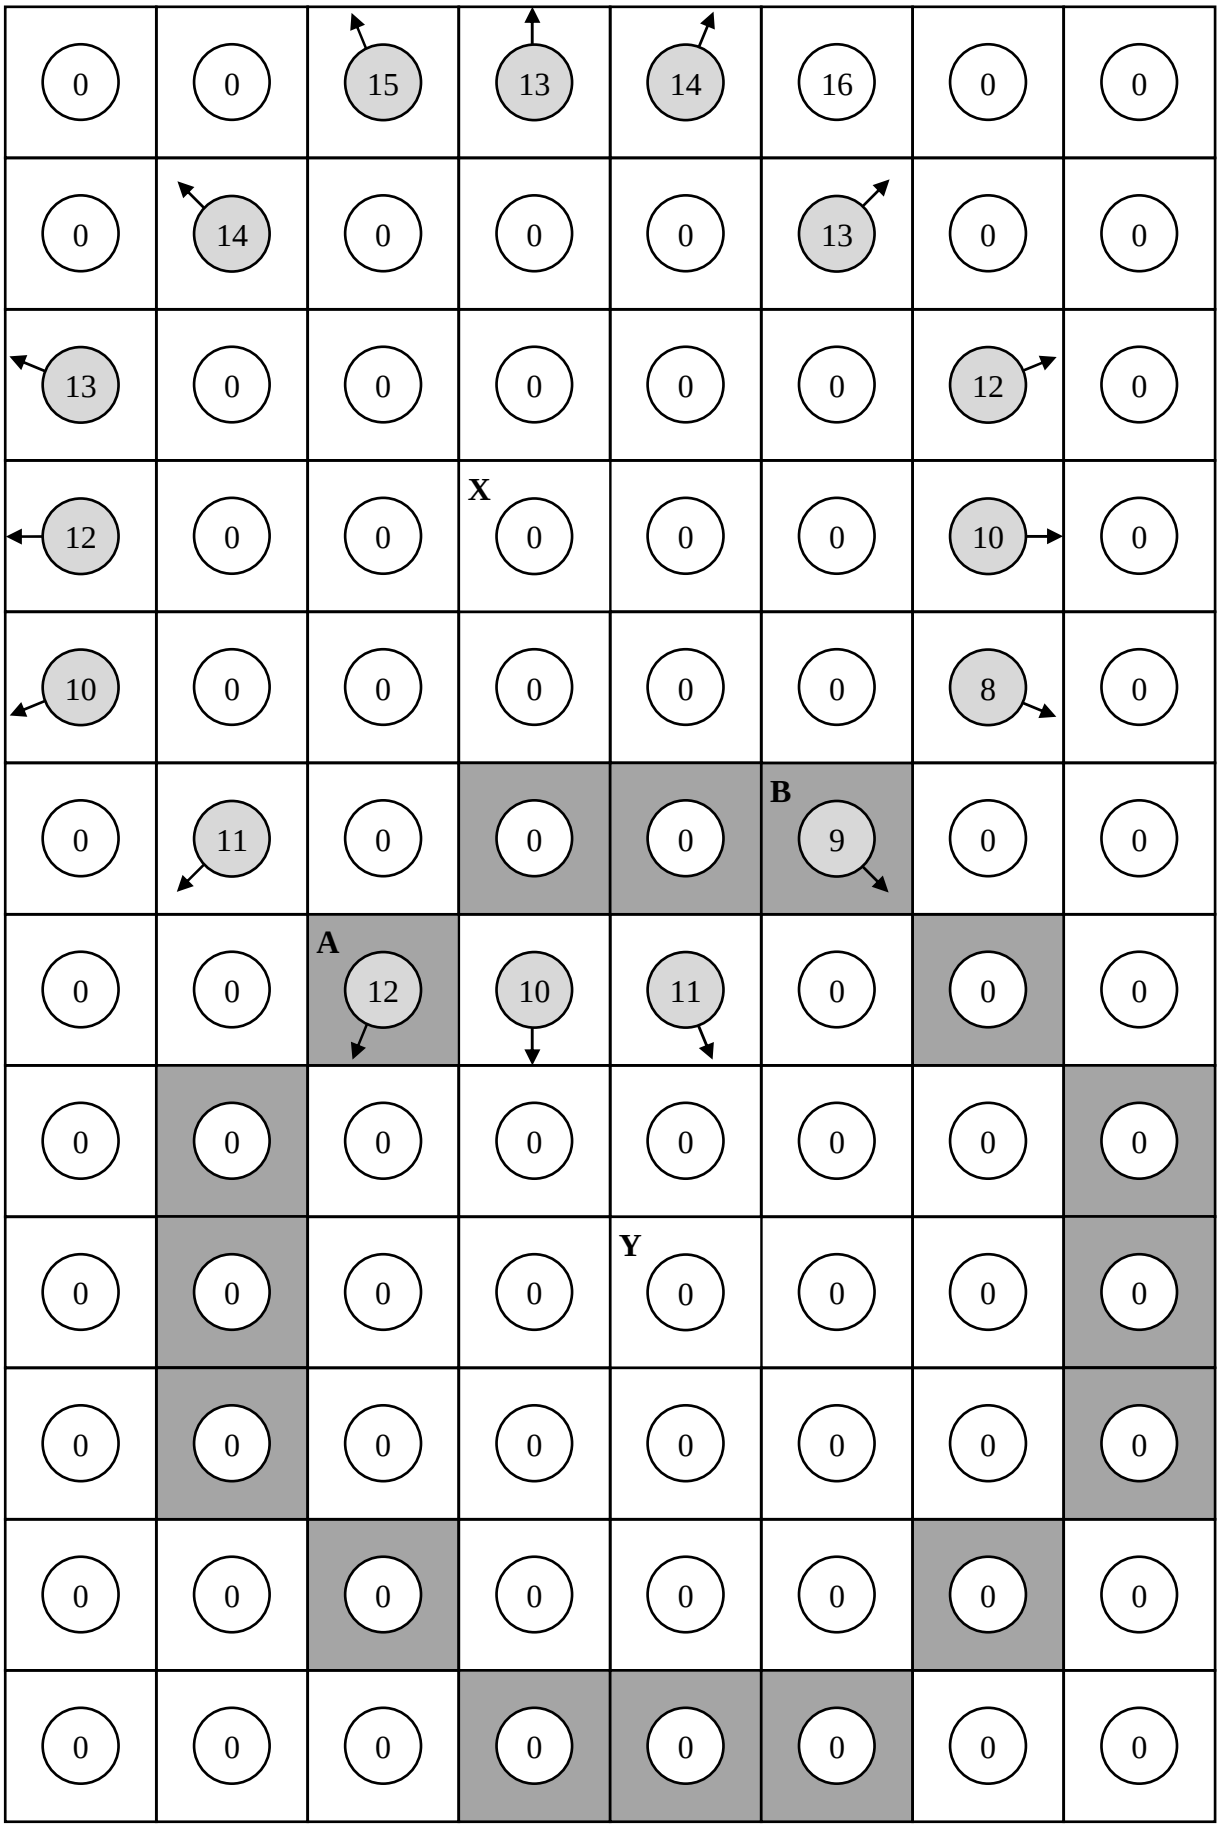


Slika 22. Jedna moguća implementacija Houghove transformacije za detekciju kružnica.

4.4.2. Poboljšanja korištenjem detekcije ruba s analizom gradijenta

Osnovna razlika između izmijenjene Houghove transformacije ovoga rada i klasične implementacije je ulaz koji je kod klasične implementacije 0 ili 1 ovisno o tome ima li ili nema ruba, dok je u ovome radu ulaz iznos gradijenta (Michael, 2003a) i smjer gradijenta (Cooper, 2003).

Radijus *r* je fiksan, što znači da je broj dimenzija parametarskog prostora (*a*, *b*) jednak 2, odnosno jednak broju dimenzija Kartezijevog koordinatnog sustava (*x*, *y*). Uz to je jednak i broj slikovnih elemenata, kako u smjeru dužine slike, tako i u smjeru visine slike. Time se parametarski prostor u potpunosti preklapa s Kartezijevim koordinatnim sustavom, a time i s izvornom topografskom slikom. Maksimumi u parametarskom prostoru detektiranih kružnica tako se nalaze upravo na poziciji slikovnog elementa koji se u Kartezijevom koordinatnom sustavu nalazi u centru kružnice detektiranog ruba, a u izvornoj topografskoj slici u centru detektiranog kratera. To znači da imamo koordinatni sustav gdje horizontalnu os možemo označiti i sa *a* i sa *x*, a vertikalnu i sa *b* i sa *y*. Slika 23 prikazuje primjere izračuna izmijenjene Houghove transformacije.



Slika 23. Izračun izmijenjene Houghove transformacije za dva različita slikovna elementa *X* i *Y*.

Prilikom računanja vrijednosti u parametarskom prostoru, za slikovni element s prethodne slike označen s *X*, gradijenti svih slikovnih elemenata koji se nalaze na detektiranom rubu u očekivanom su smjeru od centra kratera. S obzirom na to da se ovdje radi o topografskim, a ne optičkim slikama, rub se nalazi upravo na poziciji gdje se nadmorska visina povećava kako se udaljujemo od centra kratera. Prilikom računanja vrijednosti u parametarskom prostoru, za slikovni element s prethodne slike označen s *Y*, smjerovi gradijenta slikovnih elemenata ruba označenih s *A* i *B* ne odgovaraju očekivanima za tu lokaciju kratera. Stoga je osnovna ideja izmijenjene Houghove transformacije da se prilikom računanja vrijednosti u parametarskom prostoru stvarni smjer gradijenta usporedi s očekivanim, i na temelju toga odredi hoće li se dotični slikovni element detektiranog ruba uzeti u obzir ili ne, u cijelosti ili s određenim težinskim faktorom. Također, u obzir se uzima i iznos gradijenta, jer što je veći, to je i vjerojatnije da se radi o rubu. U kombinaciji, ove dvije metode daju puno bolje rezultate nego kada se koristi klasična izvedba detektora ruba i Houghove transformacije (Salamunićcar i Lončarić, 2008b).

Formula (10) definira Houghovu, a formula (11) izmijenjenu Houghovu transformaciju, gdje je p_h, odnosno p_{ih}, vrijednost izračunata za lokalni maksimum u parametarskom prostoru. U oba slučaja računa se suma samo za one slikovne elemente koji se nalaze na kružnici širokoj jedan slikovni element i udaljenosti r od centra kratera na lokaciji (a, b). Izmijenjena Houghova transformacija mogla bi uzeti u obzir iznos i smjer gradijenta i na neki drugi način. Eksperimentalnim putem, korištenjem okoline za razvoj CDA-ova, pokazano je kako upravo ovaj način kod detekcije kratera daje najbolje rezultate.

$$p_h = Hough(a,b) = \sum_{\{x,y\} \in kružnice} f_i \quad | f_i \in \{0,1\} \tag{10}$$

$$p_{ih} = Izmijenjen\,Hough(a,b) = \sum_{\{x,y\} \in kružnice} (f_i \cdot f_\alpha) \left| \begin{array}{c} f_i \in \{0,15\} \\ \alpha \in \{-8,7\} \\ |\alpha| = 0 \rightarrow f_\alpha = 3 \\ |\alpha| = 1 \rightarrow f_\alpha = 2 \\ |\alpha| = 2 \rightarrow f_\alpha = 1 \\ |\alpha| \geq 3 \rightarrow f_\alpha = 0 \end{array} \right. \tag{11}$$

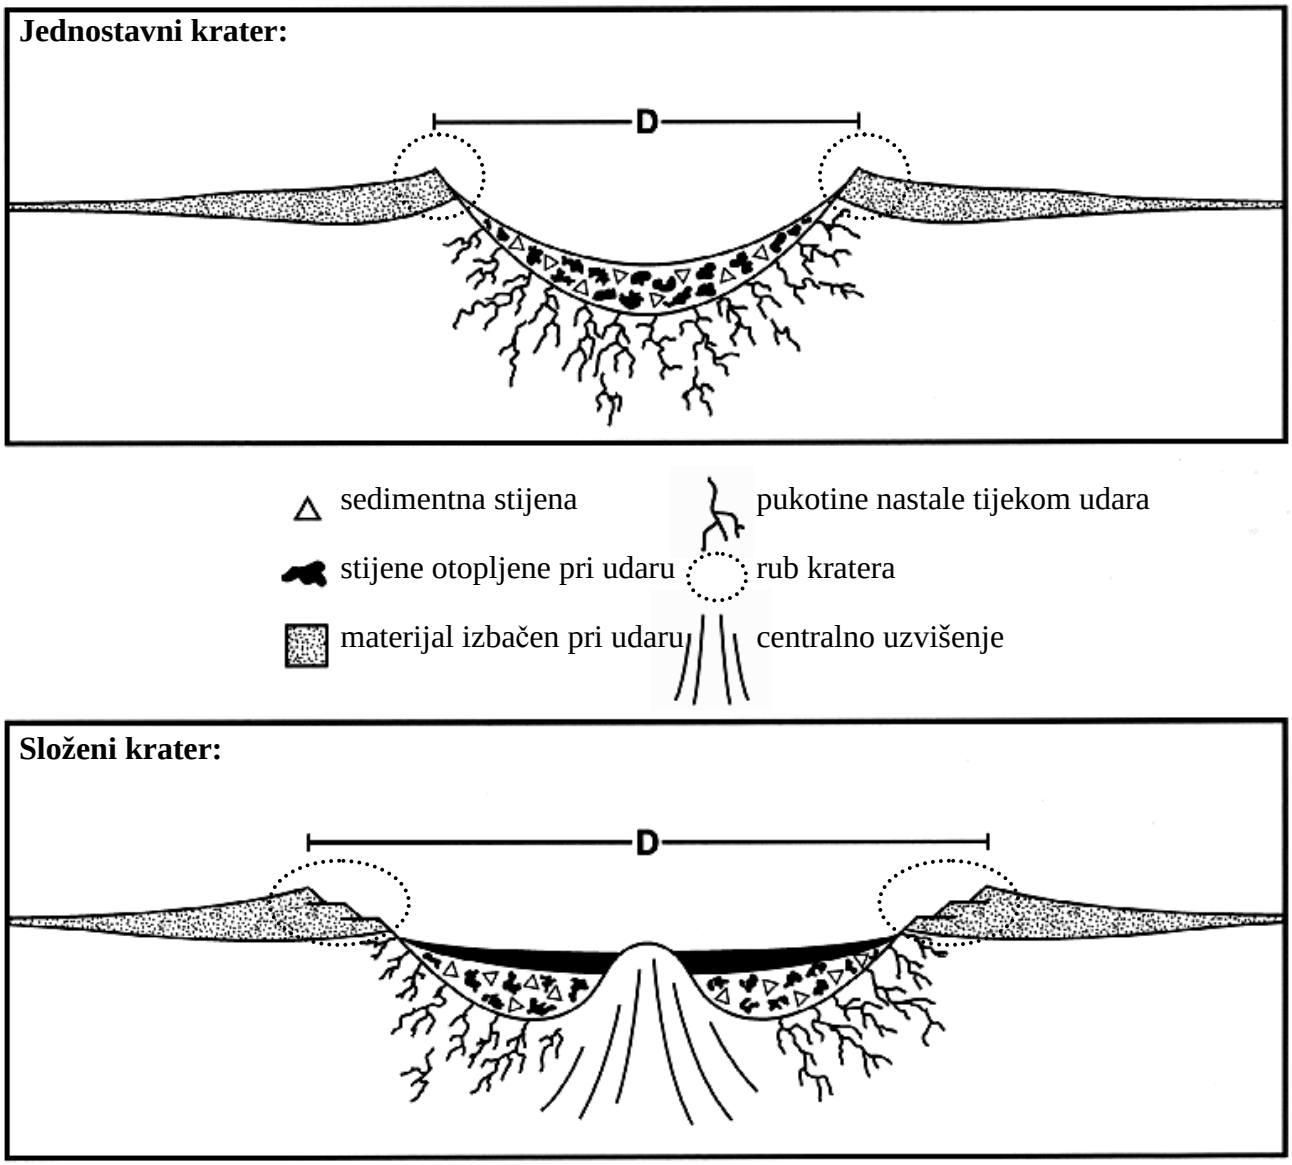
Kod klasične Houghove transformacije, ako se na lokaciji (x, y) nalazi rub, f_i je 1, u protivnom f_i je 0. Kod izmijenjene Houghove transformacije, f_i može poprimiti vrijednosti od 0 do 15, a što je upravo izlaz detektora ruba koji analizira i iznos gradijenta. Na taj način, ako je gradijent veći, segment ruba uzima se s većim težinskim faktorom, a ako je manji, s manjim.

Klasična Houghova transformacija ne uzima u obzir smjer gradijenta. Kod izmijenjene Houghove transformacije, detektor ruba analizira i smjer gradijenta, koji može poprimiti vrijednosti od 0 do 15. S obzirom na to da smjer gradijenta kao izlaz detektora ruba može poprimiti upravo 16 diskretnih vrijednosti, razlika između smjera gradijenta i očekivanog smjera od centra kratera α također se diskretizira u jednu od 16 kategorija vrijednosti od -8 do 7. Važna je apsolutna vrijednost razlike stvarnog i očekivanog smjera gradijenta $|\alpha|$, pošto je svejedno je li ona pozitivna ili negativna. Ako nema razlike stvarnog i očekivanog smjera gradijenta (ista je manja od ±11.25°), odnosno ako je $|\alpha|=0$, najvjerojatnije se radi o rubu kratera, pa se koristi najveći težinski faktor $f_\alpha=3$. Ako je razlika $|\alpha|=1$ (ista je veća od ±11.25° a manja od ±33.75), nešto je manje vjerojatno da se radi o rubu kratera, pa se koristi nešto manji težinski faktor $f_\alpha=2$. Ako je razlika $|\alpha|=2$ (ista je veća od ±33.75° a manja od ±56.25°), još je manje vjerojatno da se radi o rubu kratera, pa se koristi još manji težinski faktor $f_\alpha=1$. Ako je razlika još veća $|\alpha|\geq 3$ (ista je veća i od ±56.25°), vjerojatnost da se radi o rubu kratera je zanemariva, pa se koristi najmanji težinski faktor $f_\alpha=0$.

4.5. Modul 3: Analiza morfometrije i parametarskog prostora

Analizom oblika kratera, korištenjem topografske slike i parametarskog prostora koji je rezultat izmijenjene Houghove transformacije, mogu se dodatno poboljšati svojstva detekcije. Slika 24 prikazuje od ranije poznate oblike malih i velikih kratera. Analiza se sastoji od sljedećih segmenata, odnosno opisana je sljedećim potpoglavljima:

- 4.5.1. Mjerenje topografskog profila kratera;
- 4.5.2. Određivanje odnosa dubine i dijametra;
- 4.5.3. Mjerenje cirkularnosti u topografskoj slici;
- 4.5.4. Mjerenje cirkularnosti u parametarskom prostoru;
- 4.5.5. Detekcija i mjerenje ruba kratera;
- 4.5.6. Detekcija i mjerenje centralnog uzvišenja kratera;
- 4.5.7. Određivanja područja gdje je krater očuvan.



Slika 24. Osnovni dijelovi jednostavnog malog kratera (gore) i kompleksnog velikog kratera (dolje) (Kiefer, 2011).

Traženjem maksimuma u parametarskom prostoru dolazi se do početnih kandidata za kratere, gdje je vrijednost maksimuma u parametarskom prostoru p_{ih} definirana formulom (11). U prvoj aproksimaciji, p_{ih} se može koristiti kao početna vjerojatnost da je detektiran objekt krater. Cilj analize morfometrije i parametarskog područja je korigiranje vrijednosti p_{ih} kako bi se dobila točnija procjena vjerojatnosti p_m da je detektiran objekt krater. Faktor p_m definiran je formulom (12), p_c je mjera cirkularnosti u topografskoj slici (definirana u potpoglavlju 4.5.3.), p_{vc} je mjera cirkularnosti u parametarskom području (definirana u potpoglavlju 4.5.4.), p_{cr} je mjera ruba kratera (definirana u potpoglavlju 4.5.5.), i p_{cp} je mjera centralnog uzvišenja kratera (definirana u potpoglavlju 4.5.6.). Na temelju predznanja o oblicima kratera, vrše se mjerenja ovih faktora, i koristeći njih računa p_m definiran formulom (12).

$$p_m = p_{ih} \cdot p_c \cdot p_{vc} \cdot p_{cr} \cdot p_{cp} \tag{12}$$

4.5.1. Mjerenje topografskog profila kratera

Konstrukcija topografskog poprečnog profila definirana je formulama (13) do (20). Odnos između kraja ruba kratera (*crater rim*) i radijusa *r* je definiran u području od 100% do 200% radijusa kao parametar *por*. Za svaki različit radijalni kut kratera uzima se do *s* uzoraka, gdje su odnosi između *r*, *por*, *s* i uzorka radijusa *sor* (pozicija) definirani formulama (13), (14), (15) i (16). Uzorak radijusa *sor* najmanje može biti 9, čime se definira da je na topografskom profilu udaljenost radijusa kratera od njegovog centra barem deset slikovnih elemenata topografskog profila (kojima su indeksi od 0 do 9). Time se za sve kratere koji su u radijusu manji od 10 slikovnih elemenata koristi ista rezolucija topografskog profila, kao i za kratere koji su u radijusu veliki 10 slikovnih elemenata. Vrijednosti visine uzoraka oko centra kratera na lokaciji (*x*, *y*) definirane su formulama (17), (18) i (19), gdje je *h* broj slikovnih elemenata od Sjevernog do Južnog pola globalne topografske slike *dtd* (*digital topography data*), a *rr* je radijalna rezolucija (broj pravaca iz centra kratera po kojim se uzimaju uzorci visine). U skladu s (20), topografski poprečni profil *tcp* (*topographic-cross-profile*) je definiran kao prosječna (prosjek *rr* topografskih profila) razlika visine na udaljenosti *j* slikovnih elemenata od centra kratera i visine na lokaciji centra kratera. Moguće je da će neki slikovni elementi biti uzorkovani više puta kod malih kratera, i neki drugi preskočeni kod velikih kratera, ali to nije problem, zahvaljujući visokoj rezoluciji uzorkovanja. Rezultat ove metode je 2-D reprezentacija 3-D oblika kratera.

$$s = \min\left(r \cdot por\ /100\ ,128\right) \tag{13}$$

$$sor = \max(9, r-1) \tag{14}$$

$$s = \left(sor\ +1\right) \cdot por\ /100 \tag{15}$$

$$sor\ = s \cdot 100\ /\ por\ - 1 \tag{16}$$

$$\lambda\ = 1/\cos\left(latitude\ \right) = 1/\sin\left(\pi \cdot y/\left(h-1\right)\right) \tag{17}$$

$$\alpha_i\ = 2\pi \cdot i/rr \tag{18}$$

$$el\left(\alpha_i, j\right) = dtd\left(x + \frac{r \cdot j}{sor} \cdot \cos\left(\alpha_i\right) \cdot \lambda, y + \frac{r \cdot j}{sor} \cdot \sin\left(\alpha_i\right)\right) \tag{19}$$

$$tcp\left(j\right) = \frac{1}{rr} \cdot \sum_{i=0}^{rr-1} el\left(\alpha_i, j\right) \tag{20}$$

4.5.2. Određivanje odnosa dubine i dijametra

Odnos dubine i dijametra određen je formulom (21). Nakon što se pronađe minimum razlika visina unutar udaljenosti od centra kratera do njegovog radijusa, njegova dubina mjeri se kao razlika između visine kod tog minimuma i visine na poziciji ruba kratera, kako definira formula (21). Dobivanjem te vrijednosti, možemo izračunati i omjer *d*/*D* (Stepinski i Urbach 2009).

$$d = \max_{j=0}^{sor-1} \left(tcp\left(sor\right) - tcp\left(j\right) \right) \tag{21}$$

4.5.3. Mjerenje cirkularnosti u topografskoj slici

Cirkularnost u topografskoj slici važna je jer što je ista veća, to je i veća vjerojatnost da je detektiran objekt krater (Earl et al., 2005b; Salamunićcar i Lončarić, 2007c). Kako bi se izmjerila cirkularnost kratera, računa se standardna devijacija razlika između visine *el* i topografskog poprečnog profila *tcp*, kako definira formula (22). Jednom nakon što se suma ovih vrijednosti izračuna za sve udaljenosti od centra kratera, kako definira formula (23), izračunava se odnos između te površine a_1 i površine a_2 definirane formulom (24). Koristeći parametar kružne vjerojatnosti cpp_1 (*circularity-probability-parameter*) i formulu (25), može se izračunati vjerojatnost p_c pridružena cirkularnosti.

$$delta\left(j\right) = \sqrt{\frac{1}{rr} \cdot \sum_{i=0}^{rr-1} \left(el\left(\alpha_i, j\right) - tcp\left(j\right) \right)^2} \tag{22}$$

$$a_1 = \sum_{j=0}^{sor} delta\ (j) \tag{23}$$

$$a_2 = \sum_{j=0}^{sor} \left(tcp\left(sor\right) - tcp\left(j\right) \right) \tag{24}$$

$$p_C = 10^{-\frac{cpp_1 \cdot a_1}{a_2}} \tag{25}$$

4.5.4. Mjerenje cirkularnosti u parametarskom prostoru

Cirkularnost u parametarskom prostoru također je važna jer što je veća, veća je i vjerojatnost da je detektiran objekt krater (Salamunićcar i Lončarić, 2009a). Kako su eksperimenti potvrdili, to je posljedica više cirkularnosti (oblika koji tvore vrijednosti u parametarskom prostoru) u centrima kratera nego u centrima pogrešnih detekcija. To svojstvo se koristi kako bi se poboljšala ukupna svojstva CDA-a. Ova metoda analizira parametarski prostor isto kako je mjerenje cirkularne konzistencije analiziralo 3-D oblik kratera, kako je pokazano formulom (26). Pritom se koristi parametar kružne vjerojatnosti u parametarskom prostoru $vcpp_1$ (*votes-circularity-probability-parameter*). Vrijednosti *b1* i *b2* računaju se na isti način kako su se izračunale a_1 i a_2 formulama (23) i (24), s tim da se kao ulaz, umjesto vrijednosti topografske slike, koriste vrijednosti parametarskog područja.

$$p_{vc} = 10^{-\frac{vcpp_1 \cdot b_1}{b_2}} \tag{26}$$

4.5.5. Detekcija i mjerenje ruba kratera

Detekcija i mjerenje ruba kratera važna je jer kada se rub može detektirati, što je veći, to je u principu i veća vjerojatnost da je detektiran objekt krater. Slično kao što su u prethodnom koraku izračunati a_1 i a_2, koji predstavljaju hrapavost i površinu u *tcp*-u u području od centra kratera do njegovog radijusa, odgovarajuće vrijednosti a_3 i a_4 se izračunavaju za rub kratera u području između radijusa i kraja ruba. Koristeći te dvije vrijednosti i parametre vjerojatnosti ruba (*rim-probability-parameters*), rpp_1, rpp_2, rpp_3 i rpp_4, vjerojatnost pridružena rubu kratera *pcr* može se izračunati formulom (27).

$$p_{cr} = \left(1 - rpp_1 \cdot 10^{-\frac{rpp_2 \cdot a_3}{a_2}}\right) \cdot \left(1 - rpp_3 \cdot 10^{-\frac{rpp_4 \cdot a_3}{a_4}}\right) \tag{27}$$

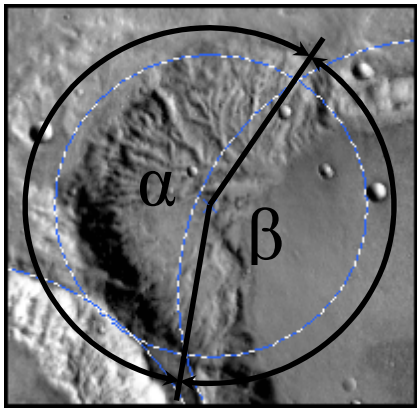
4.5.6. Detekcija i mjerenje centralnog uzvišenja kratera

Detekcija i mjerenje centralnog uzvišenja kratera važna je, kao i za rub, jer kada se može detektirati, povisuje se vjerojatnost da je detektiran objekt krater. Slično vrijednostima a_3 i a_4, odgovarajuće vrijednosti a_5 i a_6 se računaju za centralno uzvišenje kratera u području od centra kratera i minimuma definiranog formulom (21). Koristeći te dvije vrijednosti i parametre vjerojatnosti centralnog uzvišenja, $cppp_1$, $cppp_2$, $cppp_3$ i $cppp_4$, vjerojatnost pridružena centralnom uzvišenju kratera *pcp* može se izračunati formulom (28).

$$p_{cp} = \left(1 - cppp_1 \cdot 10^{-\frac{cppp_2 \cdot a_5}{a_2}}\right) \cdot \left(1 - cppp_3 \cdot 10^{-\frac{cppp_4 \cdot a_5}{a_6}}\right) \tag{28}$$

4.5.7. Određivanja područja gdje je krater očuvan

Metoda određivanja područja gdje je krater očuvan rekurzivno poziva izračunavanja cirkularnosti, kako bi pronašla dio gdje je krater očuvan. Slika 25 prikazuje krater koji je jednim dijelom očuvan (kut α), a drugim nije (kut β). Jednom nakon što se a_1 i a_2 izračunaju za dio gdje je krater očuvan, to se koristi samo za izračun formule (25). Ostale formule definirane u potpoglavlju 4.5 uzimaju u obzir cijelo područje (α+β) jer se eksperimentalnim putem utvrdilo da se tako dobivaju bolji rezultati. Metoda koristi kalibraciju u formi funkcije koja raste s porastom područja gdje je krater očuvan (*radial-calibration*). To je potrebno kako bi se izbjeglo izračunavanje za premalo područje.



Slika 25. Primjer određivanja područja gdje je krater očuvan (kut α) i područja gdje nije (kut β).

4.6. Modul 4: Adaptivna korekcija vjerojatnosti

Ova metoda koristi se za prilagođavanje CDA-a detekciji velikih, srednjih ili malih kratera (Salamunićcar i Lončarić, 2009a). Ovime se uzima u obzir i činjenica da se detekcije najmanjih kratera temelje na jako malom broju topografskih uzoraka. Stoga se takve detekcije uzimaju u obzir samo ako je pridijeljena vjerojatnost da je detektiran objekt krater viša od uobičajene.

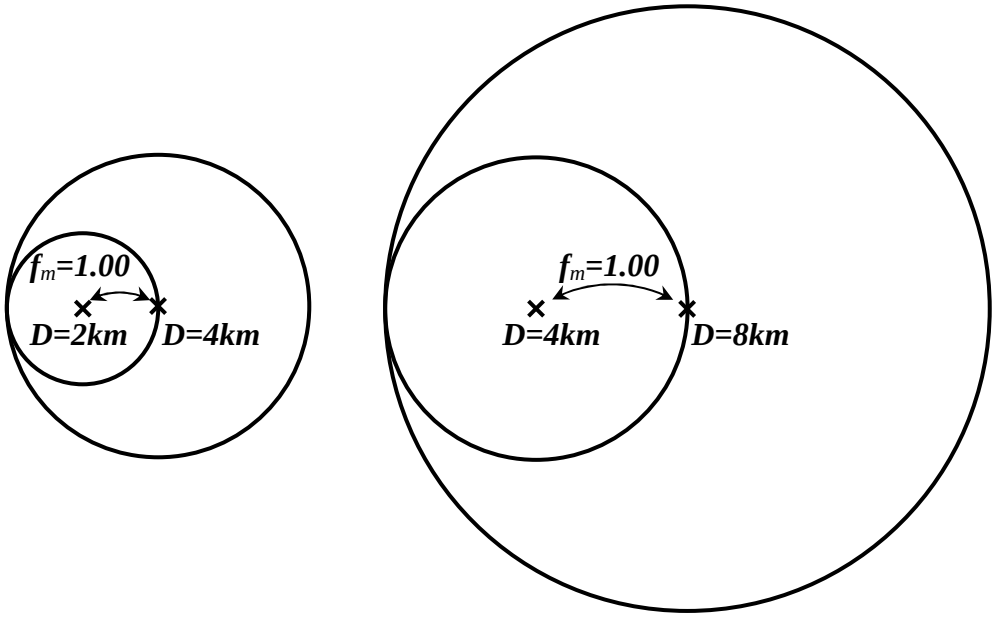
Ova metoda množi vjerojatnost p_m da je detektiran objekt krater, koja je definirana formulom (12), s kalibracijskim faktorom, kako je prikazano formulom (29).

$$p_{cf} = p_m \cdot cf \tag{29}$$

Kalibracijski faktor ovisi samo o detektiranom radijusu, i monotono je rastuća funkcija, odnosno povećava se s povećanjem detektiranog radijusa.

Svaki krater, ovisno o dijametru, razvrstava se u zasebni razred. Pritom se ne uzimaju u obzir područja dijametra ispod određenog iznosa, kao niti iznad određenog iznosa, nego je cilj pokriti veliku većinu kratera i pritom voditi računa da se pokrije područje tranzicije između velikih složenih i malih jednostavnih kratera (Melosh i Ivanov, 1999).

Slika 26 prikazuje osnovni princip klasifikacije kratera po razredima. Kako je na slici prikazano, po principu sličnosti bitan je omjer veličina između dva kratera, a ne sama veličina ili njihova razlika. Stoga se razredi određuju tako da je razlika logaritma dijametra najvećeg i najmanjeg kratera unutar razreda, ista za sve razrede, osim za prvi koji sadrži sve kratere manje od njegovog rubnog dijametra i za zadnji koji sadrži sve kratere veće od njegovog rubnog dijametra.



Slika 26. Slučajevi za f_m = 1.00 koja pokazuje da udaljenost definirana formulom (1) ne ovisi o veličini kratera, nego o omjeru veličina u usporedbi s nekim drugim kraterom.

Kalibracijski faktor vrijednost je kalibracijske funkcije za određeni dijametar. Kalibracijska funkcija, kako je opisano u potpoglavlju 9.1.1., definirana je s *n* vrijednosti kalibracije kataloga (*catalogue-calibration*), koje pripadaju prethodnim razredima, a između kojih se funkcija linearno interpolira. Tim vrijednostima inicijalizira se CDA kao i s ostalim parametrima.

Ovime se djelomično kompenzira različitost morfologije velikih i malih kratera te se također može osigurati da distribucija kratera bude slična očekivanoj za srednje i velike kratere.

4.7. Modul 5: Podešavanje kandidata za kratere pomicanjem

Ovom metodom (Salamunićcar i Lončarić, 2007c) završno se podešavaju značajke detektiranih kratera u svrhu što preciznijeg određivanja njihove lokacije na topografskoj slici (x i y koordinate središta) i radijusa (r). Algoritam metode je sljedeći:

(1) *delta* se postavlja na vrijednost 2 slikovna elementa;

(2) za svaki kandidat za krater, definiraju se novi kandidati za kratere, s $delta \cdot dr$ slikovnih elemenata manjim radijusom (dr = -1), $delta \cdot dr$ slikovnih elemenata većim radijusom (dr = 1), i koordinatama centra pomaknutim za $delta \cdot dx$ i $delta \cdot dy$ slikovnih elemenata istočno odnosno desno (dx = 1), zapadno odnosno lijevo (dx = -1), sjeverno odnosno gore (dy = 1) i južno odnosno dolje (dy = -1);

(3) za sve nove kandidate za kratere, vjerojatnost da su točne detekcije p_m definirana formulom (12) se ponovno procjenjuje koristeći sve prethodne metode, osim analize cirkularnosti oblika, koji tvore vrijednosti u parametarskom prostoru, koja više nije dostupna u ovom modulu, pa se za formulu (12) za p_{vc} koristi početno izračunata vrijednost;

(4) zasebnom metodom se detektira radi li se o manjem krateru unutar većeg (*insider*) i mjeri se odnos dubine i dijametra;

(5) ako je kandidat za krater označen kao *insider* i neki od novih kandidata za kratere ima veću izračunatu vjerojatnost da je krater, novi kandidat za krater je onaj s najvećom izračunatom vjerojatnosti da je točna detekcija; u protivnom, ako kandidat za krater nije označen kao *insider*, može se zamijeniti s novim kandidatom za krater ako je u tom slučaju omjer dubine/dijametra veći i koordinate su iste, ili, omjer dubine/dijametra nije manji i izračunata vjerojatnost je veća;

(6) koraci (2)-(5) se ponavljaju sve dok pomicanje ili povećavanje/smanjivanje kandidata za krater vodi prema boljem rješenju (ponovo izračunata vrijednost p_m je veća);

(7) *delta* se postavlja na 1 slikovni element i nakon toga se ponavljaju koraci (2)-(6).

Za *delta* se koristi 2 kao početna vrijednost, jer se korištenjem okruženja za razvoj i vrednovanje CDA-ova ustvrdilo da se time dobivaju bolji rezultati nego kada se koriste druge početne vrijednosti (1, 3, itd.).

Također se eksperimentiralo s različitim brojem novih kandidata za kratere u svakom koraku, a najbolji rezultati su postignuti sa sljedećih 18 kombinacija: $\{dr, dx, dy\} \in \{\{+1, 0, 0\}, \{-1, 0, 0\}, \{0, +1, 0\}, \{0, -1, 0\}, \{0, 0, +1\}, \{0, 0, -1\}, \{0, +1, +1\}, \{0, -1, -1\}, \{0, +1, -1\}, \{0, -1, +1\}, \{+1, +1, 0\}, \{+1, -1, 0\}, \{+1, 0, +1\}, \{+1, 0, -1\}, \{+1, +1, +1\}, \{+1, -1, -1\}, \{+1, +1, -1\}, \{+1, -1, +1\}\}$.

4.8. Klasifikacija parametara i njihova zavisnost

Parametri koje korisnik CDA-a može (ali uobičajeno ne mora) mijenjati su: (1) r_1; (2) r_2; (3) *vrijednosti-kalibracije-kataloga* (koje sve mogu biti jednake 1); (4) parametri specifični za detektore ruba (gdje se dani u priloženim datotekama mogu koristiti).

Ostale parametre korisnik ne mijenja, osim ako ne dodaje vlastiti modul za morfometrijska mjerenja ili ne napravi poboljšanja ovdje opisanih. Oni su robusni i ne utječu značajno jedni na druge.

Izračunavanje optimalnih vrijednosti ostalih parametara, *por*, cpp_1, $vcpp_1$, rpp_1, rpp_2, rpp_3, rpp_4, $cppp_1$, $cppp_2$, $cppp_3$, $cppp_4$, kalibracijske funkcije koja se koristi prilikom određivanja područja gdje je krater očuvan (*radial-calibration*) i kalibracijske funkcije koja se koristi za adaptivnu korekciju vjerojatnosti (*catalogue-calibration*), odvijalo se na sljedeći način: (1) tražio se lokalni optimum samo za odabrani parametar dok su se vrijednosti svih ostalih držale konstantnim, gdje se lokalnim optimum smatra najveća postignuta površina ispod F-ROC odnosno A-ROC krivulje; (2) isto se napravilo za sve ostale parametre; (3) cjelokupan proces se ponavljao dok god se nije došlo do optimuma gdje daljnja poboljšanja više nisu bila moguća.

Inicijalne vrijednosti optimalnih parametara su pronađene korištenjem CDA-a s gradijentnom verzijom Cannyjevog detektora ruba (vrlo slični rezultati su dobiveni za CDA koji koristi kompas verziju Cannyjevog detektora ruba), koristeći okruženje za razvoj i vrednovanje CDA-ova, uključivo i MA17582GT katalog te 1/64° MOLA podatke.

Sustav za traženje optimalnih parametara napravljen je tako da može funkcionirati u grupi umreženih računala, kako bi se što prije izračunali optimalni parametri, na sljedeći način:

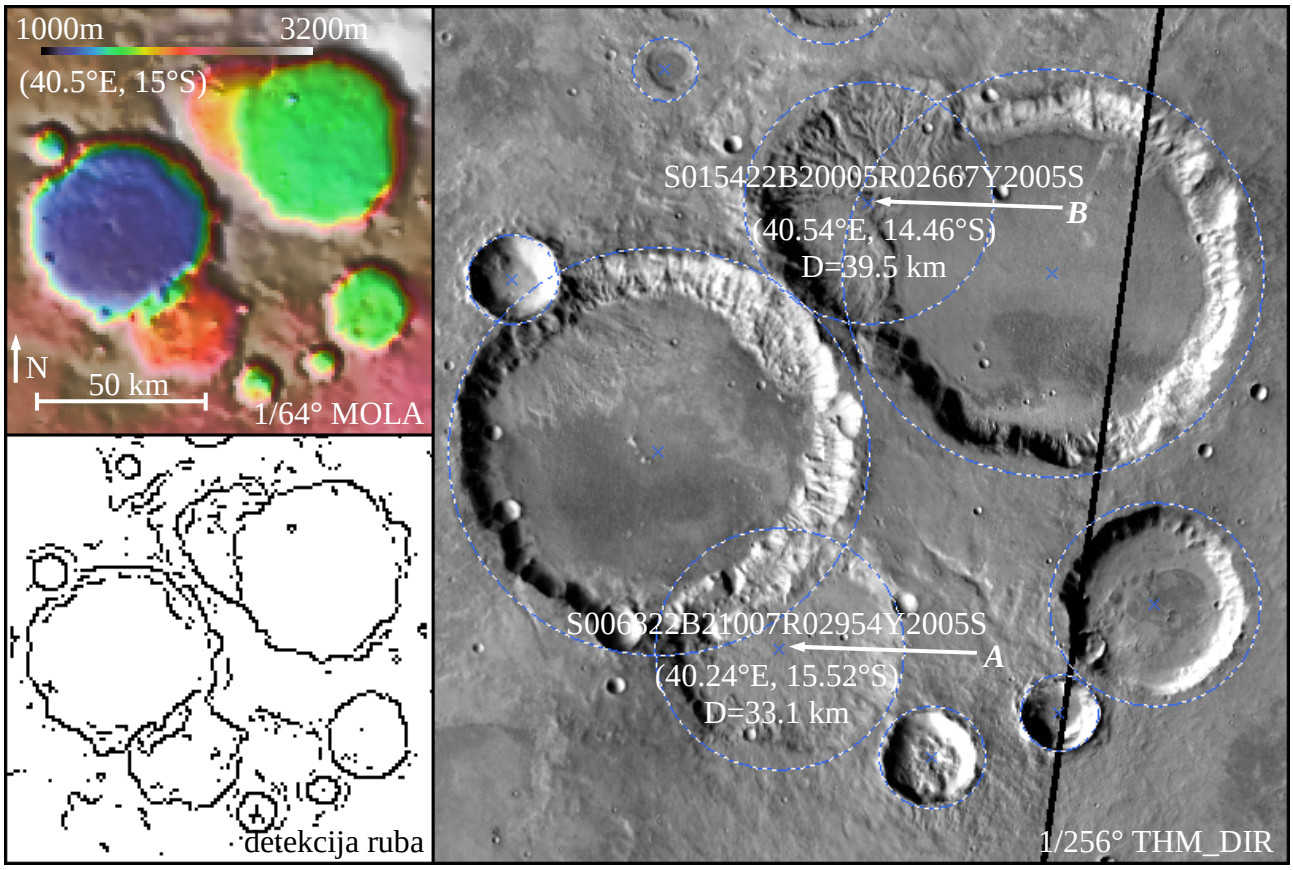
- korisnik priprema XML datoteke s odabranim vrijednostima parametara, sprema ih u arhivnu datoteku i učitava na stranicu na Internetu dostupnu bili kojem pretraživaču Interneta;
- CDA koji se pokrene u modu poslužitelja redovito provjerava je li korisnik stavio novu arhivnu datoteku (na primjer svakih 15 minuta), i ako je ista različita od prethodno skinute, skida je, raspakirava sadržaj, i pritom kopira XML datoteke u direktorij koji je u lokalnoj mreži dijeljen između računala koji se na njoj nalaze;
- CDA-ovi koji su na računalima lokalne mreže pokrenuti u modu klijenta redovito provjeravaju postoje li na dijeljenom direktoriju na lokalnoj mreži XML datoteke, a ako postoje, uzimaju svaki po jednu, izvršavaju detekciju kratera, i rezultat vraćaju u drugi dijeljeni direktorij;
- CDA koji se pokrenuo u modu poslužitelja korisniku može vratiti popis datoteka spremnih s rezultatima, gdje korisnik može birati hoće li mu CDA poslati neke od tih datoteke e-poštom (ako mu baš trebaju, jer mogu biti velike više MB-a i nakon kompresije) ili će napraviti F-ROC (ili neko drugo vrednovanje) rezultata i samo to mu poslati e-poštom.

Uz to što se ovako može koristiti mreža računala kako bi se što prije došlo do optimalnih rezultata, na svakom od tih računala gdje je CDA pokrenut u modu klijenta, isti provjerava koliko jezgri računalo ima, te sve računalno zahtjevne algoritme izvršava koristeći paralelizam, kako bi se što prije došlo do rezultata. Ubrzanje algoritma s porastom broja jezgri je gotovo linearno. Isto se provjerilo na računalu s 20 GB-a memorije i 8 jezgri (dva procesora, od toga svaki s 4 jezgre), dok računala s više memorije odnosno jezgri nisu bila dostupna za ovaj rad. Ako se koriste podaci u horizontalnoj rezoluciji do 1/64°, CDA-u je dovoljno i 2 GB-a memorije, i isti se može koristiti kao 32-bitna aplikacija. Za korištenje podataka u 1/128° ili višim horizontalnim rezolucijama, CDA je potrebno koristiti u 64-bitnoj verziji (isti izvorni kod, ali se koristi druga opcija kod prevođenja u izvršni kod) i potrebno mu je više memorije te 64-bitni operacijski sustav.

4.9. Primjer za topografsku sliku Marsa

Detaljno vrednovanje metode i usporedba s radom drugih dani su u poglavlju 9, dok je ovdje prikazan samo jedan primjer detekcije kratere za dio globalne topografske slike Marsa, koji je dobiven korištenjem okoline za razvoj CDA-ova te CDA-om opisanim u ovom poglavlju.

Slika 27 prikazuje: (1) dio topografske slike Marsa (lijevo gore); (2) rezultate Cannyjevog detektora ruba (lijevo dolje); (3) detektirane kratere (desno), gdje se optička slika u 4 puta većoj horizontalnoj rezoluciji koristila samo kako bi se bolje pokazala njihova morfologija. Kako je prikazano, za ovaj dio globalne topografije i ovu selekciju parametara, svi veći krateri su uspješno detektirani i ne postoji niti jedna pogrešna detekcija. To je teško postići za srednje erodiran krater *A* i jako erodiran krater *B*, posebno stoga što je manji dio prvog i veći dio drugog u potpunosti izbrisan kraterima koji su naknadno nastali. Da su krateri *A* i *B* zaista krateri, a ne neke druge geološke formacije, zaključuje se iz toga što se nalaze u MA17582GT katalogu, a samim time i u katalozima MA42279B i MA19308R, autora iz područja lunarnih i planetarnih znanosti.



Slika 27. Topografska slika (lijevo gore), rezultati Cannyjevog (maska=3x3, σ=0.25, r_1=5, r_2=28, $grad_1$=$grad_2$=30) detektora ruba (lijevo dolje), rezultati CDA-a za $p > 0.25$ (desno). Erodirani krater *A* i jako erodirani krater *B* su detektirani, bez pogrešnih detekcija na ovoj slici i za ove parametre. © 2010 IEEE (Salamunićcar i Lončarić, 2010b).

4.10. Zaključak

Rezultati postignuti temeljnom metodom za detekciju kratera, opisanom u ovom poglavlju (Salamunićcar i Lončarić, 2010b), su: (1) CDA je pokazao daleko bolje karakteristike detekcije od ostalih publiciranih metoda, kako će biti prikazano u potpoglavlju 9.3.1.; (2) razvijena metoda može se koristiti za automatska morfometrijska mjerenja (Robbins i Hynek, 2007; Salamunićcar i Lončarić, 2009b); (3) prethodni referentni katalog je značajno proširen s prethodno nekatalogiziranim kraterima, kako će više biti opisano u potpoglavljima 9.2.1. i 9.2.2.

Uspješnu detekciju kratera mlađeg postanka nije teško postići s obzirom na to da im je morfološka struktura dobro očuvana. No detekciju erodiranih kratera, kao i kratera koji su dijelom obrisani, teško je postići. Razlog je što s povećanjem osjetljivosti CDA-a broj pogrešnih detekcija također raste. Zahvaljujući performansama koje su postignute s CDA-om opisanim u ovom poglavlju, porast broja pogrešnih detekcija je značajno manji nego za inicijalnu verziju, čak i u modu gdje je CDA najosjetljiviji. Kao rezultat pronađen je značajan broj prethodno nekatalogiziranih kratera.

Ovime su se osigurali temelji za daljnji rad na CDA-u, i to kako bi mogao detektirati što manje kratere, što je postignuto interpolacijom koja je prilagođena obliku kratera, te kako bi se dodatno smanjio broj pogrešnih detekcije u odnosu na točne, što je postignuto strojnim učenjem korištenjem stroja s potpornim vektorima.

5. II. KORAK: POBOLJŠANJE DETEKCIJE KRATERA INTERPOLACIJOM PRILAGOĐENOM OBLIKU KRATERA

U ovom poglavlju opisuje se metoda za detekciju kratera koja koristi interpolaciju temeljenu na obliku kratera, kroz sljedeća potpoglavlja:

- 5.1. Uvod;
- 5.2. Metoda za detekciju kratera temeljena na interpolaciji;
- 5.3. Modul 6: Interpolacija prilagođena obliku kratera;
- 5.4. Modul 7: Adaptivne korekcije s obzirom na radijus planetarnog tijela;
- 5.5. Metoda za projekciju podataka i kratera;
- 5.6. Primjer za topografsku sliku Mjeseca;
- 5.7. Zaključak.

U potpoglavlju 5.1. daje se uvod u problematiku i opisuje motivacija za primjenu interpolacije te motivacija da se istim CDA-om mogu detektirati krateri i iz topografije Marsa i iz topografije Mjeseca. U potpoglavlju 5.2. opisuje se dijagram toka poboljšane metode za detekciju kratera te ukratko opisuju njezina nova dva modula koji se detaljnije opisuju u potpoglavljima 5.3. i 5.4. Potreba za metodom koja može projicirati podatke i kratere te opis implementacije iste dani su u poglavlju 5.5. Primjer detekcije iz topografske slike Mjeseca dan je u potpoglavlju 5.6. U potpoglavlju 5.7. naveden je zaključak o postignućima metode za detekciju kratera koja koristi interpolaciju.

Ovaj dio rada napravljen je u suradnji s Erwanom Mazaricom (Salamunićcar et al., 2011f), čiji doprinos je u pripremi podataka (globalnih topografskih i optičkih slika) i katalozima za Mjesec koji su se koristili (Head et al., 2010; Kadish et al., 2011).

5.1. Uvod

Svaki instrument može rezultirati slikama samo do neke određene horizontalne rezolucije, koja je određena kvalitetom instrumenta. Svaka slika sadrži konačan broj kratera. U pravilu uvijek ima puno više malih nego velikih kratera. Ovisnost broja kratera o dijametru uobičajeno se prikazuje dijagramom kumulativne frekvencije kratera (*cumulative crater frequency diagrams*), gdje horizontalna os sadrži logaritam dijametra kratera, a vertikalna os logaritam broja kratera određenog dijametra. U navedenom dijagramu kumulativna frekvencija kratera uobičajeno je pravac ili njegova aproksimacija. Time se dolazi do zaključka da se broj ukupnog broja kratera koji se mogu detektirati povećava proporcionalno smanjenju najmanjeg radijusa do kojeg se krater može uspješno detektirati CDA-om.

Temeljni algoritam za detekciju kratera iz topografskih slika, koji je opisan u prethodnom poglavlju, razvijen je za detekciju kratera čiji radijus je najmanje pet slikovnih elemenata (mjerenja značajki su to lošija što je krater manji). No analizom rezultata te usporedbom detekcija s optičkim slikama u višoj horizontalnoj rezoluciji od one u kojoj su dostupne topografske slike, pokazalo se da temeljni CDA može u nekim slučajevima detektirati i kratere čiji radijus je velik svega dva slikovna elementa. S obzirom na to da temeljni CDA uzima vrijednosti iz globalne topografske slike tako da za potrebne koordinate uzima topografsku vrijednost najbližeg slikovnog elementa, dolazi se do zaključka da to nije optimalan pristup s obzirom na iznimno mali broj uzoraka slikovnih elemenata (*sparse sampling*) (Blu et al., 2008) za kratere iznimno malog radijusa. Ovo razmatranje vodilo je do daljnjeg razvoja CDA-a, gdje se temeljni CDA opisan u prethodnom poglavlju proširuje interpolacijom. Nova metoda za interpolaciju, koja je temeljena na znanju o uobičajenom obliku kratera, razvijena je u tu svrhu. U prethodnim radovima nije se razmatralo kako bi se interpolacija mogla koristiti u svrhu što bolje detekcije kratere iz slika male horizontalne rezolucije, već se prije svega koristio obrnuti proces, filtriranje, kako bi se iz ulazne slike jednim dijelom uklonio šum prije daljnje detekcije velikih kratera.

Mogućnost detekcije kratere iz globalne lunarne odnosno planetarne slike, kako je opisano u uvodnom dijelu, poseban je izazov za CDA-ove i svega nekoliko njih je pokazalo da imaju tu mogućnost: (1) Michaelov (2003a) CDA koji se koristio za topografske podatke Marsa; (2) Stepinskov i Urbachov (2008) CDA, koji je također koristio topografske podatke Marsa, a koji je i rezultirao MA75919T katalogom; i (3) CDA koji je prvotno bio razvijen za detekciju kratera iz optičkih slika Marsa (Bandeira et al., 2007b), a za koji je naknadno pokazano da može obraditi globalne optičke slike Fobosa (Salamunićcar et al., 2011c). Mogućnost detekcije iz globalne lunarne, odnosno planetarne slike, ima i temeljni CDA opisan u prethodnom poglavlju, kako je prikazano u sljedećim poglavljima ovoga rada, gdje su dani njegovi rezultati. No mogućnost da jedan te isti CDA može detektirati kratere iz globalnih slika dva različita lunarna, odnosno planetarna tijela, do ovog istraživanja nije pokazao nijedan CDA. Ovo svojstvo je iznimno važno, s obzirom na to da željeni cilj nije razvoj novog CDA-a svaki puta kad se obrađuju globalni podaci nekog drugog planetarnog tijela, već da se jedan te isti CDA može uspješno koristiti u tu svrhu. U vrijeme razvoja temeljnog CDA-a opisanog u prethodnom poglavlju, globalni topografski podaci bili su dostupni samo za Mars, u horizontalnoj rezoluciji 1/128°, a za područja bliža polovima i u horizontalnim rezolucijama 1/256° i 1/512°. U međuvremenu, zahvaljujući SELENE i LRO (*Lunar Reconnaissance Orbiter*) misijama, postali su dostupni i globalni topografski podaci za Mjesec, SELENE LALT (*Laser Altimetry*) topografski podaci do horizontalne rezolucije 1/16° (Araki et al., 2009) i LRO LOLA podaci do horizontalne rezolucije 1/512° (Smith et al., 2010). Ovo je bila dodatna motivacija da se CDA-om temeljenim na interpolaciji osigura njegovo podjednako uspješno korištenje za detekciju kratera i iz globalne topografije Marsa i iz globalne topografije Mjeseca, s ciljem da se u budućnosti može koristiti i za detekciju kratera iz topografskih slika drugih lunarnih i planetarnih tijela.

5.2. Metoda za detekciju kratera temeljena na interpolaciji

Kako je opisano u potpoglavlju 2.2, postoje razni oblici kratera. Slika 24 prikazuje uobičajene oblike jednostavnih malih i kompleksnih velikih kratera, koji su poznati iz prethodnih istraživanja (Kiefer, 2011). Stoga se to apriori znanje o oblicima kratera može iskoristiti za razvoj CDA-a koji ima bolja svojstva detekcije. Cilj je poboljšanje svojstva značajne većine kratera koji su tih tipičnih oblika, a da se ujedno znatno ne pogoršaju svojstva detekcije kratera neuobičajenih oblika. Dodatni cilj je što točnije izmjeriti značajke katalogiziranih kratera, koje se mogu automatski mjeriti CDA-om ovoga rada. Oboje se postiglo razvojem metode interpolacije koja je prilagođena obliku kratera.

Metoda za detekciju kratera temeljena na interpolaciji je proširenje temeljne metode za detekciju kratera, koja je opisana u prethodnom poglavlju.

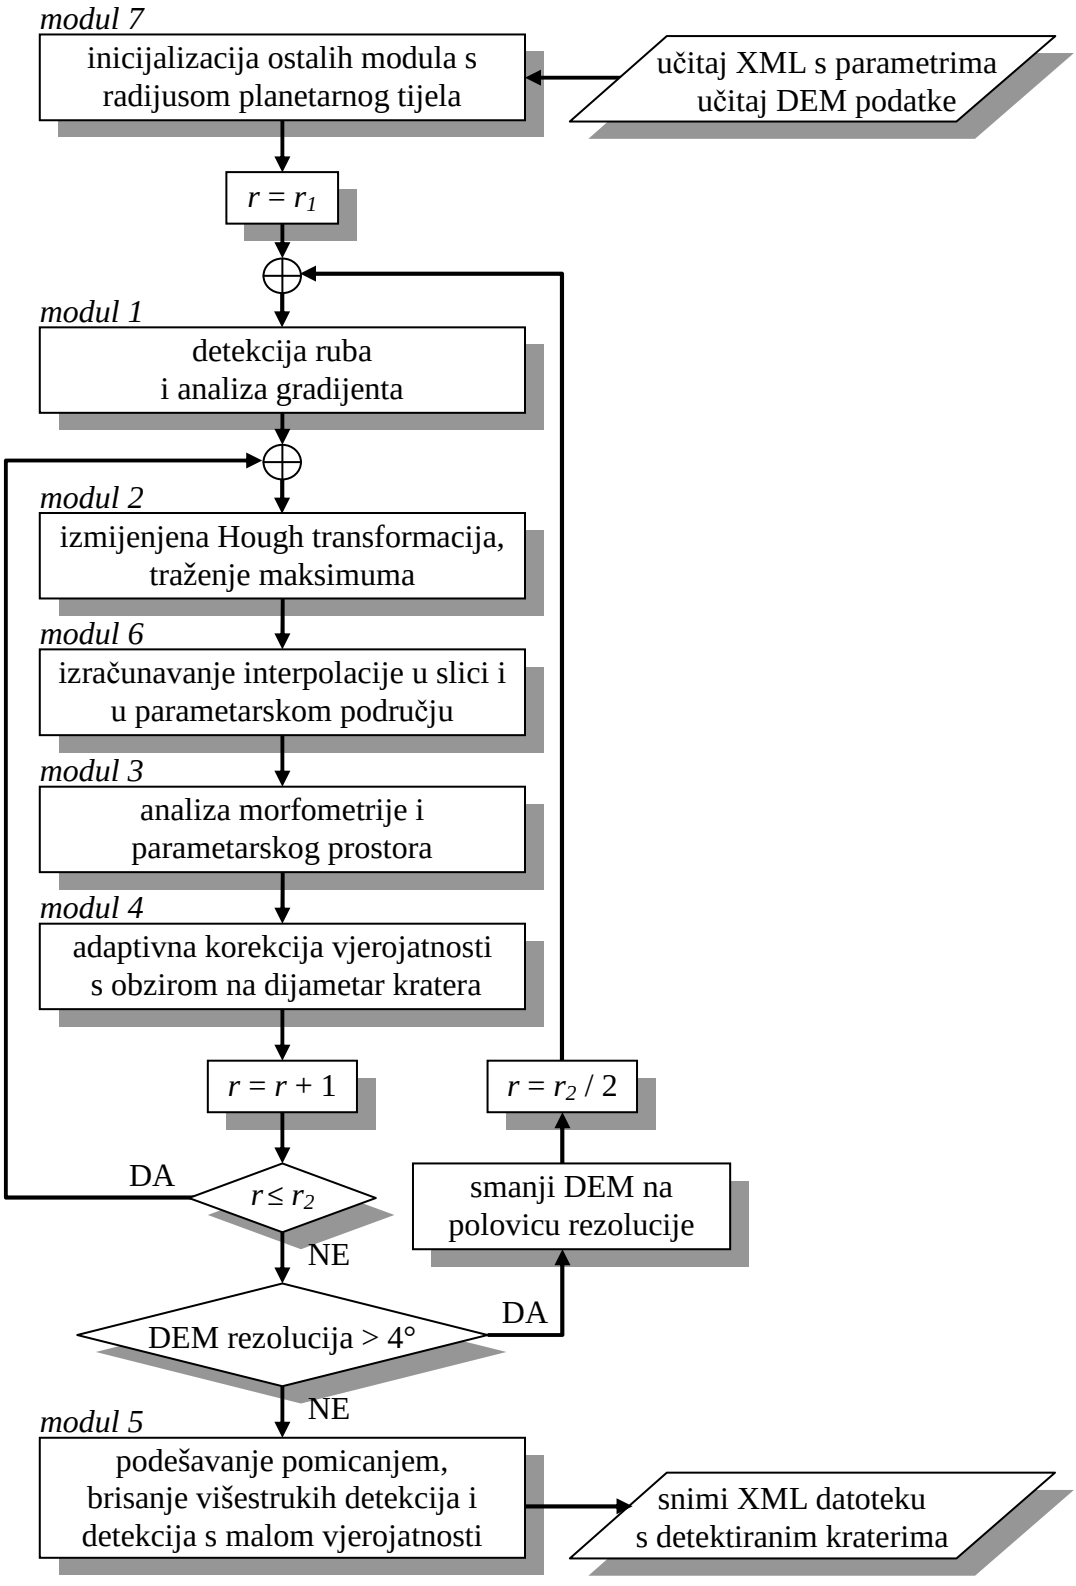
Moduli od 1 do 5 osiguravaju istu funkcionalnost kao i kod temeljnog CDA-a: (1) detekciju ruba i analizu gradijenta; (2) izmijenjenu Houghovu transformaciju; (3) analizu morfometrije i parametarskog prostora; (4) kalibraciju CDA-a ovisno o tome želimo li prvenstveno detektirati velike, srednje ili male kratere; (5) što preciznije određivanje položaja (koordinata) i dijametra detektiranog kratera. Proširenje se sastoji u: (1) modulu 6 – izračunavanju interpolacije temeljene na obliku kratera; te (2) u modulu 7 – adaptivnim korekcijama zavisnim od radijusa planetarnog tijela.

Modul 6 – interpolacija prilagođena obliku kratera, detaljno je opisan u potpoglavlju 5.3. Ulaz je topografska slika i izmijenjenom Houghovom transformacijom izračunate vrijednosti parametarskog prostora. Izlaz su vrijednosti dobivene interpolacijom koje se koriste u analizi morfometrije kratera i pripadnog parametarskog prostora. Na taj način modul 3 može napraviti potrebne analize koristeći nadodanu interpolaciju, umjesto da vrijednosti uzima direktno. Cilj je poboljšanje svojstva CDA-a, a ujedno i dobivanje točnijih rezultata pri korištenju CDA-a za automatsko mjerenje značajki kratera, kao što su primjerice omjer dubine i dijametra.

Modul 7 – adaptivne korekcije s obzirom na radijus planetarnog tijela, detaljno je opisan u potpoglavlju 5.4. Prvi se poziva, s obzirom na to da on mora inicijalizirati sve ostale module s ispravnom vrijednosti radijusa planetarnog tijela. S obzirom na to da se temeljni CDA koristio samo za topografske podatke Marsa, njegov radijus koristio se u samom kodu implementacije metode kao konstanta. Cilj je korištenje CDA-a temeljenog na interpolaciji, kako za detekciju kratera Marsa, tako i za detekciju kratera Mjeseca, te potencijalno i drugih lunarnih i planetarnih tijela. Stoga je radijus planetarnog tijela postao jedan od parametara koji se navode u ulaznom XML-u, kako bi se CDA pravilno inicijalizirao tom vrijednosti.

Kao i temeljni CDA opisan u prethodnom poglavlju, tako i CDA temeljen na interpolaciji može koristiti različite detektora ruba, koje je koristio i temeljni CDA, kao što su Cannyjev (1986) i Shen-Castanov (1992) detektor ruba. S obzirom na to da temeljni CDA daje najbolje rezultate kad se koristi Cannyjev detektor ruba, vrednovanje interpolacijskog CDA-a temeljilo se upravo na Cannyjevom detektoru ruba.

Slika 28 prikazuje dijagram toka predložene metode za detekciju kratera, koja uz višestruko rezolucijsku analizu slike koristi i interpolaciju prilagođenu obliku kratera.



Slika 28. Dijagram toka algoritma za detekciju kratera temeljenog na interpolaciji. © 2011 Elsevier (Salamunićcar et al., 2011f).

5.3. Modul 6: Interpolacija prilagođena obliku kratera

Primjena interpolacije u detekciji kratera osnovna je razlika između temeljnog CDA-a opisanog u prethodnom poglavlju koji je ne koristi i CDA-a opisanog u ovom poglavlju, koji je temeljen na posebno razvijenoj interpolaciji pogodnoj za detekciju kratera iz slika izrazito male horizontalne rezolucije (do radijusa od svega dva slikovna elementa).

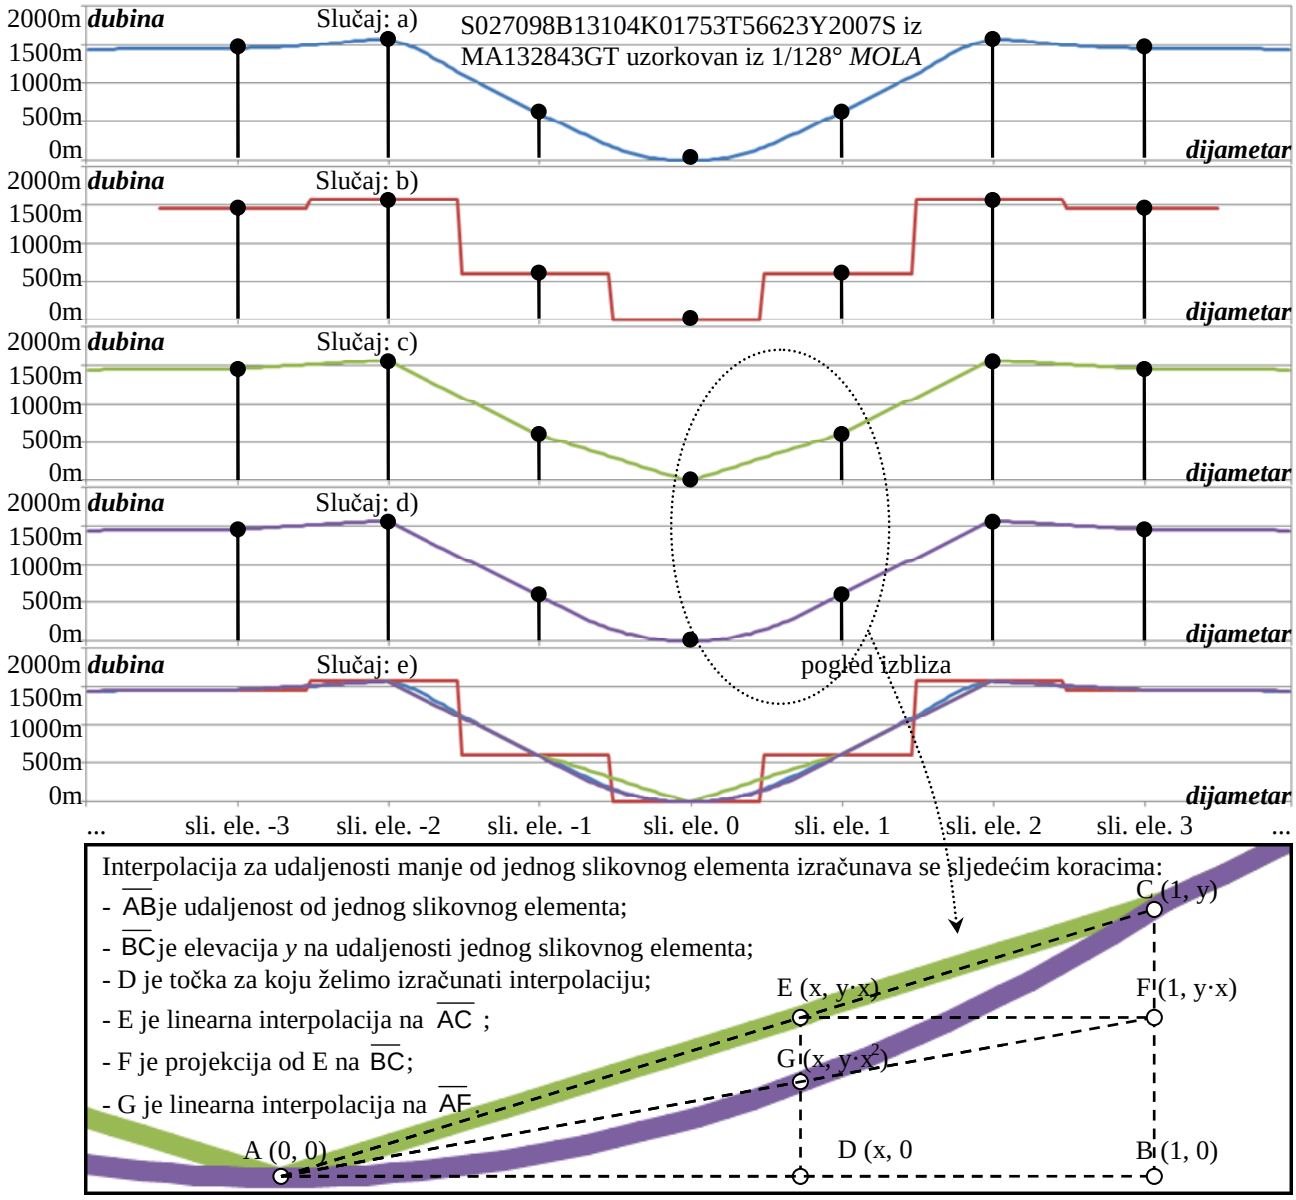
Pregled najčešće korištenih interpolacijskih funkcija (najbliži susjed - *nearest neighbor*, bi-linearna - *bilinear*, bi-kubična - *bicubic*, kvadratični splinovi - *quadratic splines*, kubični B-splinovi - *cubic B-splines*, B-splinovi višeg reda - *higher-order B-splines*, Catmull–Rom kardinalni splinovi - *cardinal splines*, Gaussova - *Gaussians, truncated sinc*) dan je u preglednom radu Zitove i Flussera (2003).

Kako bi se interpolacija što uspješnije primijenila u detekciji kratera, gdje se kao osnova koristi temeljni CDA iz prethodnog poglavlja, dodatno se treba uzeti u obzir sljedeće: (1) optimalna interpolacija treba se izračunavati u vrijeme izvođenja CDA-a i to samo za koordinate gdje je potrebna vrijednost visine (za razliku od statičke interpolacije kojom se od slike u danoj horizontalnoj rezoluciji dolazi do nove interpolirane slike u višoj horizontalnoj rezoluciji), kako izračunavanje interpolacije ne bi zahtijevala dodatnu radnu memoriju po svakom slikovnom elementu i kako bi količina izračunavanja bila što manja; (2) interpolacija treba sačuvati izvorni oblik kratera koliko god je moguće, odnosno ne smije negativno utjecati na karakteristike CDA-a (želimo dobiti bolji, a ne lošiji CDA), kako tijekom inicijalne detekcije kratera, tako i kod kasnijeg izračunavanja topografskih profila i iz njih izračunatih vrijednosti kao što su omjer dubine i dijametra; (3) kod najmanjih kratera imamo iznimno malo uzoraka slikovnih elemenata po krateru.

Na temelju ovih razmatranja dolazi se do sljedeće implementacije. Slika 29 prikazuje predloženu interpolaciju. Dio (a) prikazuje topografski profil jednog od kratera Marsa. Dio (b) prikazuje reprezentaciju slikovnim elementima (poznata i kao funkcija najbližeg susjeda), gdje je efekt digitalizacije ulaznih podataka prikazan s namjerno smanjenom horizontalnom rezolucijom u odnosu na dio (a). Rezultat linearne interpolacije prikazan je u dijelu (c). Može se primijetiti značajno poboljšanje za većinu segmenata, osim vrlo blizu centru kratera gdje postoji smanjenje točnosti što se vidi iz krivulje prikazane pod (c) koja ima diskontinuitet prve derivacije u centru kratera, dok izvorna krivulja pod (a) te aproksimacija slikovnim elementima pod (b) nemaju taj umjetni artefakt koji je posljedica računanja interpolacije, a ne oblika mjerene veličine. Kako bi se adekvatno tome pristupilo, kako je prikazano pod (d), dodatno je izmijenjena interpolacija za područje od centra kratera do najbližeg slikovnog elementa. Definicija, odnosno postupak računanja dodatne interpolacije, prikazan je u donjem dijelu te iste slike. Metoda interpolacije pretpostavlja parabolički oblik kratera. To je karakteristično za većinu malih kratera, a ujedno i pogodno za velike kratere koji imaju u svojem središtu centralno uzvišenje ili udubljenje. Navedeni oblici mogu se aproksimirati konveksnom, odnosno konkavnom parabolom. Kako je prikazano u dijelu (e), ovim se aproksimiraju izvorne vrijednosti u punoj horizontalnoj rezoluciji u svim segmentima značajno bolje nego kod prethodnih slučajeva prikazanih u dijelovima (b) i (c).

Rješenje prikazano pod (d) je vrlo učinkovito u smislu jednostavnosti izračunavanja s obzirom na to da se može implementirati kroz implementaciju jednostavne linearne interpolacije u svega dva koraka, gdje se drugi izvršava samo na udaljenostima od centra kratera manjim od jednog slikovnog elementa. Čak i kod udaljenosti od centra kratera manjih od jednog slikovnog elementa, ovaj pristup je značajno brži kod izračunavanja od drugih metoda interpolacije, kao što je na primjer izračun koeficijenata polinoma višeg reda.

Na temelju prethodnih razmatranja metoda prikazana pod (d) odabrana je za CDA temeljen na interpolaciji.



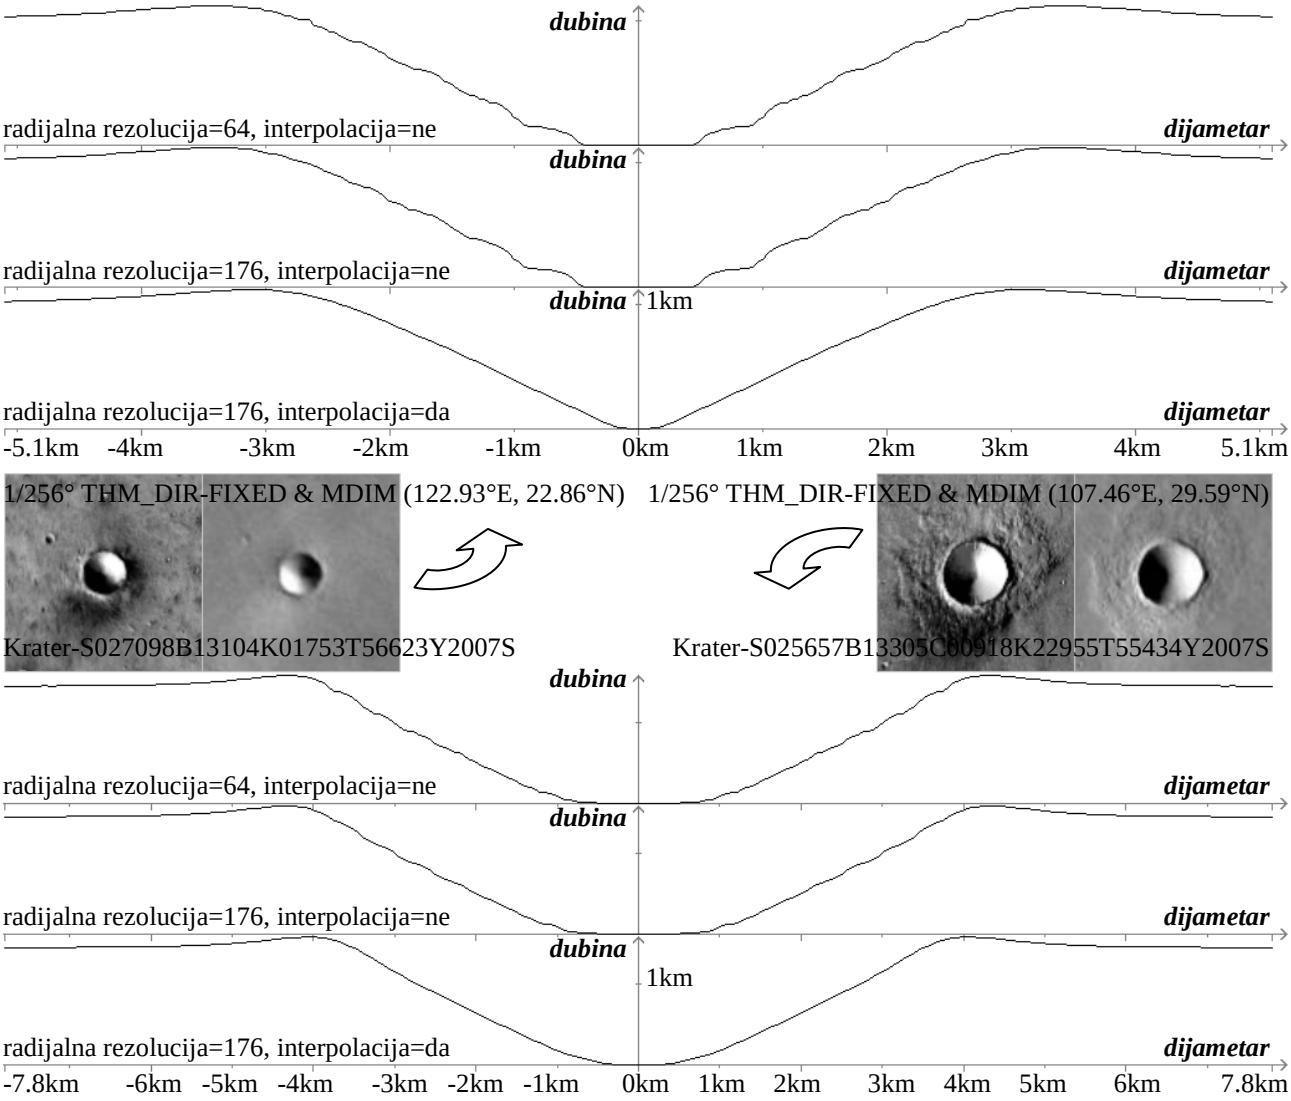
Slika 29. Interpolacija temeljena na obliku kratera. © 2011 Elsevier (Salamunićcar et al., 2011f).

Interpolacija temeljena na obliku kratera, a koja se koristi unutar CDA-a predloženog u ovom poglavlju, rezultira poboljšanim 3D-oblikom kratera te time i poboljšanim 2D-topografskim profilom, kako je prikazano na sljedećoj slici za dva kratera s posebno velikim omjerom dubine i dijametra (Vojković et al., 2010a).

Kako je prikazano za jedan manji (D = 5.1 km) krater s unutrašnjim profilom oblika slova V i jedan nešto veći (D = 7.8 km) krater s približno paraboličnim unutrašnjim profilom, povećanje radijalne rezolucije s obzirom na uzorkovanje ne može riješiti problem uzrokovan digitalizacijom slike. S druge strane, taj isti problem rješava interpolacija temeljena na obliku kratera. Rezultirajući 3D-oblik kratera te time i 2D-topografski profil, prikazan na istoj slici, ne sadrži artefakte uzorkovane neoptimalnom interpolacijom.

Slika 29 prikazuje kako krivulja (c) ima diskontinuitet prve derivacije i kod centra kratera i kod samog ruba kratera, dok krivulja (d) pokazuje da interpolacija temeljena na obliku kratera ovaj problem rješava sama po sebi samo kod centra kratera. Slika 30 prikazuje kako nema diskontinuiteta derivacije ni kod ruba kratera. Time se pokazuje da interpolacija temeljena na obliku kratera ovaj problem uspješno rješava u kombinaciji s velikim brojem uzorkovanja visinskih vrijednosti u smjerovima od centra kratera prema slikovnim elementima na rubu. To je rezultat

usrednjavanja većeg broja profila, gdje broj profila odgovara radijalnoj rezoluciji odnosno broju uzorkovanja od centra prema rubovima. Sama radijalna rezolucija odgovara broju slikovnih elemenata na kružnici koja je za *r* slikovnih elemenata udaljena od centra kratera. Tako primjerice za *r* od 28 slikovna elementa postoji ukupno $28 \cdot 2\pi$ = ~176 radijalnih skenova. Visoka radijalna rezolucija potrebna je i kod drugih elemenata CDA-a. S obzirom na to da se istim rješava problem kontinuiranosti profila u području ruba kratera, nije bilo potrebno razvijati složeniju metodu interpolacije. Dodatni razlog je što bi ista zahtijevala više izračunavanja, što se želi izbjeći.

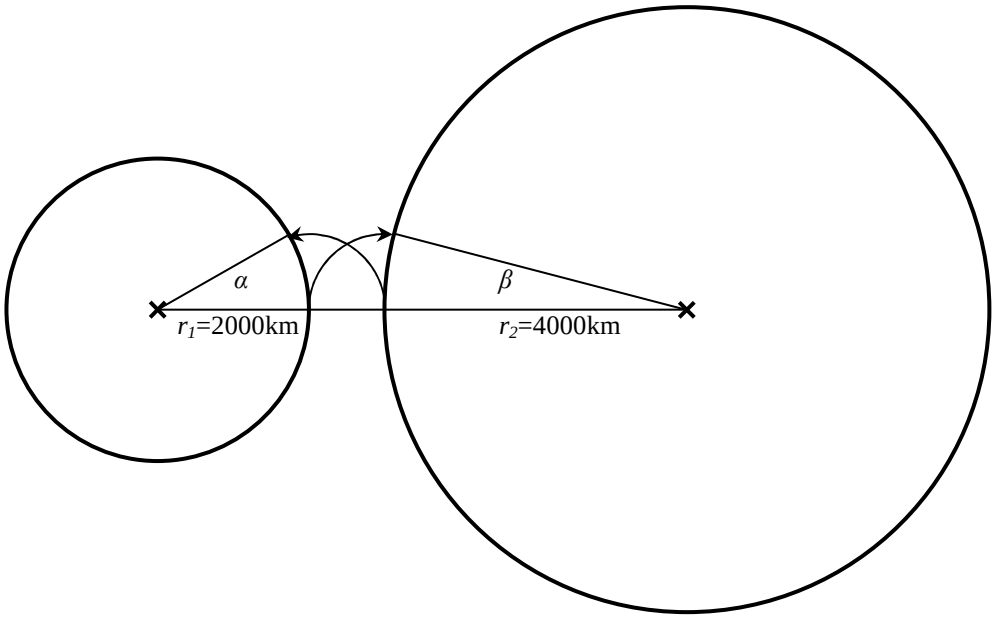


Slika 30. Poboljšanja u uzorkovanim 3D-oblicima i generiranim 2D-profilima kratera. © 2011 Elsevier (Salamunićcar et al., 2011f).

5.4. Modul 7: Adaptivne korekcije s obzirom na radijus planetarnog tijela

Osnovna svrha ovog modula je prosljeđivanje radijusa planetarnog tijela, kao i ostalih parametara, ostalim modulima. Na njima je da se u skladu s parametrima pravilno inicijaliziraju.

Slika 31 prikazuje zašto je za neke proračune važan radijus planetarnog tijela. Primjerice, ako su globalni topografski podaci za Mars u horizontalnoj rezoluciji 1/128° te globalni topografski podaci za Mjesec u istoj horizontalnoj rezoluciji 1/128°, ako je razlika visine dva susjedna slikovna elementa izražena u metrima ista, nije isti nagib površine pridružen razlikama visine i ta dva susjedna slikovna elementa. Razlog je različit radijus Marsa i Mjeseca, dok ista horizontalna rezolucija od 1/128° znači da je ukupna širina i visina globalne topografske slike u slikovnim elementima ista i za Mars i za Mjesec. Stoga slijedi da isti broj slikovnih elemenata odgovara različitom opsegu po ekvatoru, pa je zato različita horizontalna rezolucija izražena u metrima po slikovnom elementu. Samim time, istoj razlici visinskih vrijednosti pridružena je različita udaljenost te time i pridružen nagib.



Slika 31. Primjer koji pokazuje da se jedna te ista visinska vrijednost u metrima preslikava u različit kut ako su polumjeri planetarnih tijela različiti ($r_1 < r_2 \rightarrow \alpha > \beta$).

Vrijednost radijusa planetarnog tijela koristi se unutar CDA-a za izračunavanje nagiba, a što je među ostalim potrebno kod detekcije ruba implementirane unutar modula 1. S obzirom da detektor ruba očekuje nagib u određenim granicama, ovu korekciju je potrebno uzeti u obzir kako bi se isti CDA mogao koristiti i za Mars i za Mjesec bez posebnog podešavanja detektora ruba.

Vrijednost radijusa planetarnog tijela koristi se unutar CDA-a i za klasifikaciju kratera na temelju njihove veličine. Time je adaptivno implementiran i modul 4 koji korigira vjerojatnosti da je detektirani objekt krater ovisno o njegovom dijametru. Prilikom detekcije nekog kratera iz globalne topografske slike CDA, inicijalno ima samo informaciju o veličini kratera izraženoj u broju slikovnih elemenata. Stoga je i ovdje potreban radijus planetarnog tijela kako bi se broj slikovnih elemenata preračunao u kilometre. Tako se ista kalibracijska funkcija može koristiti i za Mars i za Mjesec. Primjerice krateri kojima je dijametar veći od 8 km tretiraju se na jedan način, krateri kojima je dijametar manji od 8 km i veći od 4 km, na drugi način, a oni krateri kojima je dijametar manji od 4 km, na treći način.

5.5. Metoda za projekciju podataka i kratera

Globalne topografske slike koje CDA ovoga rada koristi zapisane su u jednostavnoj cilindričnoj projekciji. Ista projekcija koristi se i kod ručne provjere svih detektiranih kratera, kada se pogrešne detekcije brišu, a točnim korigiraju koordinate i dijametri kratera prije katalogizacije. Svojstvo projekcije je sačuvanost duljina u smjeru sjever-jug, dok su u smjeru zapad-istok sačuvane samo kod ekvatora, dok se produljuju približavanjem polovima obrnuto proporcionalno kosinusu kuta udaljenosti od ekvatora. Time, s približavanjem polovima, krateri kružnog oblika imaju sve izduženiji eliptični oblik. Kako bi se ovo izobličenje uzelo u obzir, CDA udaljenosti u smjeru zapad-istok dijeli se s odgovarajućom vrijednosti. Na isti način se uzima u obzir svojstvo projekcije prilikom ručne obrade detektiranih kratera.

Naveden pristup dostatan je za CDA prilikom detekcije kratera na Marsu, gdje su gotovo svi krateri locirani između 87°N i 87°S. No isto nije dostatno i za Mjesec gdje nema polarnih depozita i gdje se krateri nalaze i na najsjevernijim i na najjužnijim područjima oko polova. Tu izobličenja idu praktički u beskonačnost (kosinus od 90° je 0, a dijeljenje s tim onda ide u beskonačnost). Tako za najekstremnije vrijednosti geografske visine kod CDA-a dolaze do izražaja problemi kod detekcije ruba, morfometrijskih mjerenja, kako u ulaznoj topografskoj slici, tako i u parametarskom prostoru koji je rezultat izmijenjene Houghove transformacije, podešavanja pomicanjem, i slično. Problem je i kod ručne provjere takvih kratera, jer su toliko izduženi da je i ljudskom oku teško pratiti njihovu konturu. Zato je teško zaključiti je li detekcija točna ili pogrešna, te precizno poravnati koordinate i popraviti određeni dijametar ako je potrebno.

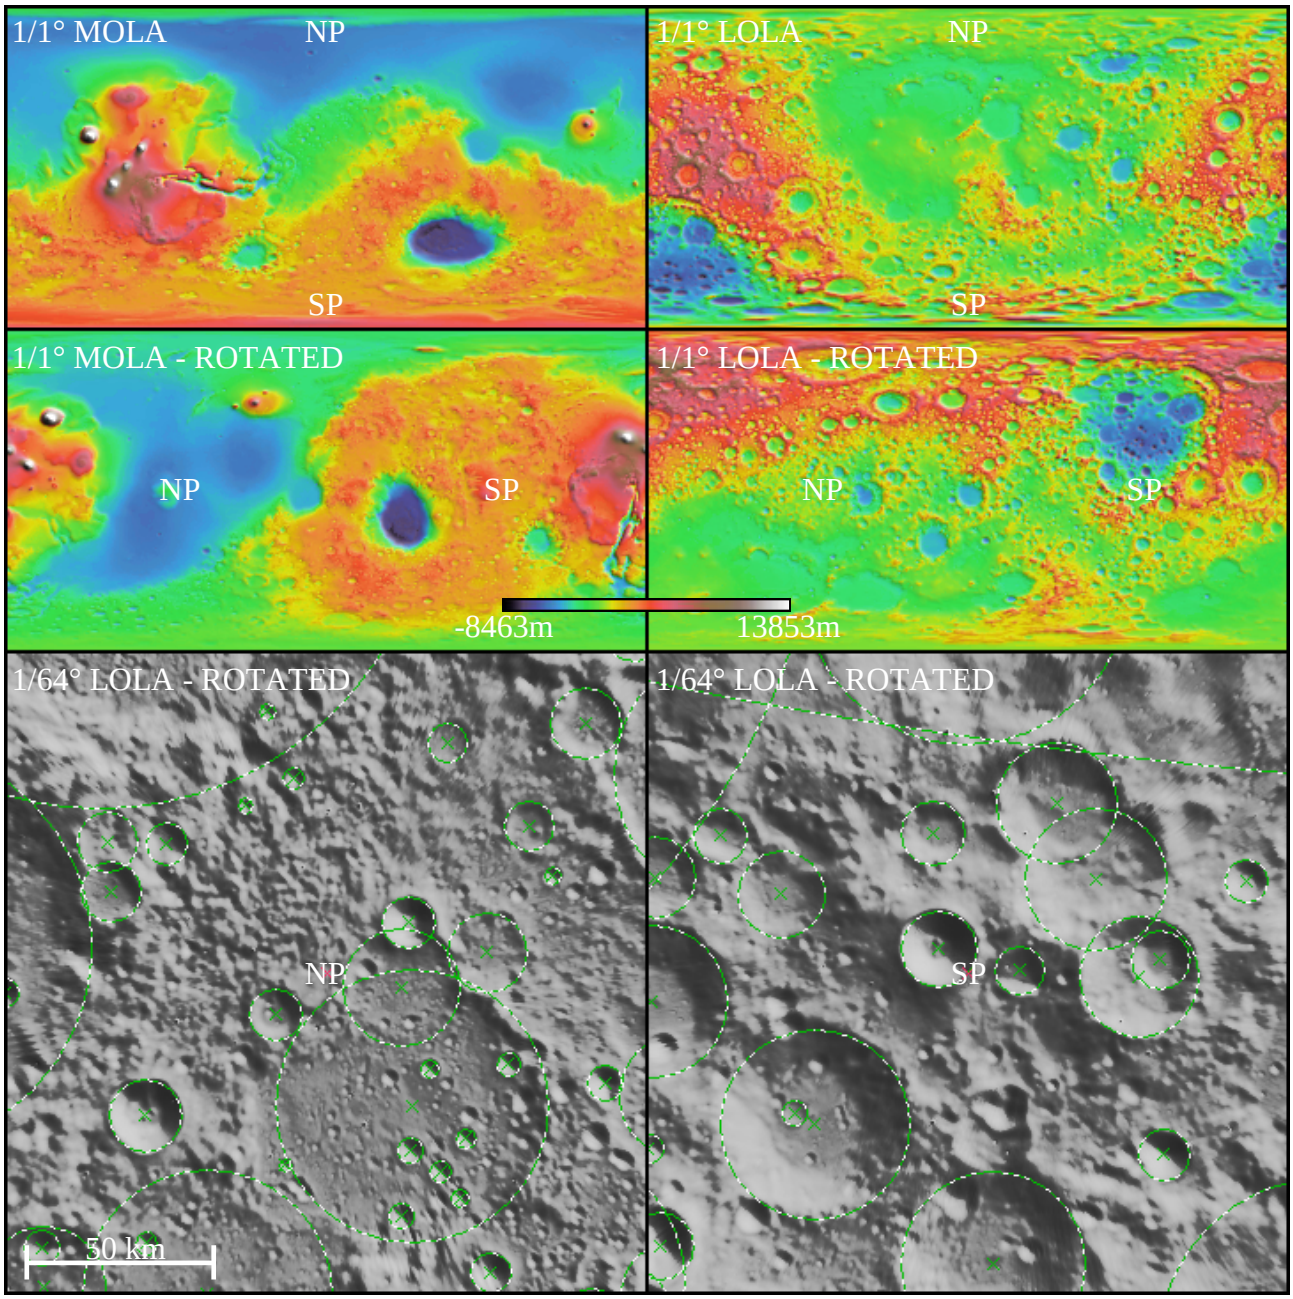
Ortografska projekcija s kraterom koji se analizira u centru projekcije napravljena je za provjeru kratera na Marsu. Ista je bila zadovoljavajuća pošto kratera nema sjevernije od 87°N i južnije od 87°S, pa je relativno jednostavno na ovaj način provjeriti najsjevernije i najjužnije kratere kako bi se utvrdilo da nisu potrebne dodatne korekcije. No kod Mjeseca imamo puno takvih kratera, pa sve pojedinačno provjeravati na ovaj način postaje vremenski prezahtjevno. Ova metoda se može koristiti kod ručne provjere detektiranih kratera. Međutim i sam CDA ima problema u detekciji kratera zbog iznimnih izobličenja kod jednostavne cilindrične projekcije kod geografskih širina najbližim polovima. Stoga ova metoda sama po sebi nije zadovoljavajuće rješenje.

Zbog ovih razloga je korištena nova metoda za projekciju globalnih podataka (optičkih i topografskih slika) i kratera (odnosno njihovih koordinata). Metoda geografski Sjeverni i Južni pol rotira na ekvator novog projekcijskog sustava. Cilj je izbjeći promjenu CDA-a odnosno metodologije za naknadnu obradu kratera, što bi iziskivalo puno vremena za implementaciju. To se na kraju metodom i postiglo.

Metoda funkcionira tako da se: (1) globalni podaci projiciraju iz jednostavne cilindrične projekcije na 3D-sferu; (2) sfera rotira za proizvoljan kut oko *x*, *y* i *z* osi; (3) globalni podaci reprojiciraju nazad s 3D-sfere u jednostavnu cilindričnu projekciju.

Ista metoda se može koristiti i za kratere: (1) kako bi se konvertirale globalne geografske koordinate, da budu u skladu s novim koordinatnim sustavom; (2) kako bi se nakon obrade podataka konvertirale nazad u početni koordinatni sustav.

Slika 32 prikazuje kako metoda rotira globalne podatke: (1) standardni (gore) i rotirani (sredina) prikaz za 1/1° MOLA (lijevo) i 1/1° LOLA (desno) topografske podatke; (2) rotirani prikaz koji se koristio za provjeru točnosti pridruženih koordinata i dijametara kratera, kako je prikazano za 1/64° LOLA podatke u područja Sjevernog pola (dolje lijevo) i Južnog pola (dolje desno).

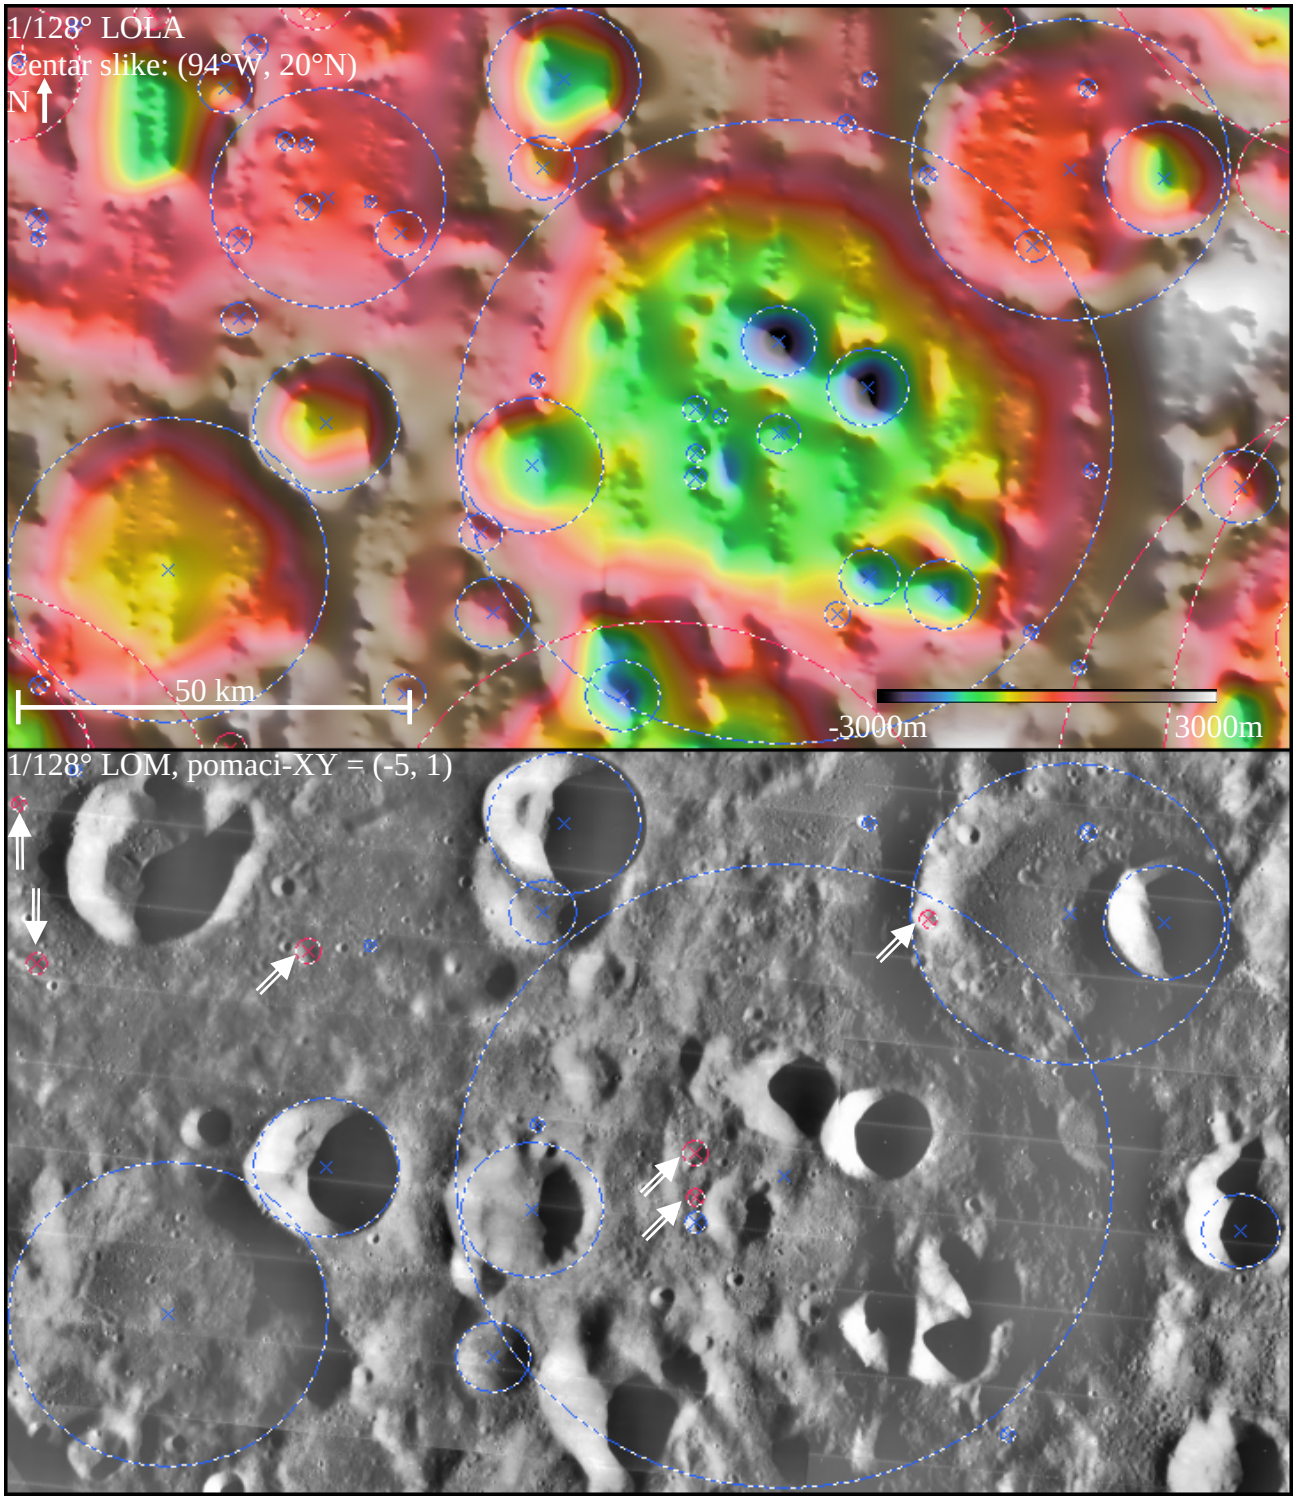


Slika 32. Projekcija podataka i kratera kako bi se bolje obradilo područje blizu polovima. © 2011 Elsevier (Salamunićcar et al., 2011f).

Ovim je osigurana zadovoljavajuća obrada cijelog planetarnog tijela, kako samom detekcijom kratera korištenjem CDA-a, tako i naknadnom ručnom obradom detektiranih kratera prilikom njihove katalogizacije.

5.6. Primjer za topografsku sliku Mjeseca

Detaljno vrednovanje metode dano je u poglavlju 9. Slika 33 prikazuje samo jedan primjer kojim se pokazalo da predloženi CDA, temeljen na interpolaciji, uspješno detektira kratere i iz globalne topografske slike Mjeseca: (1) većina kratera je uspješno detektirana; (2) broj pogrešnih detekcija je malen; (3) koordinate i dijametri su precizno određeni za većinu kratera.



Slika 33. Topografija Mjeseca i rezultat CDA-a temeljenog na interpolaciji (gore) te za kratere do odabrane granične vjerojatnosti točne (plava) i netočne (crvena, strelice) detekcije ustanovljene na temelju vrednovanja LU60645GT katalogom (dolje). © 2011 Elsevier (Salamunićcar et al., 2011f).

5.7. Zaključak

Rezultati postignuti metodom za detekciju kratera koja koristi interpolaciju temeljenu na obliku kratera su (Salamunićcar et al., 2011f): (1) CDA je pokazao još bolje karakteristike detekcije od temeljnog CDA-a, kako će biti pokazano u potpoglavlju 9.3.2., pri čemu je pokazano da se interpolacija može koristiti za poboljšanje svojstva detekcije; (2) razvijena metoda može se koristiti za topografije i Marsa i Mjeseca; (3) prethodni referentni katalog Marsa je značajno proširen s 2542 prethodno nekatalogiziranih kratera koje nije uspio pronaći temeljni CDA, a referentni katalog Mjeseca koji je sadržavao sve prethodno katalogizirane kratere značajno je proširen s 42 192 prethodno nekatalogizirana kratera, kako će i za Mjesec i za Mars više biti opisano u potpoglavlju 9.2.3.

Detekcija malih kratera, kao i erodiranih kratera te kratera koji su dijelom obrisani, bolja je od rezultata temeljnog CDA-a. Time se osiguralo proširenje kataloga kratera Marsa s kraterima koje temeljni CDA nije uspio detektirati. Zahvaljujući svojstvima koja su postignuta CDA-om opisanim u ovom poglavlju, porast broja pogrešnih detekcija još je manji nego za temeljnu verziju, čak i u modu gdje je CDA najosjetljiviji. Kao rezultat pronađen je značajan broj prethodno nekatalogiziranih kratera, uz manje kratera koje je pritom trebalo ručno obraditi, s obzirom na to da je omjer točnih i pogrešnih detekcija bolji nego za temeljni CDA.

Ovim se osigurala detekcija gotovo svih kratera dostupnih na topografskim slikama Marsa (MOLA podaci) i Mjeseca (LOLA podaci). To je ujedno i osnova za daljnji rad na CDA-u korištenjem strojnog učenja, strojem s potpornim vektorima, kako bi se što bolje mogle odvojiti točne od pogrešnih detekcija. Cilj je dodatno smanjenje vremena potrebnog za naknadnu ručnu obradu kratera.

6. III. KORAK: POBOLJŠANJE DETEKCIJE KRATERA STROJEM S POTPORNIM VEKTORIMA

U ovom poglavlju opisuje se metoda za detekciju kratera koja uz metodologiju temeljne metode za detekciju kratera i interpolaciju temeljenu na obliku kratera koristi i strojno učenje, kroz sljedeća potpoglavlja:

- 6.1. Uvod;
- 6.2. Metoda za detekciju kratera zasnovana na učenju;
- 6.3. Modul 8: Učenje strojem s potpornim vektorima;
- 6.4. Primjeri za topografske slike Marsa i Mjeseca;
- 6.5. Zaključak.

U potpoglavlju 6.1. daje se uvod u problematiku i opisuje motivacija za primjenu strojnog učenja kako bi se što više smanjio broj pogrešnih detekcija, s obzirom na to da je prethodno opisana metoda po svim ostalim kriterijima već postigla zadovoljavajuće rezultate. U potpoglavlju 6.2. opisuje se dijagram toka nove metode za detekciju kratera te ukratko opisuje novi modul strojnog učenja, koji se detaljnije opisuju u potpoglavlju 6.3. Primjer detekcije iz topografskih slika Marsa i Mjeseca, a iz kojih se jasno očituje smanjenje broja pogrešnih detekcija za isti broj točnih, dani su u potpoglavlju 6.4. U potpoglavlju 6.5. naveden je zaključak o postignućima metode za detekciju kratera koja uz interpolaciju i sve prethodno koristi i strojno učenje strojem s potpornim vektorima, kako bi osigurala što bolju detekciju kratera iz topografskih slika.

6.1. Uvod

Implementacijom temeljne metode za detekciju kratera i njezinim korištenjem prilikom katalogizacije kratera Marsa, značajnim poboljšanjem interpolacijom te dodatnim korištenjem za doradu kataloga kratera Marsa i izradu trenutno najpotpunijeg kataloga kratera Mjeseca, logičan sljedeći korak je analiza postignutog, za određenje smjernica daljnjeg razvoja.

Nažalost, metode ovoga rada (temeljna i koja koristi interpolaciju) ne mogu se usporediti s CDA-om koji je razvio Michael (2003a), s obzirom na to da isti nije rezultirao nekim novim katalogom. Također, metode ovoga rada ne mogu se usporediti s CDA-om koji je prvotno bio razvijen za detekciju kratera iz optičkih slika Marsa (Bandeira et al., 2007b), a za koji je naknadno pokazana mogućnost obrade globalne optičke slike Fobosa (Salamunićcar et al., 2011c), s obzirom na to da su topografske slike Fobosa dostatne za detekciju jako malog broja kratera. Time je jedini CDA koji je u detekciji kratera iz topografskih slika usporediv s CDA-ovima ovoga rada, Stepinskov i Urbachov (2008) CDA, a koji je rezultirao MA75919T katalogom.

Usporedbom je pokazano, ako se uzimaju u obzir samo detektirani krateri s precizno određenim koordinatama i dijametrima ($f_m < 0.5$), da su CDA-ovi ovoga rada po svim kriterijima bolji. Razlika je u većem broju točnih za bilo koji broj pogrešnih detekcija. Time su i izvedene mjere koje se koriste u vrednovanju pokazale isto. Također, sveukupni broj kratera koje mogu detektirati CDA-ovi ovoga rada puno je veći, pa su i po tom kriteriju bolji. No ako se uzmu u obzir i detektirani krateri kojima nisu precizno određene koordinate ili dijametar ($0.5 < f_m < 3$), dolazi se do zaključka da je u jednom području rada bolji Stepinskov i Urbachov (2008) CDA. Ukratko, njihov CDA može detektirati manje kratera, detektira ih s lošijom preciznosti koordinata i dijametra, ali ima manji postotak pogrešnih detekcija.

Time je cilj daljnjeg razvoja postao smanjenje udjela pogrešnih detekcija u odzivu CDA-a. Što je katalog kratera potpuniji, teže je pronaći dodatne kratere koji prethodno nisu bili katalogizirani. Obično su to krateri koji su iznimno erodirani ili su ih većim dijelom obrisali drugi krateri, pa ih je vrlo teško razlikovati od ostalih geoloških oblika, kako CDA-u, tako i osobi koja ručno katalogizira kratere.

Ova problematika može se opisati sljedećim primjerom. U prvom koraku polazimo od onih kandidata za kratere kojima je CDA pridijelio najvišu vjerojatnost da su zaista krateri, a ne pogrešne detekcije. Tu gotovo da i nema pogrešnih detekcija. No nakon što se ti kandidati za kratere obrade, prelazi se na one kojima je CDA pridijelio nešto manju vjerojatnost da su krateri. Tu već ima više pogrešnih detekcija. Kako katalog postaje sve potpuniji, a kandidati za kratere koji se ručno provjeravaju imaju sve manju pridruženu vjerojatnost da su točne detekcije, potrebno je pregledati sve više kandidata kako bi se pronašla neka nova točna detekcija.

Ovo je motivacija za dodatnim CDA-ovim poboljšanjem, primjenom strojnog učenje, kako bi broj pogrešnih detekcija u odnosu na točne bio što manji.

Osoba koja katalogizira kratere obično mora CDA-u osigurati primjere točnih i pogrešnih detekcija. Dodatni cilj je to izbjeći. To je važno s obzirom na to da je odabir dobrih primjera za učenje sam po sebi problematičan prilikom obrade globalnih podataka kao i kada osoba koja koristi CDA nije tehnički stručna da odabere dobre primjere za učenje. Umjesto toga, CDA treba samostalno naučiti kako da se poboljša, na temelju već katalogiziranih kratera. To je samo po sebi također izazov, s obzirom na to da su obično dostupni samo katalogizirani krateri, a ne i oni koji su kao pogrešne detekcije jednostavno obrisani.

6.2. Metoda za detekciju kratera zasnovana na učenju

Predložena metoda za detekciju kratera iz topografskih slika koja koristi strojno učenje strojem s potpornim vektorima proširenje je temeljne metode i metode koja koristi interpolaciju temeljenu na obliku kratera, koje su opisane u prethodna dva poglavlja.

Moduli od 1 do 7 osiguravaju istu funkcionalnost kao i kod CDA-a temeljenog na interpolaciji: (1) detekciju ruba i analizu gradijenta; (2) izmijenjenu Houghova transformaciju; (3) analizu morfometrije i parametarskog prostora; (4) kalibraciju CDA-a ovisno o tome želimo li prvenstveno detektirati velike, srednje ili male kratere; (5) što preciznije određivanje položaja (koordinata) i dijametra detektiranog kratera; (6) izračunavanje interpolacije temeljene na obliku kratera; (7) adaptivne korekcije s obzirom na radijus planetarnog tijela. Proširenje se sastoji u modulu 8, primjeni strojnog učenje kako bi se smanjio omjer pogrešnih i točnih detekcija.

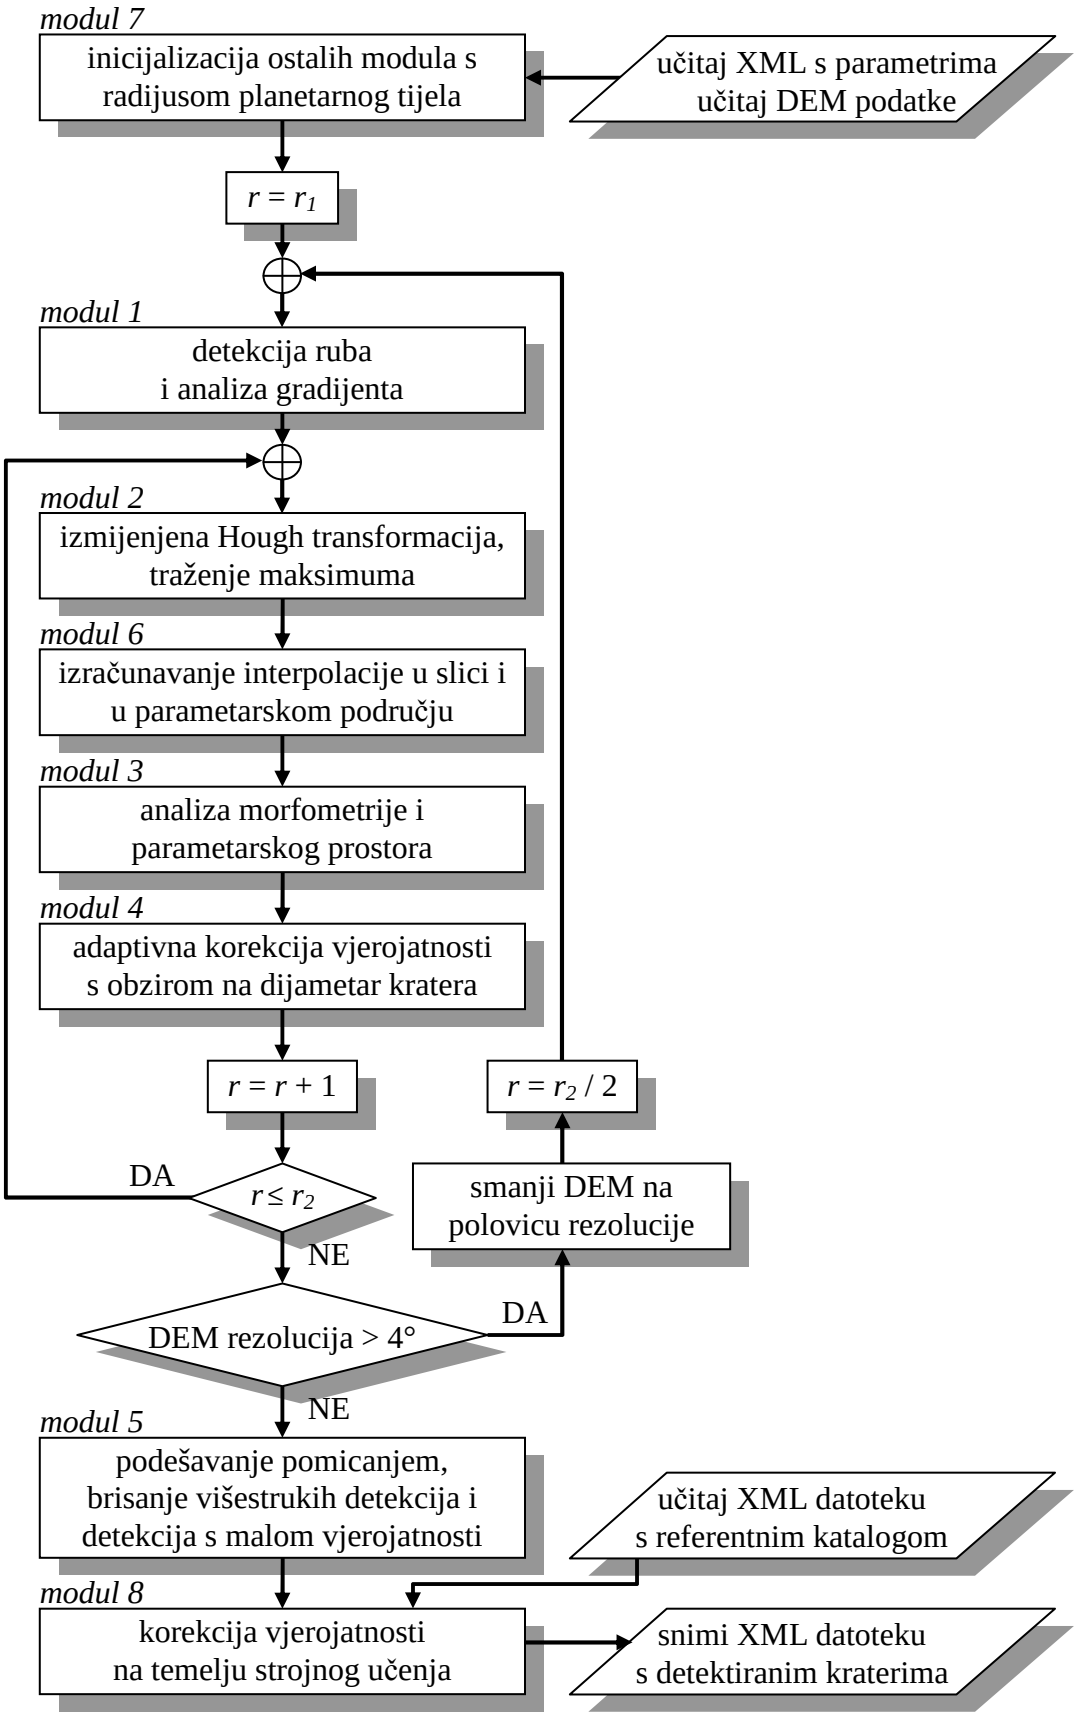
Modul 8 – učenje strojem s potpornim vektorima, detaljno je opisan u potpoglavlju 6.3. Ulaz je lista detektiranih kandidata za kratere, koja za svaki krater sadrži njegove koordinate, dijametar te početnu procjenu vjerojatnosti da je detektiran objekt krater. Izlaz je bolje procijenjena vjerojatnost da je detektiran objekt krater, dok se ostale značajke detektiranih kandidata za kratere ne mijenjaju u ovoj završnoj fazi obrade. U ovome radu koristi se strojno učenje strojem s potpornim vektorima. Na temelju istih principa otvorena je mogućnost korištenja i drugih metoda strojnog učenja.

Teoretski najbolja implementacija strojnog učenja bi svim pogrešnim detekcijama trebala pridijeliti vjerojatnost 0 (što znači da je vjerojatnost da je detekcija krater jednaka 0%), a svim točnim 1 (što znači da je vjerojatnost da je detekcija krater jednaka 100%). U praksi to nije moguće postići, no cilj je postići značajno bolju klasifikaciju u jednu od dva razreda (*krater* i *nije krater*) od one koju su postigli prethodni koraci obrade.

Strojno učenje može se koristiti na klasičan način, gdje korisnik priprema skup za učenje s primjerima točnih i pogrešnih detekcija, kako bi se na temelju toga strojnim učenjem mogla poboljšati svojstva detekcije. No kako korisnik ne bi morao kreirati primjere za učenje, za strojno učenje može se koristiti i referentni katalog. Osnovni princip je klasifikacija (automatskom validacijom referentnim katalogom) svih detekcija CDA-a u jedan od dva korištena razreda (*krater* i *nije krater*). Time se automatski može generirati velik broj primjera za učenje, gdje se dodatnim podjelama ulaznog skupa za učenje može osigurati nekorištenje istih primjeri i za učenje i za predikciju. Time, porastom broja kratera koje korisnik katalogizira, algoritam za učenje poboljšava svojstva CDA-a. To je rezultat većeg broja primjera točnih detekcija iz kojih može učiti, te manje točnih detekcija u preostalim kandidatima za kratere, pa samim time i boljeg skupa primjera pogrešnih detekcija. Ovo je važno svojstvo, jer potreba za boljim svojstvima CDA-a u katalogizaciji kratera i dolazi upravo do izražaja kada je katalog većim dijelom već napravljen. Tada naime na ručnu obradu dolaze oni kandidati za kratere koje je CDA detektirao s puno manjom vjerojatnosti da su zaista krateri.

Kao i temeljni CDA opisan u prethodnom poglavlju te CDA koji je temeljen na interpolaciji, tako i CDA koji uz sve prethodno dodatno koristi i strojno učenje može koristiti različite detektora ruba, kao što su Cannyjev (1986) i Shen-Castanov (1992) detektor ruba. S obzirom na to da temeljni CDA daje najbolje rezultate pri korištenju Cannyjeva detektora ruba te da se vrednovanje interpolacijskog CDA-a temeljilo na Cannyjevom detektoru ruba, isti se koristio i u okviru razvoja i vrednovanja CDA-a opisanog ovim poglavljem.

Slika 34 prikazuje dijagram toka predložene metode za detekciju kratera, koja uz višestruko rezolucijsku analizu slike i interpolaciju prilagođenu obliku kratera koristi i strojno učenje.



Slika 34. Dijagram toka algoritma za detekciju kratera temeljenog na učenju.

6.3. Modul 8: Učenje strojem s potpornim vektorima

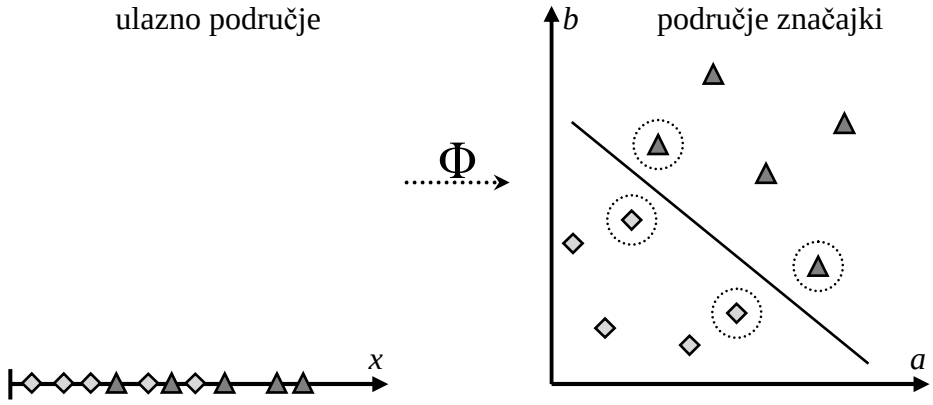
Zadatak stroja s potpornim vektorima je točnija procjena vjerojatnosti da je detektiran objekt krater. Metodologija kojom je proširena metoda za detekciju kratera iz topografskih slika, a koja se temelji na strojnom učenju strojem s potpornim vektorima, opisana je sljedećim potpoglavljima:

- 6.3.1. Osnovni principi stroja s potpornim vektorima;
- 6.3.2. Učenje o oblicima kratera;
- 6.3.3. Učenje o geološkom kontekstu kao dodatak učenju o kraterima;
- 6.3.4. Dohvat značajki strojnog učenja;
- 6.3.5. Metoda strojnog učenja temeljena na stroju s potpornim vektorima;
- 6.3.6. Integracija rezultata strojnog učenja.

6.3.1. Osnovni principi stroja s potpornim vektorima

Stroj s potpornim vektorima koristi se u ovome radu kako bi se poboljšala svojstva detekcije kratera. Cilj je što bolje razlučiti točne od pogrešnih detekcija. Slika 35 prikazuje osnovnu zamisao uporabe stroja s potpornim vektorima u kontekstu strojnog učenja (Vapnik, 2000; Hearst et al., 1998). Nelinearna funkcija Φ preslikava ulazno područje (na slici jedne dimenzije *x*) u područje značajki (na slici dvije dimenzije *a* i *b*), koje ima više dimenzija, ali se zato hiperravninom može bolje izvršiti klasifikacija. Pritom se korištenjem različitih jezgrenih funkcija (najuobičajenije su radijalne i polinomne) to može napraviti bez izračunavanja same funkcije Φ.

Potporni vektori (na slici označeni kružnicama) su vektori najbliži hiperravnini te su samo oni potrebni za daljnju klasifikaciju objekata (na slici u razred trokuta ili u razred četverokuta). Učenje stroja s potpornim vektorima sastoji se od određivanja potpornih vektora odnosno hiperravnine, koristeći ulazne vektore čija je točna klasifikacija poznata. Predikcija strojem s potpornim vektorima sastoji se od klasifikacije vektora čiji razred nije poznat, s obzirom na to s koje strane hiperravnine se nalaze.



Slika 35. Princip rada stroja s potpornim vektorima.

U našem slučaju vektor je skup značajki kratera koji među ostalim obuhvaća koordinate centra, radijus, i vjerojatnost da je detektiran objekt krater. Razredi u koje stroj s potpornim vektorima klasificira vektore pridružene detektiranim objektima (kandidatima za kratere) su *krater* i *nije krater*. Cilj je razlučivanje pogrešnih od točnih detekcija iz velikog broja detektiranih kandidata za kratere, kako bi se kasnijom ručnom provjerom i katalogizacijom trebalo pregledati što manje kratera.

Uz samu klasifikaciju u jedan od dva razreda (*krater* i *nije krater*), stroj s potpornim vektorima na temelju udaljenosti od hiperravnine dodatno može procijeniti vjerojatnost *p* da je objekt krater (odnosno da pripada razredu *krater*), te time i vjerojatnost 1 - *p* da nije (odnosno da pripada razredu *nije krater*). Stoga imamo dvije moguće implementacije. Prva mogućnost je izdvajanje i brisanje svih kandidata za kratere kojima je *p* manji od 50% (odnosno onih koji su klasificirani u razred *nije krater*), a ostalim (onima koji su klasificirani u razred *krater*) pritom ne mijenjamo pridruženu vjerojatnost da su krateri (izračunatu prethodnim koracima). Druga mogućnost je ostavljanje svih kratera, s tim da im pritom prethodno pridruženu vjerojatnost da su krateri zamijenimo s *p* izračunatog strojem s potpornim vektorima. U ovome radu koristi se druga mogućnost jer se na taj način, kako je pokazalo kasnije vrednovanje, postižu bolji rezultati.

6.3.2. Učenje o oblicima kratera

Kao što je opisano u prethodnim poglavljima, postoji mnogo oblika kratera, a svaki od njih vremenom erodira i time dodatno mijenja oblik. Cilj je da metoda zasnovana na učenju na temelju informacija o poznatim kraterima što bolje klasificira još nekatalogizirane kratere za koje nije poznato jesu li točne ili pogrešne detekcije CDA-a.

Temeljni CDA, pa time i CDA zasnovan na interpolaciji, izračunavaju brojne značajke kratera. To svojstvo se koristi da se na isti način mogu dohvatiti značajke i prilikom strojnog učenja.

Značajke koje se mogu koristiti prilikom strojnog učenja prije svega su osnovne značajke 3D-oblika kratera koje CDA izračunava prilikom detekcije kratera. Primjeri su omjer dubine i dijametra, rezultati mjerenja cirkularnosti kratera, ruba kratera i centralnog uzvišenja kratera.

Također se mogu koristiti i različite pridijeljene vjerojatnosti koje CDA računa u svom radu. Primjeri su vjerojatnost koju je kao konačnu pridijelio prethodni dio CDA-a, te vjerojatnosti pridijeljene cirkularnosti, rubu kratera, centralnom uzvišenju kratera, kao i vjerojatnost ponovno izračunata na temelju morfologijskih mjerenja prilikom podešavanja kratera pomicanjem.

Mogu se koristiti i značajke koje se ne koriste u prethodnom radu CDA-a, a koje su dodane za poboljšanje svojstva strojnog učenja. Primjer su ekscentričnost i nagib elipse koja, generalno gledano, može odrediti krater bolje od kružnice. Stoga je modul 3 proširen da može izračunati i parametre elipse. Parametri elipse mogu biti korisni u strojnom učenju, s obzirom na to da pogrešne detekcije koje su blizu često mogu imati slične vrijednosti. Primjer su pogrešne detekcije kratera locirane u kanjonu, gdje im je svima nagib elipse u smjeru kanjona, a ekscentričnost također podjednako uvjetovana oblikom kanjona. Ponekad je i cilj izbjeći katalogizaciju sekundarnih kratera, koji nastaju kada krhotine primarnog kratera padnu uobičajeno nedaleko od njega i pritom generiraju nakupine sekundarnih kratera. O smjeru iz kojeg su doletjele krhotine koje su rezultirale sa sekundarnim kraterima ovisi i nagib pridružen njihovim elipsama. Također, zbog uobičajeno manjeg kuta pod kojim krhotine udare o površinu, ekscentričnost sekundarnih kratera uobičajeno je veća od onih primarnih. Stoga su kao dodatne značajke upravo odabrani parametri elipse.

Parametri elipse se računaju na sljedeći način: (1) određuje se 75% iznosa dubine kratera kao dubina konture koja će se analizirati; (2) za sve radijalne profile uzima se vrijednost udaljenosti od centra kratera do konture određene u prethodnom koraku; (3) najveća razlika udaljenosti između dva slikovna elementa konture na pravcu *a* i dva na pravcu *b*, gdje je pravac *a* okomit na pravac *b* i oba pravca prolaze kroz središte kratera, traži se za određenje nagiba elipse; (4) omjer prethodne dvije udaljenosti uzima se kao vrijednost ekscentričnosti elipse.

Također se uz pojedinačne značajke mogu koristiti i profili kratera (2D-podaci), kao i njihovi izvorni oblici (3D-podaci). Ovi podaci predstavljaju puno više značajki od prethodnih, pa mogu biti poprilično zahtjevni kod strojnog učenja, to jest potrebno je više vremena i radne memorije za izračunavanja.

6.3.3. Učenje o geološkom kontekstu kao dodatak učenju o kraterima

Kod ručnog označavanja kratera, kada se radi o nejasno definiranoj ili iznimno erodiranoj geološkoj strukturi, često o geološkom kontekstu ovisi odluka je li ista krater ili to nije. Na iznimno glatkoj površini, gdje se nalaze gotovo isključivo krateri različitih veličina, čak i za kratere velike svega nekoliko slikovnih elemenata možemo biti poprilično sigurni da su zaista krateri. S druge strane, ako u nekom području ima iznimno puno neravnina ili drugih struktura sličnih kraterima, a gotovo uopće nema kratera koji su relativno dobro očuvani, vrlo je mala vjerojatnost da su promatrane geološke strukture krateri.

Dosadašnja istraživanja CDA-ova isključivo su se temeljila na značajkama kratera. Kako bi se uzeo u obzir i geološki kontekst, značajkama strojnog učenja dodane su i koordinate kandidata za kratere. Time se ne mora raditi dodatna analiza, odnosno detekcija, ostalih geoloških struktura, ili svojstava površine kao što su hrapavost, nagib, i slično.

Na ovaj način, iako nema direktan uvid u geološki kontekst, CDA ima indirektni uvid preko analize grupiranosti pogrešnih detekcija. Cilj je takve grupacije pogrešnih detekcija detektirati i razlučiti od točnih detekcija. CDA ovime ima uvid u geološki kontekst onoliko koliko je isti utjecao na svojstva CDA-a da detektira kratere. Više od toga i nije potrebno za poboljšanje svojstva detekcije kratera.

Važno je da se isti krateri ne koriste i za učenje i za predviđanja, stoga se svaki krater klasificira u jedan od dva razreda. Sama klasifikacija vrši se na temelju zbroja x i y koordinate. Zbroj može biti ili paran ili neparan broj, budući da su i x i y cjelobrojne vrijednosti koje označavaju udaljenost u slikovnim elementima od gornjeg lijevog ruba slike. Stoga su razredi kratera nazvani *parni* i *neparni*.

Na taj način se sustav za učenje dijeli u dva dijela. Prvi na temelju primjera točnih i pogrešnih detekcija kratera uči gdje je zbroj koordinata paran broj i koristi se za predviđanje ostalih kandidata za kratere gdje je zbroj koordinata neparan broj. Drugi na temelju primjera uči gdje je zbroj koordinata neparan broj i koristi se za predviđanje gdje je zbroj koordinata paran. Na taj način osigurano je da se isti primjer nikad ne koristi i za učenje i za predviđanje, a s druge strane da je cijelo planetarno tijelo dovoljno dobro pokriveno kako bi učenje o geološkom kontekstu moglo dodatno poboljšati svojstva CDA-a.

6.3.4. Dohvat značajki strojnog učenja

U sljedećoj tablici navedene su prethodno spomenute značajke strojnog učenja. Koje značajke će CDA koristiti, ovisi o korisniku. Mogu se u prvom koraku koristiti značajke serije 1, a u drugom serije 2, što, kako će se pokazati ovim radom, daje najbolje rezultate kod korištenja stroja s potpornim vektorima s radijalnom jezgrom. No korisnik može i sam odabrati koje značajke iz sljedeće tablice će se koristiti. CDA na temelju toga onda priprema značajke strojnog učenja.

Samo strojno učenje ne mora biti temeljeno na stroju s potpornim vektorima, koji se koristi u ovome radu. Jednom nakon što su dohvaćene značajke kandidata za kratere, u principu se može koristiti i bilo koja druga metoda za strojno učenje. Pritom se od metode strojnog učenja zahtjeva dovoljna učinkovitost kako bi mogla obraditi ovoliku količinu podataka i pritom poboljšati klasifikaciju u jednu od dva razreda (*krater* i *nije krater*), odnosno da kandidatima za kratere može pridijeliti bolje procijenjenu vjerojatnost p da je detektiran objekt krater. Stoga korisnik i ima mogućnost odabira značajki koje će se koristiti, a ovisno o odabiru metode za učenje može upravo ovisiti i odabir značajki.

Sve značajke osim ekscentričnosti i nagiba elipse dohvaćaju se koristeći prethodno implementirane metode CDA-a, opisane u poglavlju 4. Parametri elipse računaju se koristeći

metodu opisanu u potpoglavlju 6.3.2. Time se ujedno određuje i nagib i ekscentričnost elipse koja sam krater bolje aproksimira od prethodno pridijeljene kružnice.

Tablica 5. Pregled značajki strojnog učenja koje se koriste, odnosno mogu koristiti.

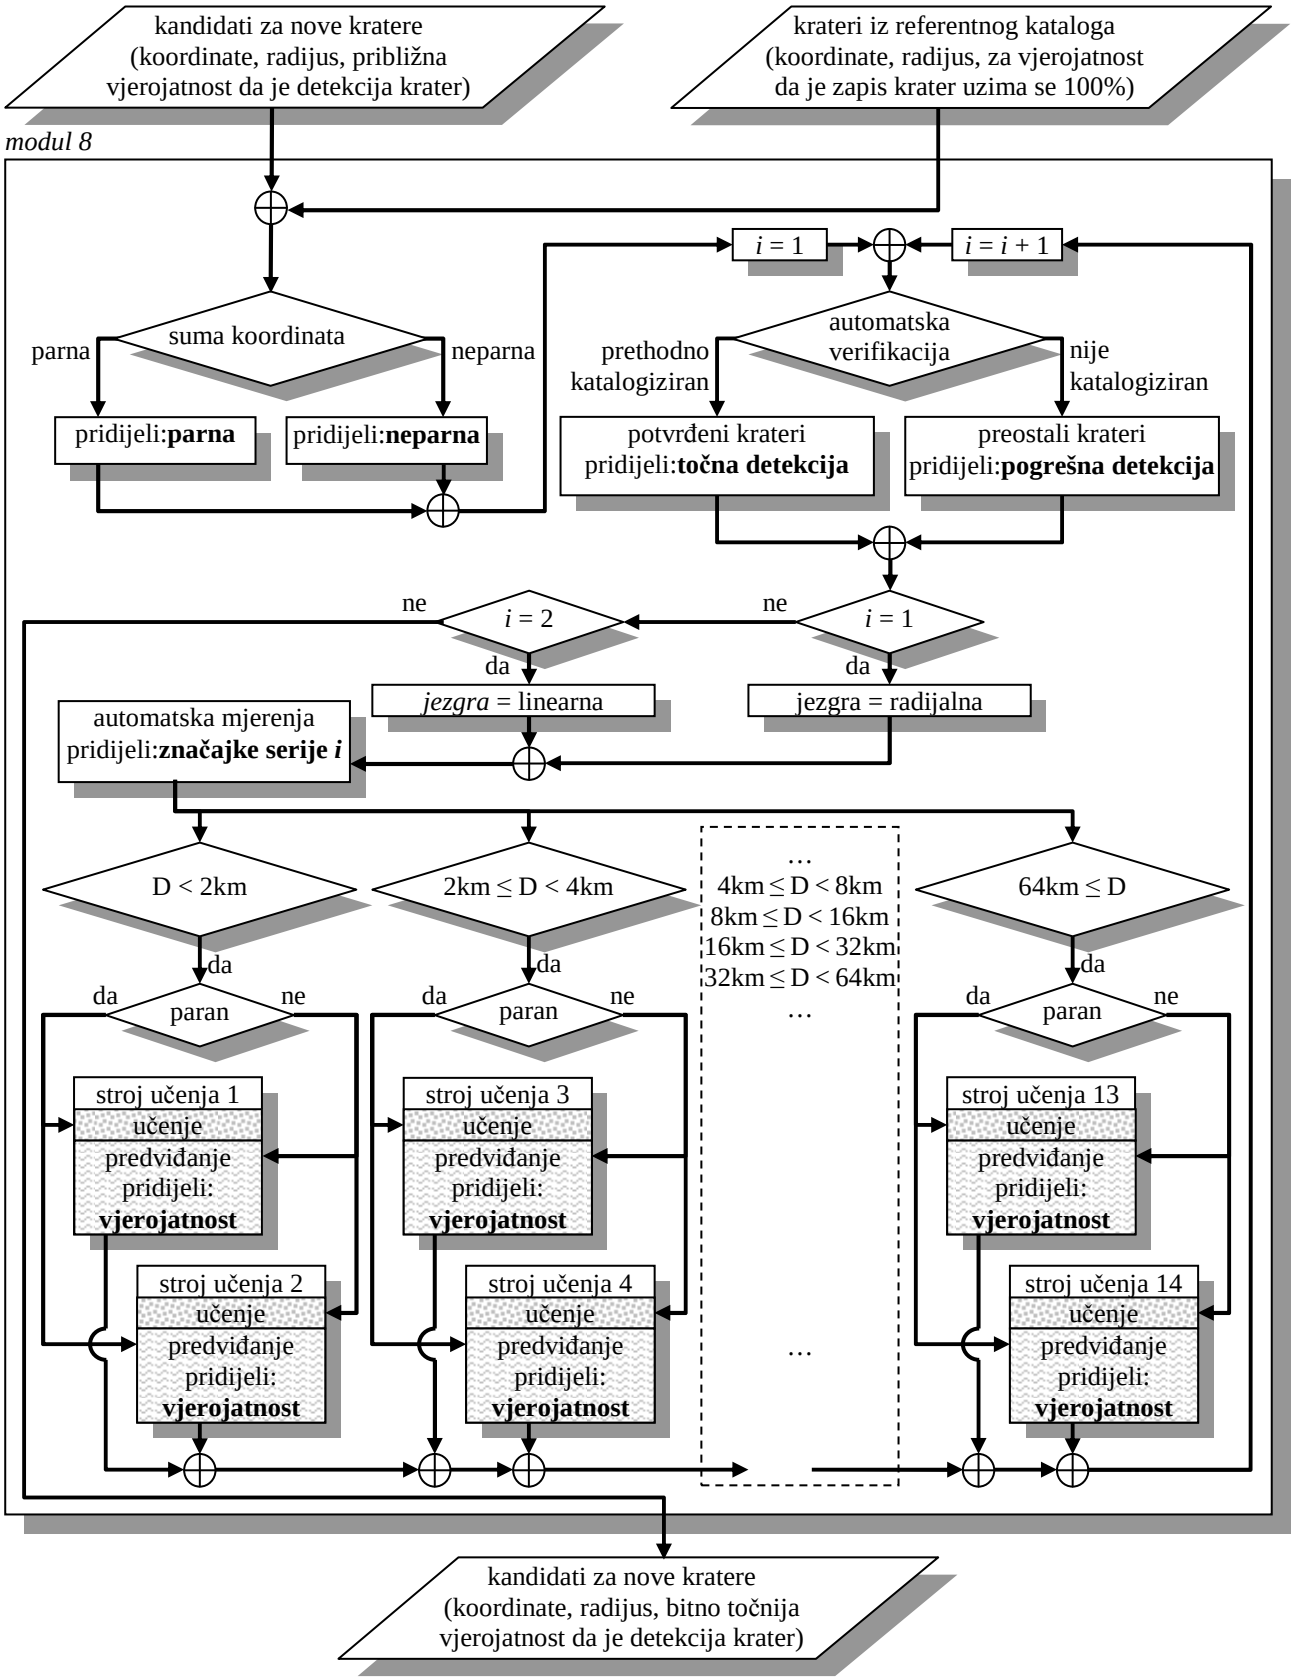
oznaka značajke:	**serija:**	**opis značajki (u zagradi je potpoglavlje definicije):**
longitude	1, 2	geografska dužina centra kratera
latitude	1, 2	geografska širina centra kratera
diameter	1, 2	dijametar kratera
probability_org	1, 2	izvorna procjena vjerojatnosti da je detekcija krater
depth_diameter	1, 2	omjer dubine i dijametra kratera (4.5.2)
area1	1, 2	cirkularnost kratera, a_1 (4.5.3)
area2	1, 2	cirkularnost kratera, a_2 (4.5.3)
area3	1, 2	rub kratera, a_3 (4.5.5)
area4	1, 2	rub kratera, a_4 (4.5.5)
area5	1, 2	centralno uzvišenje kratera, a_5 (4.5.6)
area6	1, 2	centralno uzvišenje kratera, a_6 (4.5.6)
circularity_probability	1, 2	vjerojatnost pridružena cirkularnosti kratera, p_c (4.5.3)
rim_probability	1, 2	vjerojatnost pridružena rubu kratera, p_{cr} (4.5.5)
central_peak_probability	1, 2	vjerojatnost pridružena centralnom uzvišenju, p_{cp} (4.5.6)
probability_recalculated	1, 2	ponovno izračunata vjerojatnost da je detekcija krater
ellipse_eccentricity	2	ekscentričnost elipse koja krater aproksimira bolje od kružnice
ellipse_tilt	2	nagib elipse koja krater aproksimira bolje od kružnice
profiles_data [2D]	2	profil kratera, odnosno njegova prezentacija u 2 dimenzije
raw_data [3D]	-	puni oblik kratera, odnosno njegova prezentacija u 3 dimenzije

6.3.5. Metoda strojnog učenja temeljena na stroju s potpornim vektorima

U ovome radu, koristio se stroj s potpornim vektorima dostupan u obliku biblioteke u C++-u, a što je i jezik u kojem je napisan CDA ovoga rada (kako temeljne verzije, tako i verzija temeljenih na interpolaciji i strojnom učenju). Koristile su se biblioteke koje je napravio Lin (2010), i to verzija 2.9 biblioteke LIBSVM (*A Library for Support Vector Machines*) i verzija 1.51 biblioteke LIBLINEAR (*A Library for Large Linear Classification*). Slika 36 prikazuje metodu strojnog učenja strojem s potpornim vektorima (modul 8).

Ulazni podaci metode su: (1) izlazni podaci iz prethodnog dijela CDA-a, koji sadrže listu kratera gdje su svakom pridijeljene koordinate, dijametar i početna vjerojatnost da je detekcija zaista krater; i (2) referentni katalog. Izlaz su lista kratera, gdje je svakom određena nova vjerojatnost da je detekcija zaista krater, dok se ostale značajke ne mijenjaju. Klasifikacija se može koristiti i tako da se izlaz automatski podijeli na kratere i pogrešne detekcije. Prvi kriterij može biti je li pridijeljena vjerojatnost veća ili manja od 50%. Drugi kriterij može biti i analiza odziva te maksimum *Q* krivulje, što će kasnije u ovome radu biti opisano. Treći kriterij može biti uzimanje one vrijednosti za prag vjerojatnosti koja je potrebna kako bi imali isti broj točnih detekcija, kako bi se pokazalo smanjenje broja pogrešnih detekcija.

Kako je u nastavku potpoglavlja detaljnije opisano, samo strojno učenje i predviđanje odvija se u dva ciklusa. U svakom od ciklusa, od svih značajka koje su pridijeljene svakom krateru, jedina koja se mijenja je pridijeljena vjerojatnost da je detektiran objekt krater. Na taj način se u svakom od ciklusa pridijeljena vjerojatnost korigira odnosno točnije određuje.



Slika 36. Dijagram toka modula za učenje strojem s potpornim vektorima.

Priprema podataka strojnog učenja sastoji se u analizi kandidata za kratere korištenjem referentnog kataloga, kako bi se isti mogli podijeliti na točne i pogrešne detekcije.

Dodatno je potrebno osigurati da isti klasifikatori iste primjere ne koriste i za učenje i za predviđanje, kako je opisano u potpoglavlju 6.3.3: (1) za svaki kandidat za krater računa se parnost

zbroja *x* i *y* koordinata; (2) na temelju rezultata krater se klasificiraju u jedan od dva razreda (*parni* i *neparni*). Tako se krateri klasificirani u razred *parni* koriste za učenje onih strojeva s potpornim vektorima koji se koriste za predikcije kratera klasificiranih u razred *neparni*, i obrnuto.

Iz ranijih razmatranja poznato je da oblik kratera ovisi o njegovoj veličini, no ujedno da i granični dijametar kratera kod kojeg se oblik velikih počinje razlikovati od malih nije isti za različita planetarna tijela. S druge strane, prijelaz s oblika malih kratera na oblik velikih kratera uvijek se odvija u području dijametara od 2 do 64 km. Stoga je kratere dodatno potrebno klasificirati u jedan od razreda ovisno o veličini dijametra, kako bi se strojno učenje prilagodilo obliku kratera koji je karakterističan za kratere određene veličine dijametra. Sveukupno postoji 7 takvih razreda: (1) krateri manji od 2 km, koji u principu na svim lunarnim i planetarnim tijelima imaju oblik karakterističan za male kratere; (2) krateri veći od 64 km, koji u principu na svim lunarnim i planetarnim tijelima imaju oblik karakterističan za velike i vrlo velike kratere; (3) dodatnih 5 razreda kratera na prijelazu iz malih u velike, gdje se unutar svakog od tih razreda mogu nalaziti krateri koji su najviše dva puta veći od najmanjih kratera unutar istog razreda. Na ovaj način osigurala se struktura koja je dovoljno robusna za kandidate za kratere Marsa i Mjeseca, a time i vrlo izgledno dovoljno robusna i za kratere ostalih lunarnih i planetarnih tijela.

S obzirom na to da imamo 7 razreda na temelju različitih područja veličine kratera, te 2 razreda na temelju parnosti koordinata centra (razredi *parni* i *neparni*), jezgra za učenje sastoji se od 14 strojeva s potpornim vektorima. Svaki od 7 parova zadužen je za određeno područje dijametara, gdje jedan stroj s potpornim vektorima uči iz *parnih* kandidata za kratere, a pridijeljene vjerojatnosti korigira kod *neparnih*, a drugi iz *neparnih* uči, dok pridijeljene vjerojatnosti korigira kod *parnih*.

Samo strojno učenje i predviđanje odvija se u dva ciklusa. U prvom ciklusu koriste se strojevi s potpornim vektorima s radijalnom jezgrom, s obzirom na to da je iz eksperimentalnih rezultata proizašlo da su rezultati bolji nego za linearne jezgre. No u tom slučaju podatke kao što su 2D-profil i 3D-oblik kratera nije praktično koristiti, jer time korišteni stroj s potpornim vektorima ne može odraditi potrebno u nekom prihvatljivom vremenu, koristeći raspoložive računalne resurse. U prvom ciklusu ne koriste se niti parametri elipse, jer su eksperimentalni rezultati u tom slučaju pokazali da su rezultati nešto lošiji nego kada se ne koriste. No u drugom ciklusu se koriste i parametri elipse, jer u tom su slučaju rezultati bolji ako se i ti parametri koriste. U drugom slučaju, kada se koristi linearna klasifikacija koja je posebno optimizirana da može obraditi vrlo velike količine podataka, koriste se i 2D-profili. Eksperimentiralo se i s 3D-oblikom kratera, no to nije dovelo do značajno boljih rezultata, dok je znatno usporilo obradu, vrlo vjerojatno zato što je broj značajki u tom slučaju prevelik da linearni klasifikator može kroz optimizaciju to iskoristiti.

Time se osiguralo i korištenje strojeva s potpornim vektorima s radijalnom jezgrom, korištenjem manjeg broja značajki, dok se s linearnom klasifikacijom mogu obraditi i preostale značajke koje sadrže i cjelokupne topografske 2D-profile kandidata za kratere.

6.3.6. Integracija rezultata strojnog učenja

Integracija rezultata strojnog učenja sastoji se u učitavanju rezultata strojnog učenja. Na temelju toga se mijenjaju pridijeljene vjerojatnosti da je detektirani kandidat za kratere zaista krater. Ostali parametri, kao što su koordinate i dijametar, pritom se ne mijenjaju. Time se ponovo dobiva lista koja sadrži iste kratere, no sada s pridijeljenim drugim vjerojatnostima s obzirom na to koji objekti jesu, a koji nisu krateri, a gdje su nove pridijeljene vjerojatnosti značajno bolje procijenjene.

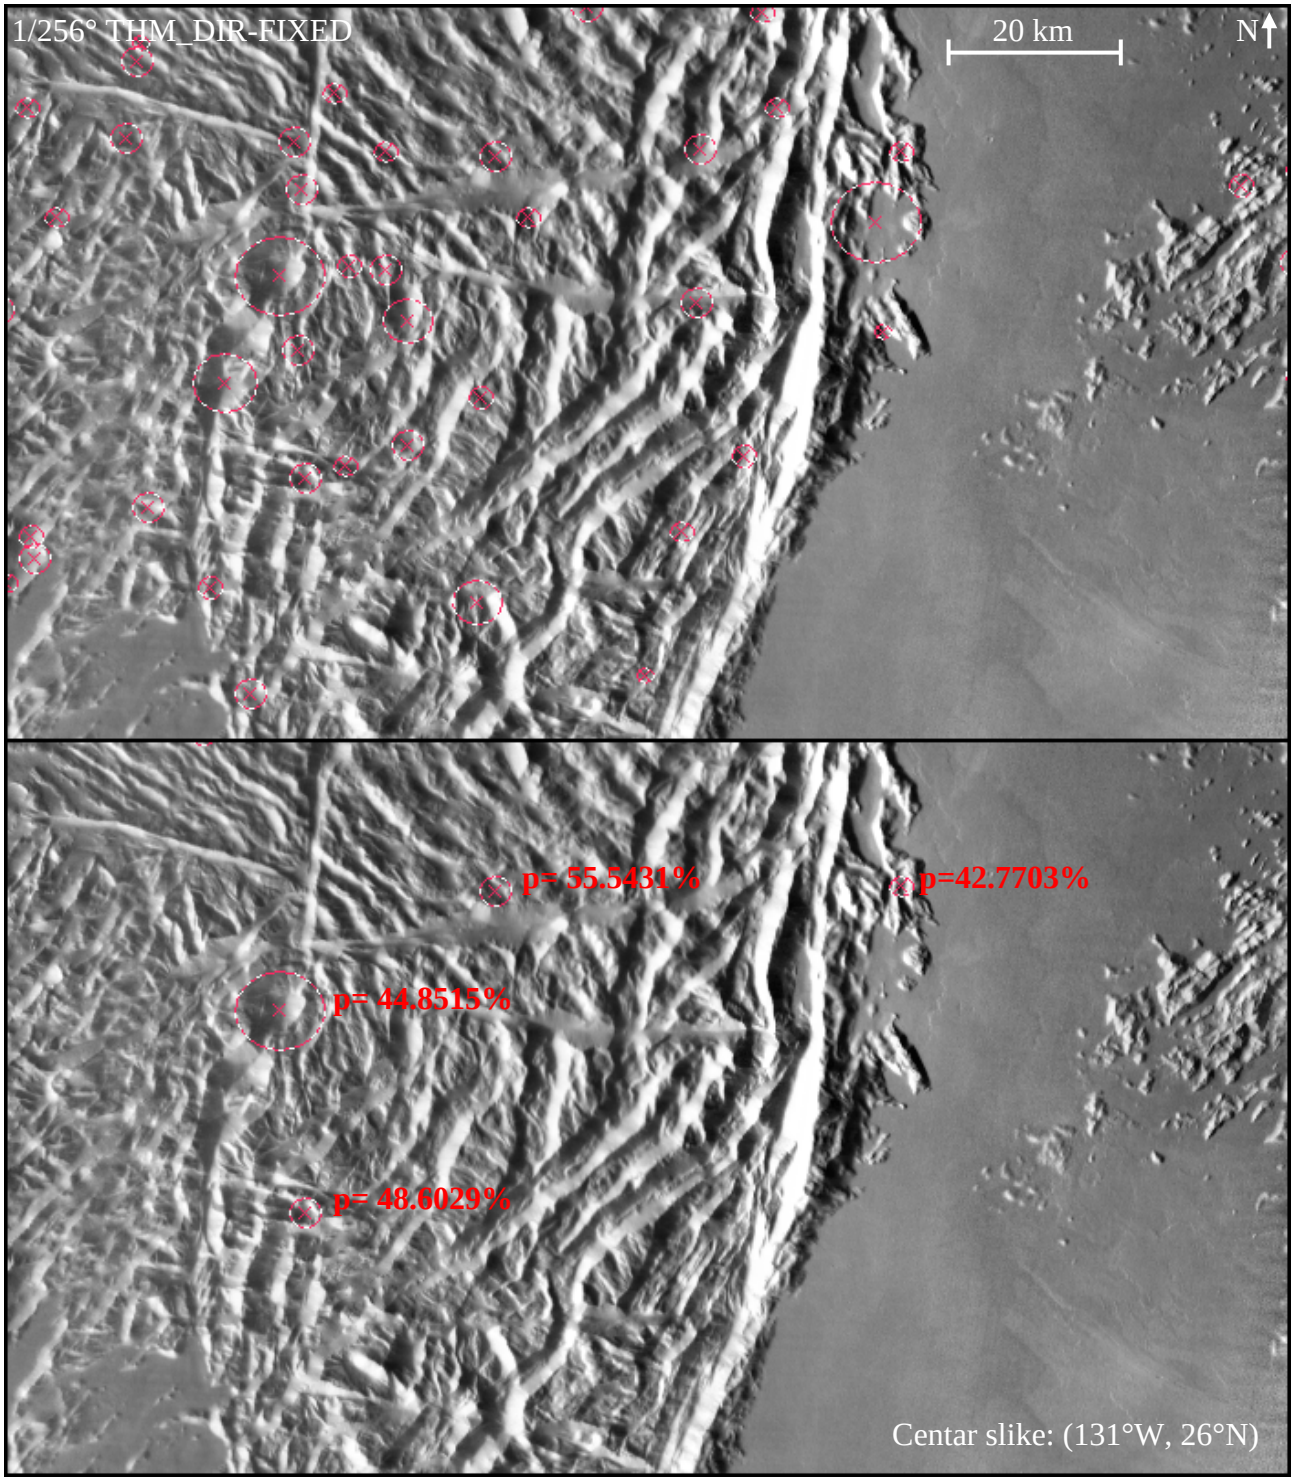
Korisnik, kao i kod izlaza temeljnog CDA-a te CDA-a zasnovanog na interpolaciji, može koristiti različite kriterije kojima bira prag vjerojatnosti do kojeg će se koristiti CDA rezultati. O tome ovisi broj pogrešnih detekcija koje dolaze za dani broj točnih detekcija.

Pridijeljene vjerojatnosti koje su određivale prethodne dvije verzije CDA-a su bile samo međusobno usporedive, gdje veći broj znači da je veća vjerojatnost da je detektiran objekt krater. Stroj s potpornim vektorima kandidatima za kratere pridjeljuje vrijednosti vjerojatnosti u području od 0 do 1, koje predstavljaju vjerojatnosti od 0% do 100% da je detektiran objekt krater. U tom smislu, ako je rezultat strojnog učenja pridijeljena vjerojatnost koja je manja od 50%, to znači da je vjerojatnije da detektiran objekt nije krater, a ako je veća od 50%, da je vjerojatnije da je upravo krater, a ne neki drugi geološki objekt koji je po izgledu samo sličan krateru. Time se kod izlaza CDA-a koji je temeljen na stroju s potpornim vektorima i prag od 50% može također koristiti kao jedan od načina da se kandidati za kratere klasificiraju u pogrešne, odnosno točne detekcije.

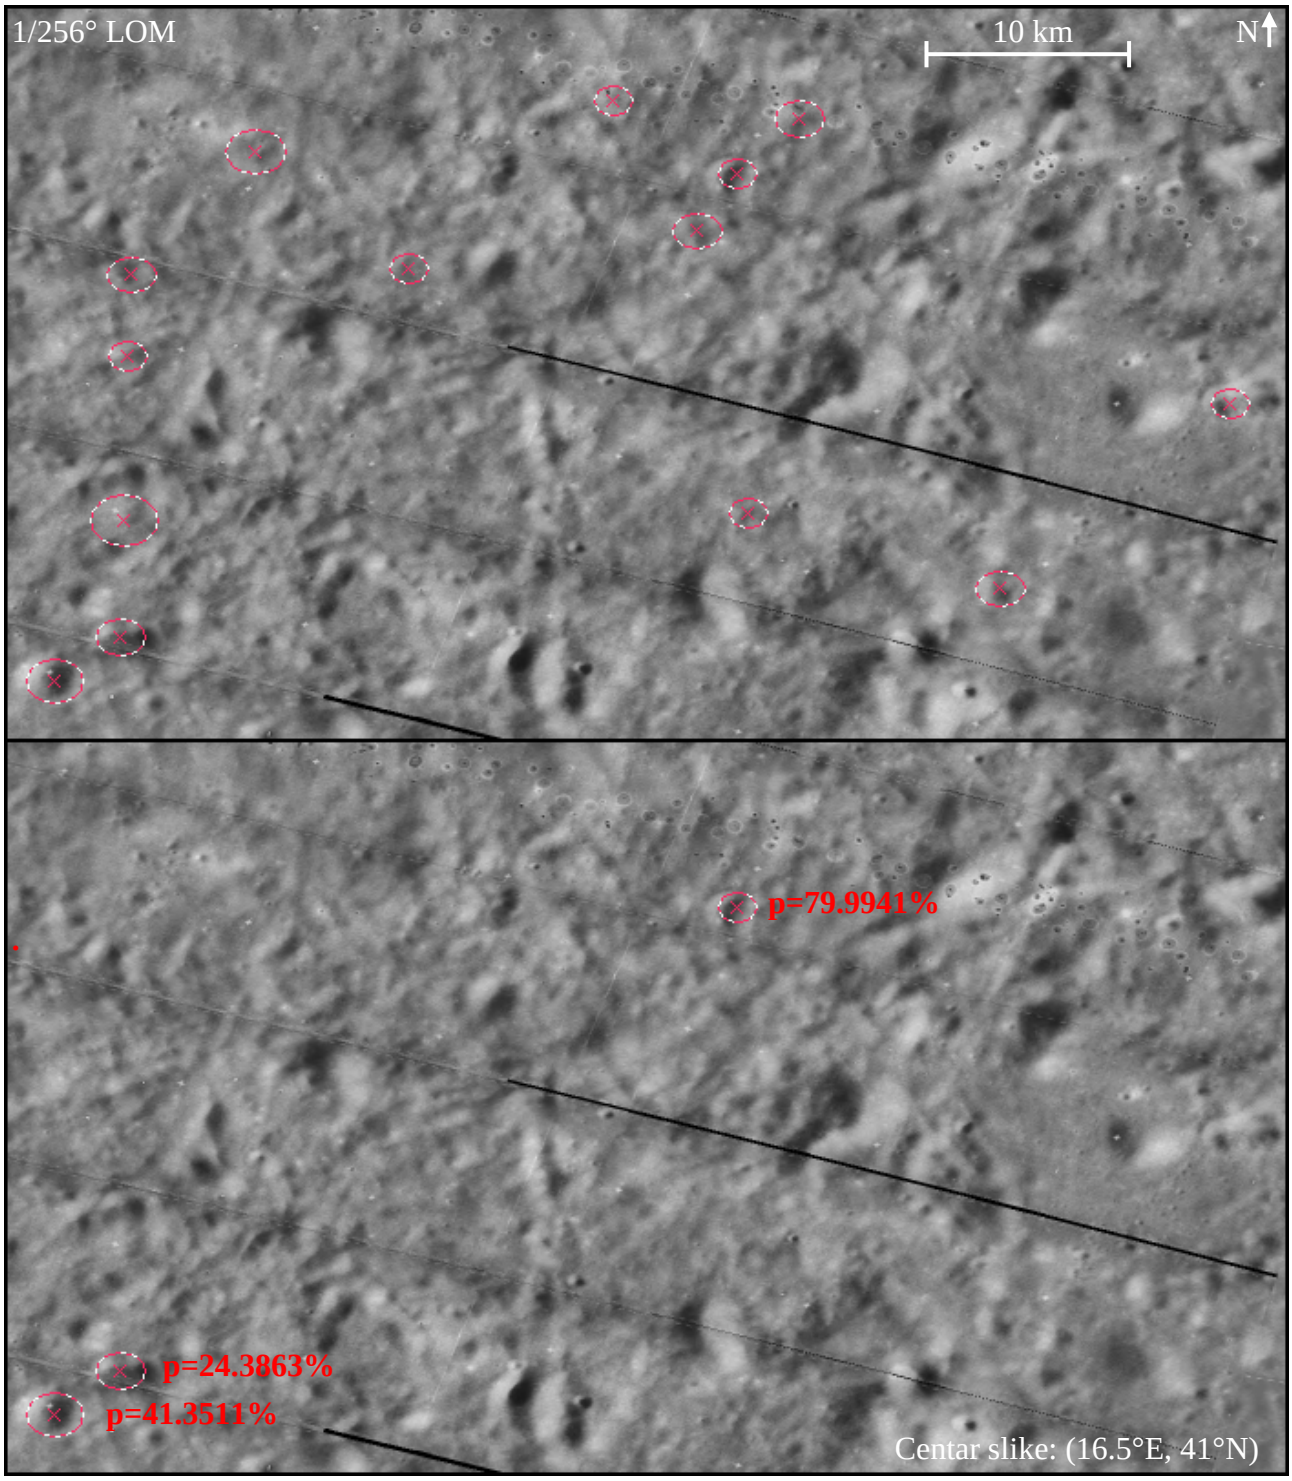
S pristupom strojnom učenju koji je prilagođen prirodi kratera, kako je prikazano na prethodnoj slici, proširivanje predložene metode sa svrhom korištenja i drugih metoda strojnog učenja ne bi smjelo biti previše složeno. Jedan od razloga je i pristup koji uključuje: (1) eksportiranje svih atributa u datoteke; (2) pozivanje zasebnog programa koji izvršava strojno učenje i klasifikaciju; te (3) integriranje rezultata. Ovim modularnim pristupom, što se tiče samog CDA-a, klasifikacija strojnim učenjem u principu se može napraviti bilo kojim klasifikatorom. Međutim, bi li isti uspio obraditi globalne podatke i dati bolje rezultate od stroja s potpornim vektorima, pitanje je na koje je teško odgovoriti bez eksperimentalne provjere.

6.4. Primjeri za topografske slike Marsa i Mjeseca

Razlike u detekciji kratera između CDA-a koji je zasnovan na interpolaciji, a koji daje bolje rezultate nego temeljni CDA, i CDA-a koji uz interpolaciju koristi i strojno učenje, prikazane su na sljedeće dvije topografske slike Marsa i Mjeseca. Detaljno vrednovanje metode i usporedba s radom drugih dani su u poglavlju 9. Za prag vjerojatnosti koristi se vrijednost za koju je globalno isti broj točnih detekcija kao i bez strojnog učenja, kako bi se vidjelo smanjenje broja pogrešnih detekcija.



Slika 37. Detekcije problematičnog područja na Marsu prije i nakon primjene strojnog učenja.



Slika 38. Detekcije problematičnog područja na Mjesecu prije i nakon primjene strojnog učenja.

Kako se iz obje slike može primijetiti, broj pogrešnih detekcija značajno je manji nakon primjene strojnog učenja, koje uzima u obzir i geološki kontekst te na taj način uspješno dodatno potiskuje broj pogrešnih detekcija na problematičnim područjima. Slika 37 prikazuje dio površine Marsa, gdje je nakon primjene strojnog učenja preostalo svega četiri pogrešne detekcije. Od toga je trima CDA pridijelio vjerojatnost manju od 50%, pa time preostaje svega jedna gdje je CDA dao pogrešnu procjenu. Slika 38 prikazuje sličan primjer za Mjesec. Ovdje su preostale samo tri detekcije, od kojih također samo jedna ima pridijeljenu vjerojatnost veću od 50%, gdje se vjerojatno radi o krateru kojem je ostao sačuvan još samo jedan dio ruba.

6.5. Zaključak

Rezultati postignuti metodom za detekciju kratera koja uz sve prethodno navedeno koristi i strojno učenje su (Salamunićcar i Lončarić, 2010d): (1) CDA je pokazao još bolje karakteristike detekcije od temeljne i interpolacijske metode te u cjelokupnom području od Stepinskovog i Urbachovog CDA-a (2008), kako će biti prikazano u potpoglavlju 9.3.3, pri čemu je pokazano da se strojnim učenjem mogu dodatno poboljšati svojstva detekcije; (2) uspio se smanjiti broj pogrešnih detekcija, dok su ostala dobra svojstva sačuvana, što je i bio osnovni cilj ovog dijela rada na novoj metodi za detekciju kratera iz topografskih slika.

Detekcija malih kratera, kao i erodiranih kratera te kratera koji su dijelom obrisani, bolja je nego kod detekcije kratera temeljnom ili interpolacijskom metodom. Zahvaljujući svojstvima postignutima metodom opisanom u ovom poglavlju, porast broja pogrešnih detekcija još je manji nego u prethodnim dvjema verzijama. Poboljšanje je vidljivo u svim područjima rada definiranim različitim pragovima vjerojatnosti, pa i u modu gdje je CDA najosjetljiviji. Kao rezultat, za katalogizaciju istog broja točnih detekcija potrebno je ručno obraditi značajno manje kandidata za kratere, s obzirom na to da je udio pogrešnih detekcija značajno manji.

Ovime se osiguralo ne samo da se gotovo svi krateri dostupni na topografskim slikama Marsa (MOLA podaci) i Mjeseca (LOLA podaci) mogu detektirati metodom predloženom ovim poglavljem, nego i značajno manji broj pogrešnih detekcija od broja točnih, kako će više biti pokazano u sljedećim poglavljima. To ujedno znatno olakšava daljnju obradu i katalogizaciju kandidata za kratere, time što se u odnosu na prethodne dvije verzije dodatno smanjuje vrijeme koje je potrebno za naknadnu ručnu obradu kratera, pri kojoj se pogrešne detekcije brišu, a točne dodaju u katalog nakon korigiranja njihovih koordinata i dijametra po potrebi. To je rezultat manjeg broja pogrešnih detekcija za isti broj točnih što vodi do manjeg ukupnog broja kratera koji se ručno provjeravaju. Ručnim provjeravanjem osigurava se što točniji rezultirajući katalog.

7. REFERENTNI KATALOG ZA VREDNOVANJE ALGORITAMA ZA DETEKCIJU KRATERA

U ovom poglavlju opisuje se referentni katalog za vrednovanje metoda za detekciju kratera, kao i metode koje su pritom razvijene, kroz sljedeća potpoglavlja:

- 7.1. Uvod;
- 7.2. Problematika prethodnih kataloga i potreba za integracijom;
- 7.3. Metoda za integraciju kratera iz različitih kataloga;
- 7.4. Metoda za provjeru konzistentnosti kataloga;
- 7.5. Rezultirajući katalog za vrednovanje s 57 633 kratera;
- 7.6. Zaključak.

U potpoglavlju 7.1. daje se uvod u problematiku i opisuje motivacija za novim referentnim katalogom za vrednovanje CDA-ova. U potpoglavlju 7.2. opisuje se problematika prethodnih kataloga te obrazlaže potreba za integracijom, kako bi se osigurao novi referentni katalog za vrednovanje CDA-ova. Pritom su razvijene metode za integraciju kratera iz različitih kataloga te za provjeru konzistentnosti kataloga, koje se dalje opisuju u potpoglavljima 7.3. i 7.4. Rezultirajući katalog za vrednovanje CDA-ova opisan je u potpoglavlju 7.5. U potpoglavlju 7.6. naveden je zaključak o postignutom s novim katalogom i razvijenim metodama.

7.1. Uvod

Okolina za razvoj algoritama za detekciju kratera, opisana u poglavlju 3, uspješno se koristila tijekom razvoja temeljne metode za detekciju kratera, metode temeljene na interpolaciji te metode dodatno temeljene na strojnom učenju.

Tijekom rada na CDA-u, MOLA podaci su uz horizontalnu rezoluciju 1/64° postali dostupni i u horizontalnoj rezoluciji 1/128°. To je bila motivacija za korištenje topografskih podataka i u višoj rezoluciji, kako bi se moglo detektirati i katalogizirati što više prethodno nekatalogiziranih kratera.

Daljnjim razvojem CDA-a postalo je moguće da isti detektira i kratere koji su veliki svega 2 slikovna elementa u radijusu. Time se, uz podatke u višoj rezoluciji, postiglo i znatno povećanje broja kratera koji se mogu detektirati. Neki od tih kratera toliko su mali da niti osoba koja ručno provjerava sve kandidate za kratere više ne može biti sigurna jesu li točne ili pogrešne detekcije, posebno stoga što MOLA podaci nisu potpuni u horizontalnoj rezoluciji 1/128°. Mjerenja visine su dostupna samo po putanjama kojima je prošao satelit. Zbog toga mnoge vrijednosti MOLA podataka u globalnoj topografskoj slici horizontalne rezolucije 1/128° imaju interpolirane vrijednosti, a ne stvarna mjerenja, stoga je bilo potrebno pripremiti i optičke slike u horizontalnoj rezoluciji 1/256° za korištenje prilikom ručne obrade pronađenih kandidata za kratere.

Kao rezultat navedenog, ukupan broj kratera koji se može detektirati CDA-om znatno je prelazio broj kratera iz MA17582GT kataloga. Stoga je bilo potrebno proširiti taj katalog (Salamunićcar i Lončarić, 2007a) kako bi se bolje moglo vrednovati razvijene metode za detekciju kratera.

Dodatni razlog za proširenje je i katalog MA75919T, rezultat Stepinskovog i Urbachovog (2008) CDA-a, a koji većinom sadrži točne detekcije. S obzirom na to da se svi oni krateri koje CDA pronađe, a ne nalaze se u referentnom katalogu prilikom vrednovanja, tretiraju kao pogrešne detekcije, proizlazi da se MA17582GT treba proširiti radi što boljeg vrednovanja CDA-a koji je rezultirao s MA75919T katalogom. Usporedba dva CDA-a može se izvršiti i katalogom MA17582GT, s obzirom na to da se i tada dva različita CDA-a nepristrano uspoređuju prilikom vrednovanja, no svakako je time usporedba znatno ograničena.

Izrada kataloga međutim nije trivijalan zadatak. Jednostavno označiti ručno sve kratere koje korisnik želi imati u katalogu svakako je lakši postupak izrade kataloga, ali ne i najbolji, jer postupak kojim osoba mora desetak tisuća puta ponoviti jednostavne operacije, podložan je pogreškama. Zbog navedenog, u MA17582GT katalogizirali su se samo oni krateri koji su se nalazili i u katalogu MA42279B i u katalogu MA19308R i u proširenoj verziji kataloga MA22044N iz prethodnog rada. Upravo tim pristupom koji je osigurao da se u katalogu nalaze zaista samo krateri, i to svaki samo po jednom, bio je i ograničen ukupan broj kratera koji se mogao katalogizirati u MA17582GT. Trebalo je zato promijeniti pristup registracije, kako bi se sve točne detekcije iz prethodnih kataloga mogle iskoristiti, a u isto vrijeme da se u novi referentni katalog ne registriraju i pogrešne ili duple detekcije iz prethodnih kataloga.

Sljedeći važni čimbenik u vrednovanju CDA-ova je objektivnost, a objektivnost ne može biti osigurana ako sastavnice vrednovanja nisu osigurane kroz objektivni pristup. Stoga je odlučeno da referentni katalog za vrednovanje CDA-ova sadrži samo one kratere koje su prethodno fizičke osobe (a ne računalni algoritmi odnosno CDA-ovi) pronašli i katalogizirali. Time se osigurava objektivnost usporedbe dva različita CDA-a.

U ovom će se poglavlju opisati kako je u sklopu ovih razmatranja pripremljen MA57633GT katalog, s ciljem što veće objektivnosti daljnjeg vrednovanja CDA-ova.

7.2. Problematika prethodnih kataloga i potreba za integracijom

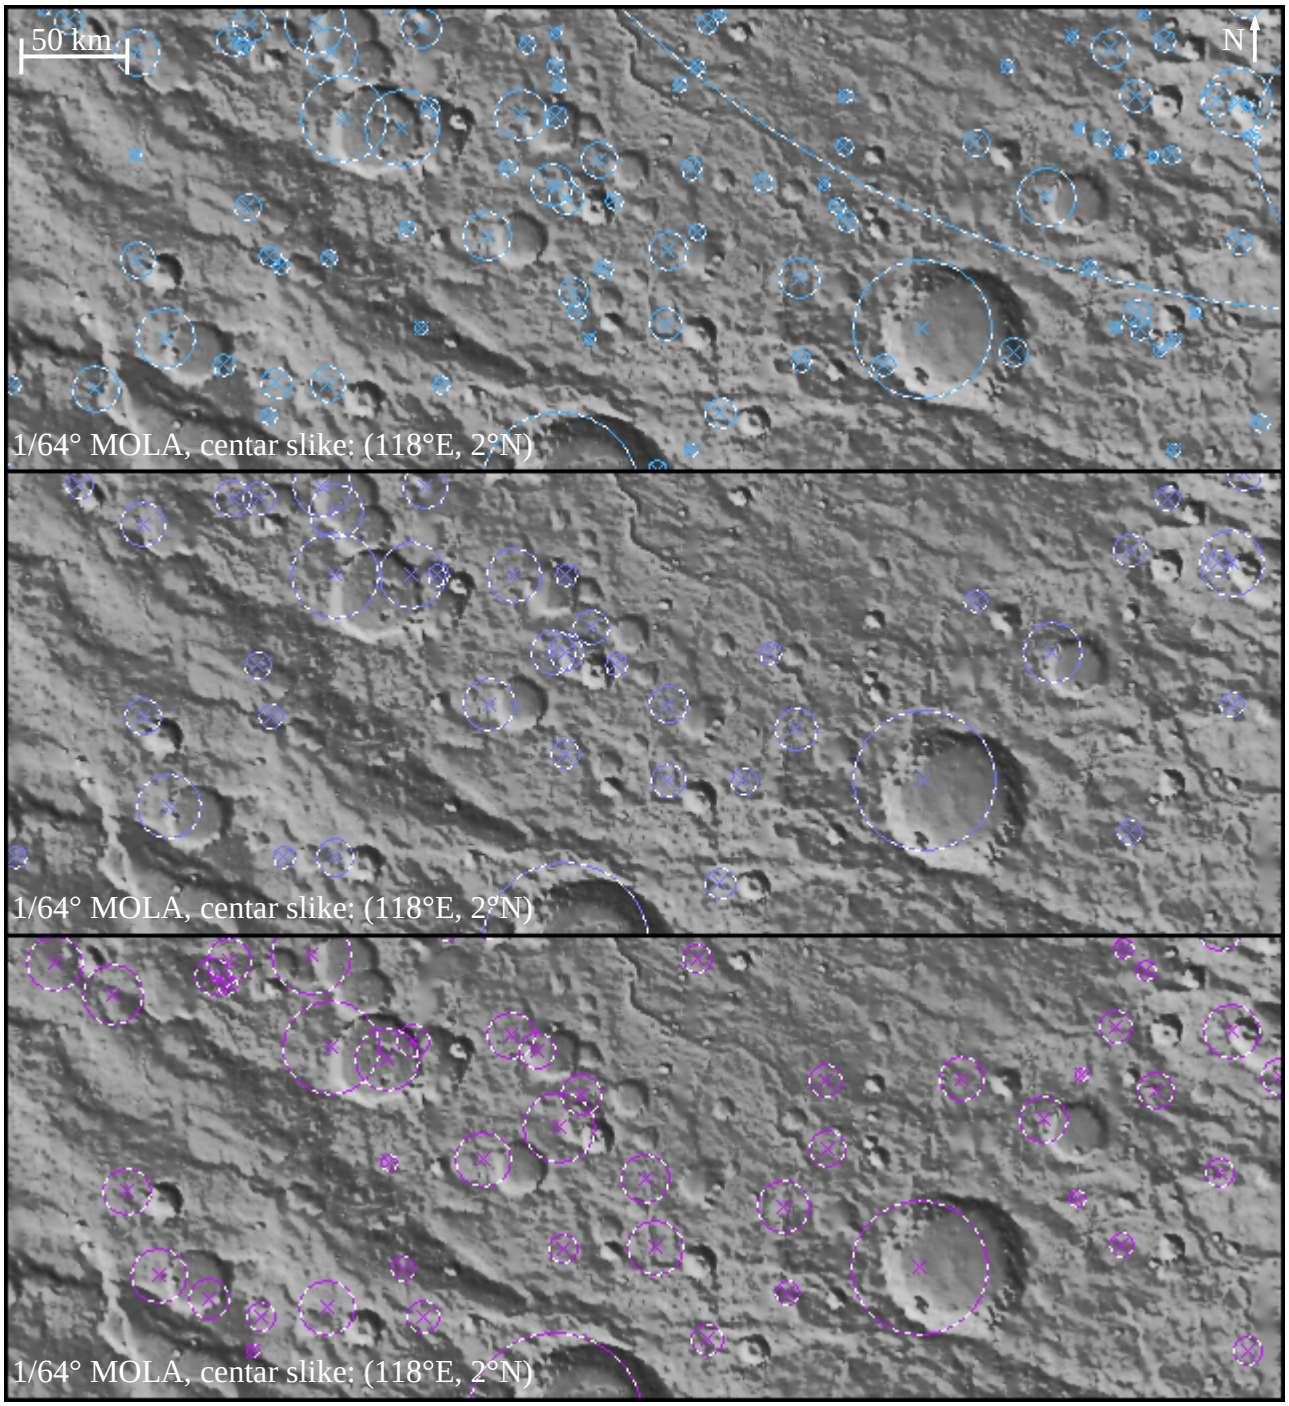
Postoji nekoliko kataloga kratera Marsa (Salamunićcar i Lončarić, 2008e) i svi su osim MA75919T napravljeni prije početka rada na katalogu MA57633GT te katalogu MA17582GT koji mu je prethodio:

- MA42279B (Barlow katalog *Catalog of large Martian impact craters*), koji je prije izrade MA57633GT bio najpotpuniji globalni katalog, sadrži kratere kojima je dijametar veći od 5 km;
- MA19308R (Rodionov katalog *Morphological catalogue of the craters of Mars*), također globalni katalog, sadrži kratere kojima je dijametar veći od 10 km;
- MA2268C katalog (Boyce et al., 2005) sadrži kratere samo za odabrana područja pa se ne može smatrati globalnim katalogom, no sadrži i kružne depresije koje se ne vide na optičkim slikama, nego samo na topografskim, te zato upotpunjuje prethodna dva kataloga;
- MA24380K (Kuzminov katalog) sadrži u principu samo male kratere pa se zato ne može smatrati globalnim katalogom, no sadrži desetke tisuća malih kratera od kojih se mnogi ne nalaze u prethodnim katalozima, te ih također na taj način nadopunjuje;
- MA9496N (Salamunićcar, 2004) i MA22044N (Salamunićcar, 2009) katalozi (koautor kataloga je Z. Nežić) korišteni su u prethodnom radu za statističku analizu kratera i oba kataloga su globalni (MA22044N je proširenje prethodnog kataloga MA9496N);
- MA75919T katalog u potpunosti je rezultat Stepinskovog i Urbachovog (2008) CDA-a, isti se nije koristio prilikom razvoja MA57633GT kataloga, jer tada još nije bio dostupan, no kasnije je revidiran i integriran u rezultirajući katalog ovoga rada.

Osnovni problem svih prethodnih kataloga (osim MA75919T) je neporavnatost kratera s MOLA podacima, što je za kataloge MA42279B i MA19308R pokazano u poglavlju 3. Slika 39 prikazuje da zbog neporavnatosti katalozi nisu iskoristivi u izvornom obliku za vrednovanje CDA-ova. Detekcije CDA-a i krateri neporavnatih kataloga ne mogu se naime automatskom procedurom uparivati kako bi se napravilo vrednovanje, a da se pritom izbjegnu brojna pogrešna uparivanja zbog neporavnatosti kratera. Optičke slike koje su korištene za izradu tih kataloga nisu ni same bile poravnate s MOLA podacima, pa onda niti krateri iz nastalih kataloga također nisu poravnati.

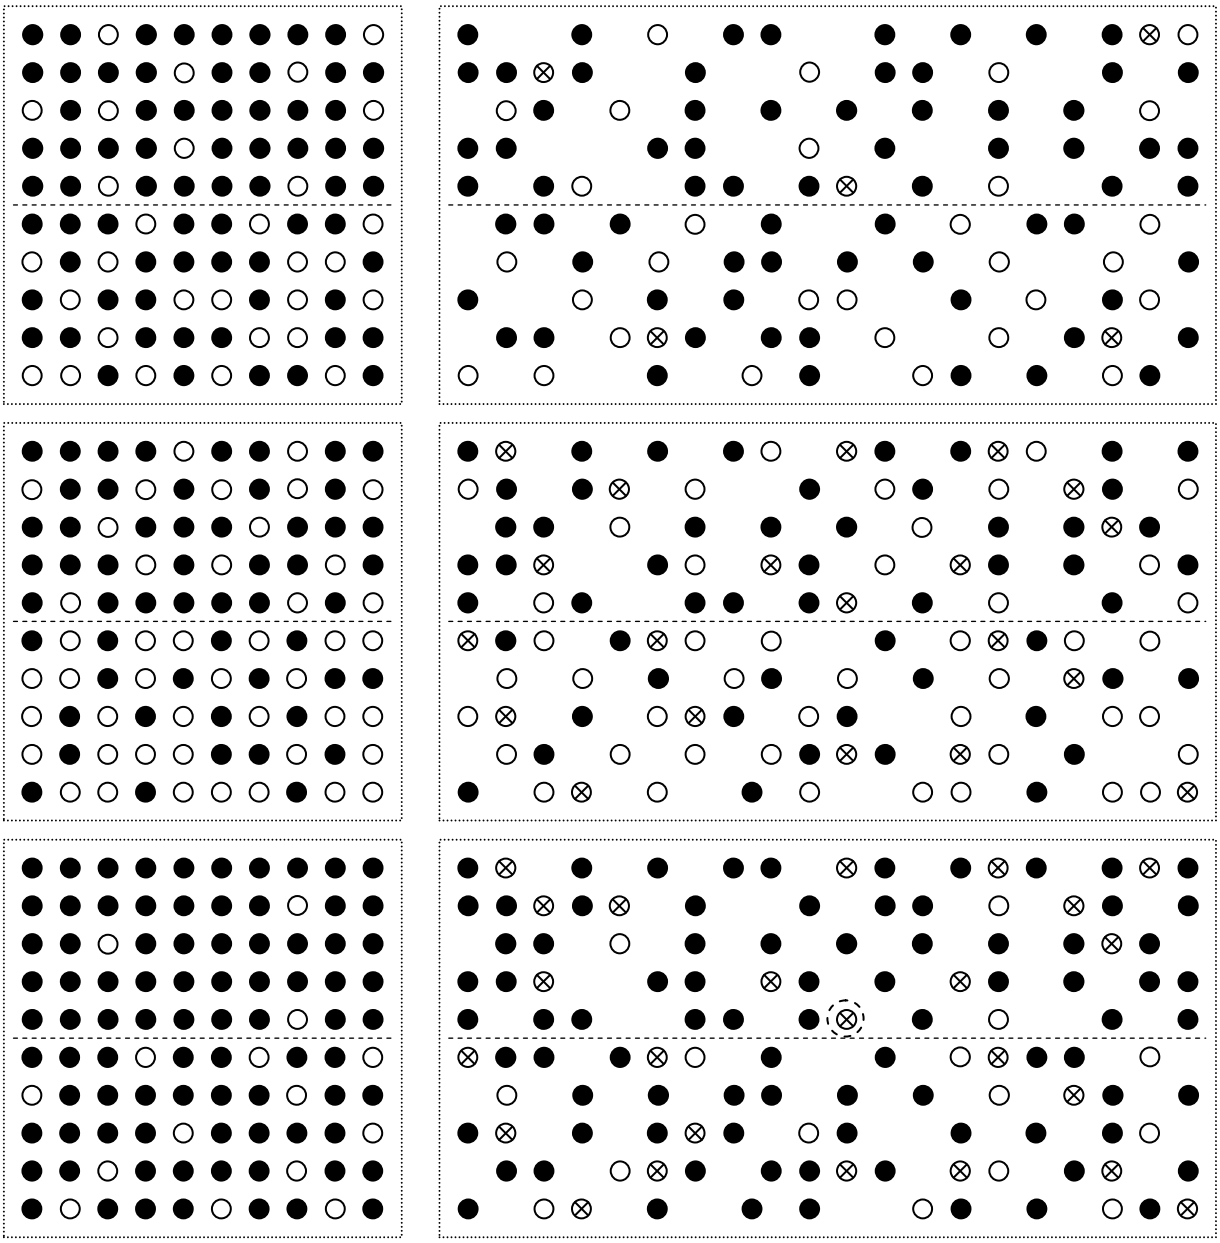
Dodatni problem je što se prilikom izrade tih kataloga nisu koristile (tada nisu niti postojale) metode za automatsku provjeru konzistentnosti kratera unutar kataloga. Tako ima primjera gdje je isti krater višestruko unesen u neki katalog (duplikat). Ovakvi unosi najvjerojatnije su nastali korištenjem brojnih slika različitih dijelova planeta, umjesto globalnog mozaika slika. Isti krater se tako mogao nalaziti na dvije ili više različitih slika koje se preklapaju, stoga su neki krateri višestruko uneseni u katalog. Kada višestruki unosi nemaju iste koordinate i dijametar, nije ih jednostavno ručno pronaći u katalogu. Osoba koja ručno označava kratera isto uvijek čini unutar određenih granica preciznosti, pa postoje odstupanja.

Analizom prethodnih kataloga, došlo se i do zapisa koji na površini ne odgovaraju vidljivom krateru. S obzirom na to da su u vrijeme nastanaka starijih kataloga bile dostupne, odnosno korištene samo optičke slike, isključuje se mogućnost njihove katalogizacije korištenjem nekih drugih podataka (topografija, radar, i slično). Kod nekih takvih slučajeva relativno blizu kratera iz kataloga postoji neoznačen krater jednake veličine, a gdje se koordinate razlikuju samo u jednoj od znamenaka iza decimalne točke. Pogreške su nastale prilikom ručnog unosa kataloga u računalo, što je inače podložno tipfelerima.



Slika 39. Prethodni katalozi MA42279B (gore), MA19308R (sredina) i MA22044N (dolje), koji nažalost nisu poravnati s MOLA podacima (slika pozadine). © 2008 Elsevier (Salamunićcar i Lončarić, 2008e).

Kada tipfeler promijeni neku od težinski važnijih znamenki u koordinatama ili dijametru kratera, tada ga više nije moguće jednostavno pronaći i ispraviti grešku, stoga su se takvi unosi mogli samo obrisati. U MA19308R katalogu primijećeno je da su katalogizirani i krateri vulkanskog porijekla (grotla vulkana). Oni ne pripadaju referentnom katalogu, pa su se takvi unosi također samo obrisali.



Legenda: ● - krater ispravno unesen u katalog (stvarni krater)
○ - krater koji nije unesen u katalog (propušten krater)
⊗ - nije krater, pogrešan unos u katalog (pogrešan krater)

Slika 40. Primjer gdje spajanje pojedinačnih kataloga koristeći jednostavne operatore (*I*, *ILI*) ne uzima u obzir i propuštene i pogrešne kratere. © 2008 Elsevier (Salamunićcar i Lončarić, 2008e).

Navedene kataloge potrebno je stoga odgovarajuće obraditi, kako bi se dobio zadovoljavajući referentni katalog za vrednovanje CDA-ova. Slika 40 prikazuje kako pritom nije optimalno koristiti logičke operatore kao što su *I* (dodaju se samo oni krateri koji se nalaze u više kataloga) i *ILI* (dodaje se krater ako se nalazi i u samo jednom katalogu). Ako se koristi logički operator *I*, problem je relativno mali broj kratera u rezultirajućem katalogu u odnosu na kataloge koji su se koristili, kao što je bio slučaj s prethodnim MA17582GT katalogom za evaluaciju. Analizom neregistriranih kratera utvrdilo se i postojanje onih krateri koji su u katalogu MA19308R navedeni kao krateri kojima je dijametar nešto veći od 10 km, a u katalogu MA42279B s dijametrom nešto manjim od 10 km, pa stoga nisu bili uzeti u obzir prilikom izrade MA17582GT kataloga. Obrada takvih kratera dovela je do kataloga MA18711GT (Salamunićcar i Lončarić, 2007d), no time se nažalost ukupan broj kratera nije znatno povećao. Ovaj problem se može riješiti korištenjem logičkog operatora *ILI*,

no tada se pogrešne detekcije u potpunosti prenose u rezultirajući katalog, u slučaju automatizirane obrade kataloga.

Katalog MA17582GT, odnosno MA18711GT, može se stoga dodatno značajno proširiti samo ako se registriraju i oni krateri koji se nalaze u samo jednom od prethodno dostupnih kataloga (Salamunićcar i Lončarić, 2008a). No postupak namjerno nije automatiziran, kako bi se i pogrešni unosi pronašli i obrisali. Dodatni razlog ručne obrade je i potreba registracije, kako s MOLA podacima, tako i s globalnim optičkim mozaicima: (1) 1/256° THEMIS-DIR (*THEMIS Day IR Global Mosaic*); (2) 1/256° MDIM (*Mars Global Digital Image Mosaic*); (3) 1/256° MOC (*Mars Orbiter Camera Wide Angle Atlas*).

7.3. Metoda za integraciju kratera iz različitih kataloga

Metoda za integraciju kratera iz različitih kataloga nadogradnja je na osnovnu metodu koja je prikazana i opisana u potpoglavlju 3.2. Slika 11 iz tog potpoglavlja prikazuje registraciju koja je zahtijevala postojanje kratera i u katalogu MA42279B i u katalogu MA19308R, dok se katalog MA22044N proširivao ako krater postoji i u MA42279B i u MA19308R. S obzirom na to da se sada trebaju registrirati i oni krateri koji postoje u MA42279B, a ne postoje u MA19308R, i obrnuto, kao i ako postoje samo u nekom od ostalih kataloga, metoda je u tom smislu dorađena.

Također je metoda dorađena kako bi se svaki krater uz registraciju s 1/128° MOLA podacima registrirao i s trima globalnima optičkim mozaicima, 1/256° THEMIS-DIR, 1/256° MDIM i 1/256° MOC. S obzirom na to da ti mozaici nisu međusobno poravnati, to znači da su uz koordinate kratera u koordinatnom sustavu MOLA topografske slike, potrebne i koordinate za svaki od optičkih mozaika. Odnosno, za svaki krater potrebno je zapisati iznos potrebnog pomaka u x i y smjeru pojedinih slika da bi bile poravnate na lokaciji njegovog središta.

Sama metoda za registraciju mora uzeti u obzir i moguće ljudske pogreške prilikom izrade prethodnih kataloga. Uz pogrešku koja je uzrokovana pomakom između različitih globalnih slika (kako topografskih tako i optičkih), moguća je i pogreška u određivanju koordinata i dijametra.

Uz sve prethodno nabrojano, metoda mora biti efikasna kako bi se moglo ručno registrirati preko 50 000 kratera s četiri različita globalna mozaika. To je za četiri globalne slike (jedna topografska i tri optičke) sveukupno preko 200 000 registracija koje je potrebno ručno odraditi.

Kako bi se sve navedeno uzelo u obzir, implementirana je metoda sa sljedećim koracima:

(1) učitava se XML datoteka s kraterima koji su već registrirani i koje je tek potrebno registrirati, kao i pripadni globalni optički mozaici, s tim da se za topografske podatke odmah učitava unaprijed pripremljena slika kako bi se dovoljno brzo prikazala na ekranu;

(2) korisnik bira hoće li preostale kandidate za kratere pregledavati od većih prema manjima, od sjevera prema jugu ili obrnuto, i slično;

(3) korisnik pokreće pripremu za registraciju kojom se automatski pronalazi prvi sljedeći kandidat za kratere te se svi pripadni globalni optički mozaici pomiču na lokaciju kandidata za krater, traži se najbliži neregistrirani krater u LLR prostoru korištenjem formule (1), računa se za koliko se slikovnih elemenata u smjeru dužine i širine slike moraju pomaknuti globalni mozaici na temelju informacije o najbližem registriranom krateru, i za toliko se pomiču te se korisniku prikazuje aktivni optički mozaik s kružnicom pridijeljenom kandidatu za krater;

(4) nakon prethodnog koraka u prikazanom dijelu slike može biti jedan ili više kandidat za kratere, korisnik mišem odabire onoga kojeg želi prvog registrirati, pri čemu kružnicu pridijeljenu kandidatu za krater briše i ponovo prikazuje kako bi mogao bolje vidjeti dio aktivnog globalnog mozaika gdje se nalazi kandidat za krater;

(5) ako korisnik smatra da se radi o pogrešnom unosu, briše kandidata za krater;

(6) u protivnom, ako smatra da se radi o točnom unosu, korisnik može pomaknuti krateru pridijeljenu kružnicu radi što bolje registracije sa slikom, a može i povećati ili smanjiti njezin radijus, a pritom može mijenjati i aktivni globalni mozaik koji se prikazuje;

(7) kad je korisnik zadovoljan poravnanjem kružnice i pozadinske slike, registrira krater, a pritom se, ako korisnik nije pogledao sve globalne mozaike, isti prikazuju kako bi korisnik ili nastavio s registracijom daljnjih kratera ili dodatno pomaknuo neke od ostalih globalnih mozaika radi što boljeg poklapanja s kružnicom pridijeljenom krateru koji se registrira; također se u ovom koraku generira ime novoregistriranog kratera koje u sebi sadrži i ime kataloga i identifikator unutar tog kataloga, kako bi za svaki krater znali koji od kataloga je njegov izvor;

(8) ako na slici ima još kratera, korisnik može nastaviti registraciju kroz ponavljanje koraka od (4) do (7);

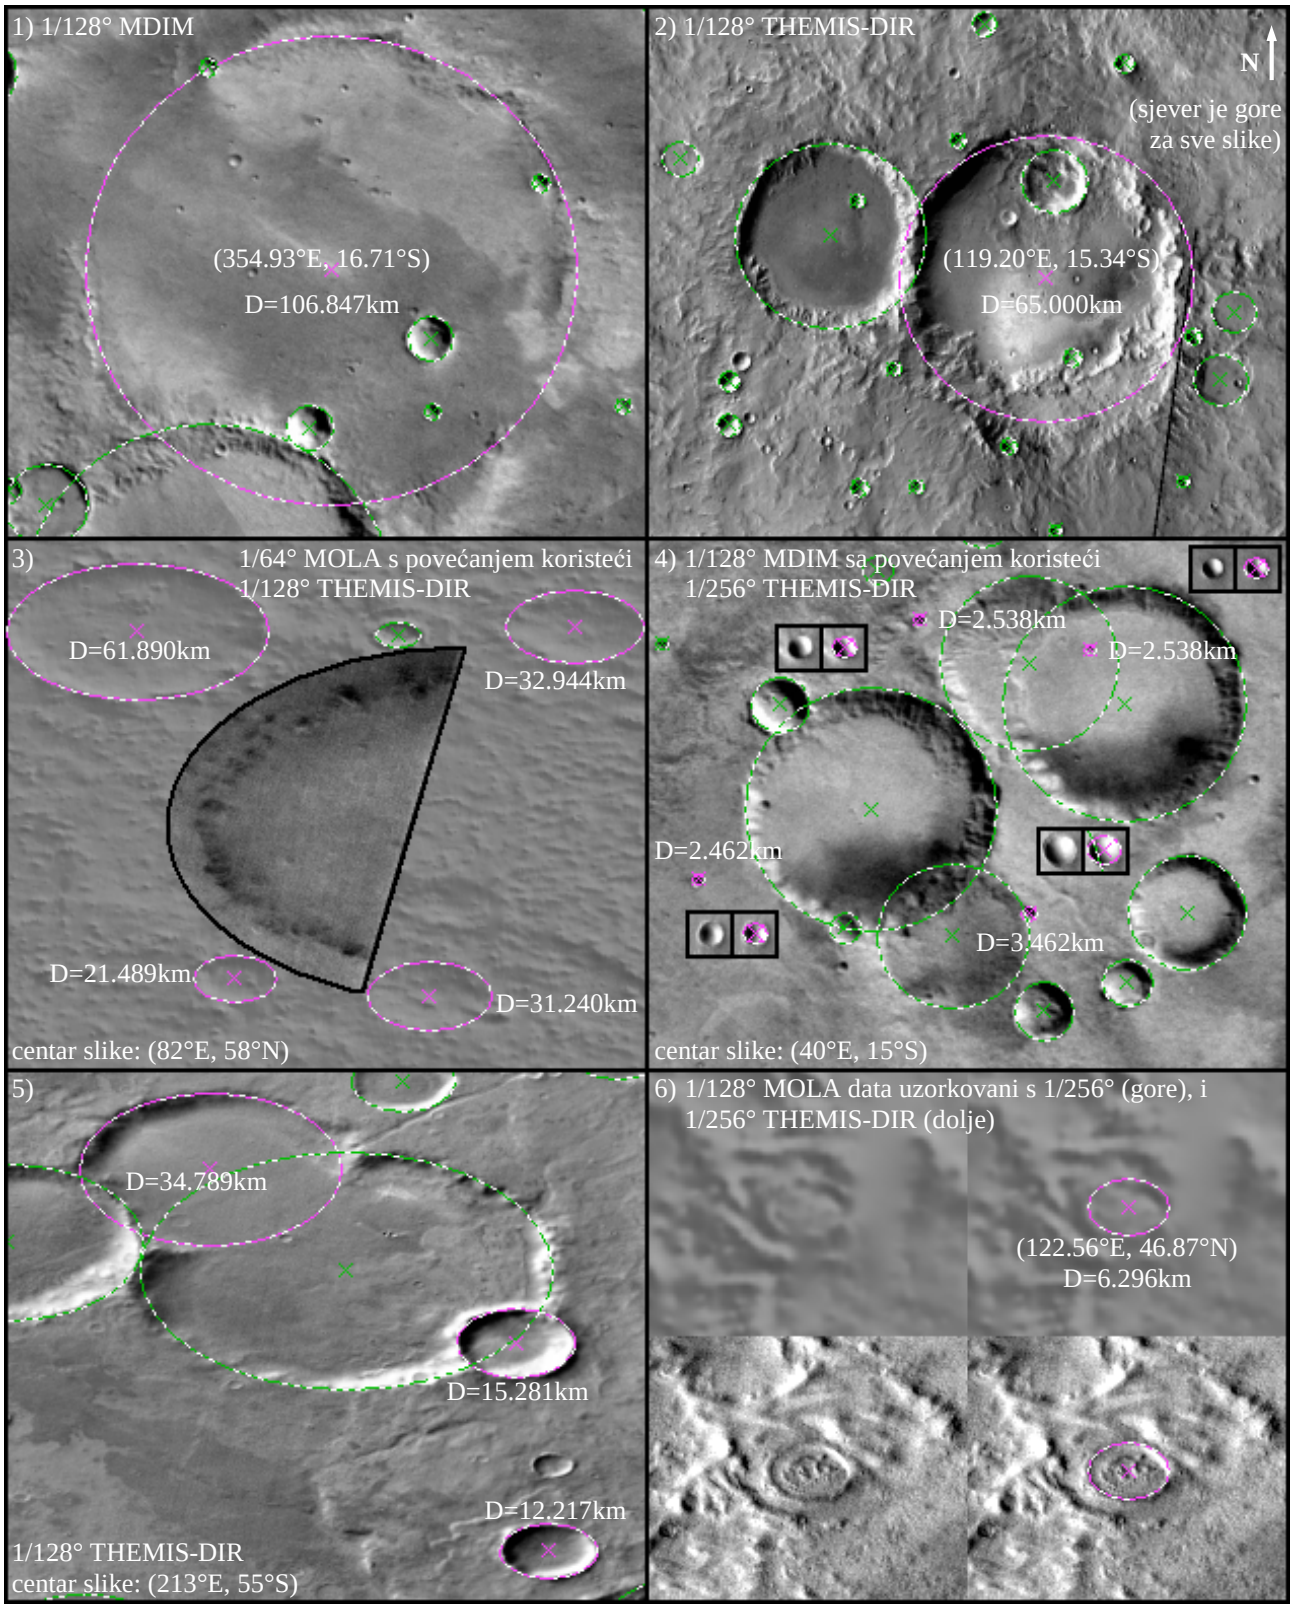
(9) nakon što korisnik obradi sve kratere na dijelu globalnog mozaika koji mu je prikazan, ponavlja korake od (3) do (8);

(10) rezultati obrade snimaju se u XML datoteku.

Krateri koji su blizu jedni drugima uobičajeno imaju isti pomak u odnosu na različite globalne mozaike, odnosno kada se jedan krater registrira s više globalnih mozaika, onda su i svi ostali krateri iz skupine vrlo vjerojatno dobro registrirani, sa svim korištenim mozaicima. Koristeći navedeni pristup znatno se može skratiti vrijeme registracije velikog broja kratera.

Slika 38 prikazuje novoregistrirane kratere iz različitih korištenih kataloga: (1) krater S019093B19134Y2007S iz kataloga MA42279B; (2) krater S019127R00792Y2007S iz kataloga MA19308R; (3) krateri S042146C01833Y2007S (prikazan gore lijevo), S042147C01832Y2007S (prikazan gore desno), S042149C01821Y2007S (prikazan dolje lijevo) i S042148C01820Y2007S (prikazan dolje desno) iz kataloga MA2268C; (4) krateri S050964K08416Y2007S (prikazan gore lijevo), S050967K08447Y2007S (prikazan gore desno), S050963K08674Y2007S (prikazan dolje lijevo) i S050965K08675Y2007S (prikazan dolje desno) iz kataloga MA24380K; (5) krateri S057533N00291Y2007S (prikazan gore lijevo), S057534N01357Y2007S (prikazan gore desno), S057535N03173Y2007S (prikazan dolje desno) iz kataloga MA22044N; (6) Ston krater kojim je pokazano da se niti sa svim ovim katalozima nisu katalogizirali svi krateri u dijametru veći od 5 km.

U prvom koraku pronašli su se krateri koji se nalaze u oba kataloga, MA42279B i MA19308R, te se katalog MA17582GT proširio s 1129 kratera, što je rezultiralo katalogom MA18711GT. Obradom preostalih kratera iz kataloga MA42279B i MA19308R, registrirano je 23 433 dodatnih kratera. Nakon toga je obrađen katalog MA2268C, što je rezultiralo s 282 dodatnih kratera. Pritom su se za kratere iz kataloga MA42279B, MA19308R i MA2268C koristila imena, odnosno identifikatori, koji povezuju svaki krater s katalogom i zapisom istog koji je korišten, a gdje je identifikator redni broj u korištenom katalogu. Katalog MA24380K sastoji se od tri liste kratera, pa su isti dobili imena i identifikatore u području od K00001 do K14943, od K20001 do K29527, i od K30001 do K30407. Analizom je potvrđeno da se svi krateri iz treće liste nalaze u drugoj, te su samo prve dvije liste dalje razmatrane. U trima slučajevima je potvrđeno da se tri kratera iz druge liste nalaze i na prvoj listi. Kako bi se razlikovali od drugih, pridijeljena su im imena/identifikatori K42605 (za K00288 i K22605), K43031 (za K00749 i K23031) i K45219 (za K06548 i K25219). Na kraju, koristeći MA24380K, registrirano je 14 981 dodatnih kratera. Za kratere iz kataloga MA22044N imena su pridijeljena od N00001 do N07356 za kratere koji nisu bili obuhvaćeni prethodnim koracima registracije iz kataloga MA42279B i MA19308R. Katalog MA22044N za svaki kratera sadrži samo koordinate i dijametar, pa prethodno registrirani ne mogu doprinijeti znanstvenim istraživanjima i stoga se nisu uzimali u obzir. Nakon što je završena registracija kratera iz kataloga MA2268C i MA24380K, obrisani su i oni krateri koji su se nalazili u tim katalozima, kao i neke od pronađenih pogrešnih detekcija koje se nisu mogle potvrditi uvidom u neki od globalnih mozaika ili koje su bile potvrđene kao duplikati. Preostalih 347 kandidata za kratere iz kataloga MA22044N poslani su drugom autoru tog kataloga na dodatnu reviziju (Z. Nežić), kako bi i za svaki od kratera iz tog kataloga postojala barem dva mišljenja da su zaista krateri. Od toga, referentni katalog je dodatno proširen s 225 potvrđena kratera. Prilikom završne provjere (korištenjem imena kratera), primijećeno je kako krater Ston nije katalogiziran, stoga je on dodan u referentni katalog pod imenom S057633Y2007S. Time je bio cilj pokazati otvorenosti rezultirajućeg kataloga MA57633GT za dodatna buduća proširenja.

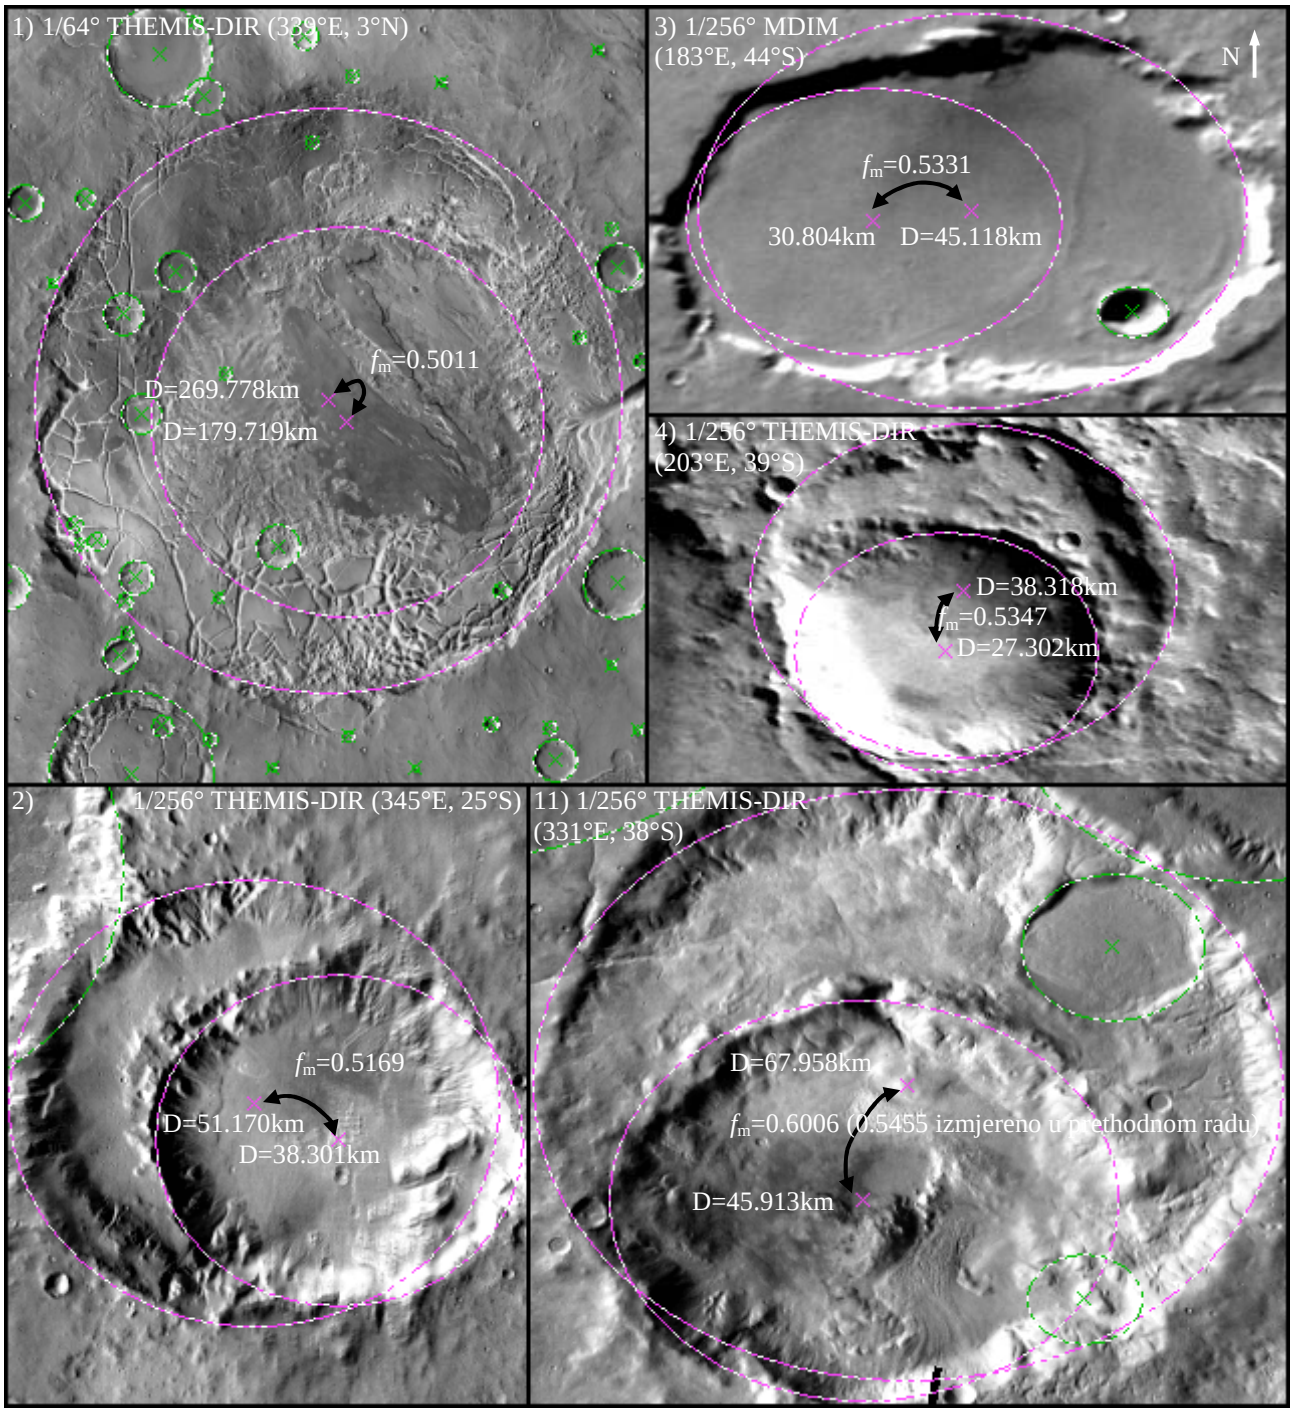


Slika 41. Proširenja kataloga: MA42279B (1), MA19308R (2), MA2268C (3), MA24380K (4), MA22044N (5) i Ston krater (6). © 2008 Elsevier (Salamunićcar i Lončarić, 2008e).

7.4. Metoda za provjeru konzistentnosti kataloga

Osnovni cilj metode za provjeru konzistentnosti kataloga je provjera postojanja višestrukih unosa za jedan te isti krater unutar kataloga (Salamunićcar i Lončarić, 2007b).

Za svaki krater traži se njemu najbliži u LLR prostoru, gdje je udaljenost definirana formulom (1). Nakon toga se analiziraju oni parovi kratera između kojih je udaljenost najmanja. Korištenjem ove metode pronađeno je dosta duplih unosa u prethodnim katalozima. Slika 42 prikazuje analizu MA57633GT kataloga, a njome je prikazano da u tom katalogu nema duplih unosa.



Slika 42. Četiri primjera iz MA57633GT kataloga s najmanjim f_m (1, 2, 3 i 4) te najmanji f_m iz prethodnog MA17582GT kataloga (11). © 2008 Elsevier (Salamunićcar i Lončarić, 2008e).

7.5. Rezultirajući katalog za vrednovanje s 57 633 kratera

Navedeni postupak za integraciju kratera iz prethodno dostupnih kataloga rezultirao je katalogom s 57 633 kratera (MA57633GT).

Navedeni katalog sadrži puno više kratera od korištenih kataloga. Naime, svaki od prethodnih kataloga neke je od kratera katalogizirao, a neke propustio, dok rezultirajući katalog sadrži sve one kratere koje barem jedan od analiziranih kataloga sadržava. Posebno za kratere veće od 10 km u dijametru, gotovo je nemoguće da je isti krater propušten i katalogom MA42279B i katalogom MA19308R, pa je samim time i vrlo izvjesno da se svi krateri koji su veći od 10 km u dijametru nalaze u rezultirajućem katalogu MA57633GT, kao i gotovo svi veći od 5 km u dijametru, jer je već i MA42279B katalog gotovo potpun u tom području.

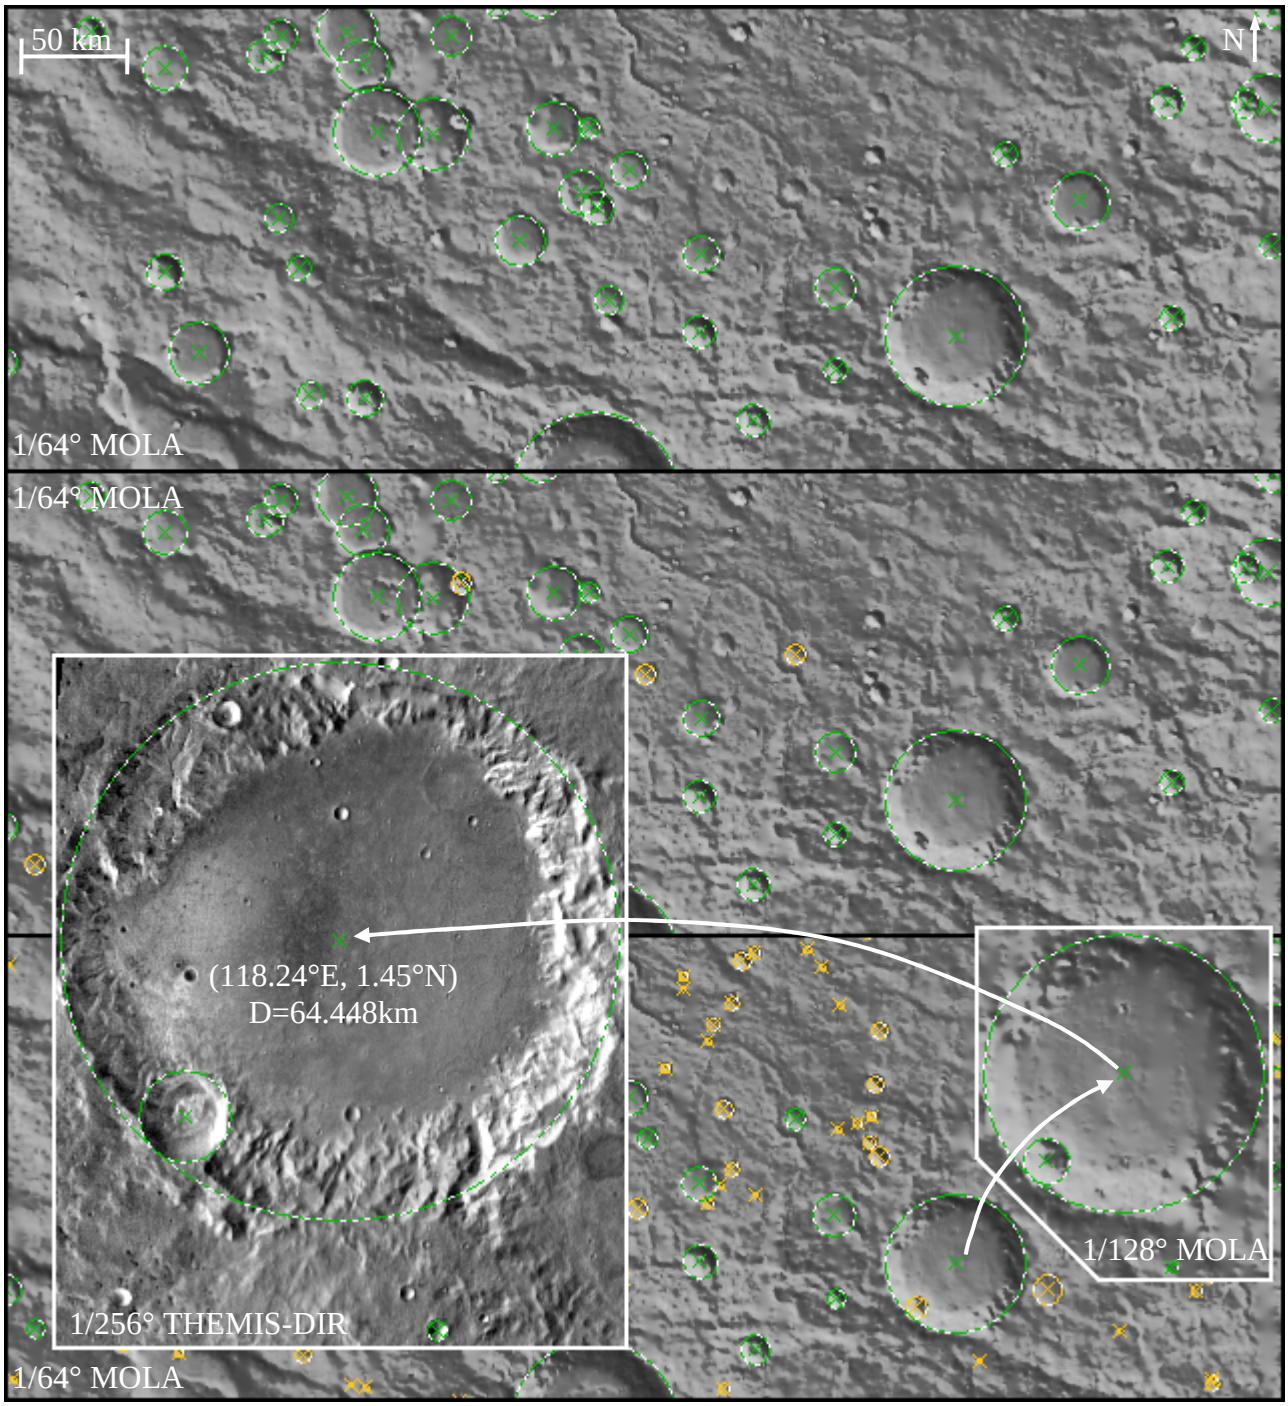
Tablica 6 prikazuje rezultate integracije, koji pokazuju da nijedan od kataloga ne sadrži više od ~73% kratera koji su na kraju registrirani u MA57633GT. Također, iz tablice se vidi i da ručno sastavljeni katalozi imaju između 0.7% i 1.4% pogrešnih unosa. Taj broj se penje i do ~10% ako se ne radi o kraterima vidljivim na optičkim slikama, nego i o depresijama koje se mogu prepoznati samo na topografskim slikama. S obzirom na vrlo malu vjerojatnost da dvije različite osobe unesu u katalog nešto što nije krater, samim time što je svaki krater iz MA57633GT potvrđen u barem dvama nezavisnim izvorima, očekuje se još manje pogrešnih unosa u tom katalogu (isti se nikada ne mogu potpuno isključiti) u odnosu na prethodne kataloge. To je vrlo važno svojstvo potrebno za što bolje vrednovanje CDA-ova.

Tablica 6. Rezultati integracije različitih kataloga u MA57633GT (Salamunićcar i Lončarić, 2008e).

katalog\krateri	**svi zapisi**	**različiti zapisi**	**duplikati ili nepronađeni**	**uspješno integrirani**	**postotak u katalogu**
MA42279B (Barlow)	42 284	42 279	558 (1.32%)	41 721 (98.68%)	72.39%
MA19308R (Rodionova)	19 308	19 308	174 (0.90%)	19 134 (99.10%)	33.20%
MA2268C (Boyce)	2 268	2 268	224 (9.88%)	2 044 (90.12%)	3.55%
MA24380K (Kuzmin)	24 877	24 380	186 (0.76%)	24 194 (99.24%)	41.98%

Slika 43 prikazuje progres prilikom registracije kratera. Katalog MA18711GT ima nešto više kratera od početnog kataloga MA17582GT, koji su većinom oko 10 km u dijametru. Znatno više kratera od MA18711GT ima katalog MA57633GT, gdje su dodani krateri u pravilu u promjeru manji od 10 km, s obzirom na to da se većina kratera velikih 10 ili više kilometara nalazi u katalogu MA18711GT. Slika također prikazuje koliko 1/128° MOLA podaci bolje prikazuju detalje u odnosu na 1/64° MOLA podatke. Dodatno je prikazano i koliko 1/256° THEMIS-DIR globalni optički mozaik bolje prikazuju detalje u odnosu na 1/128° MOLA globalnu topografsku sliku, pa tako i ostali 1/256° globalni optički mozaici.

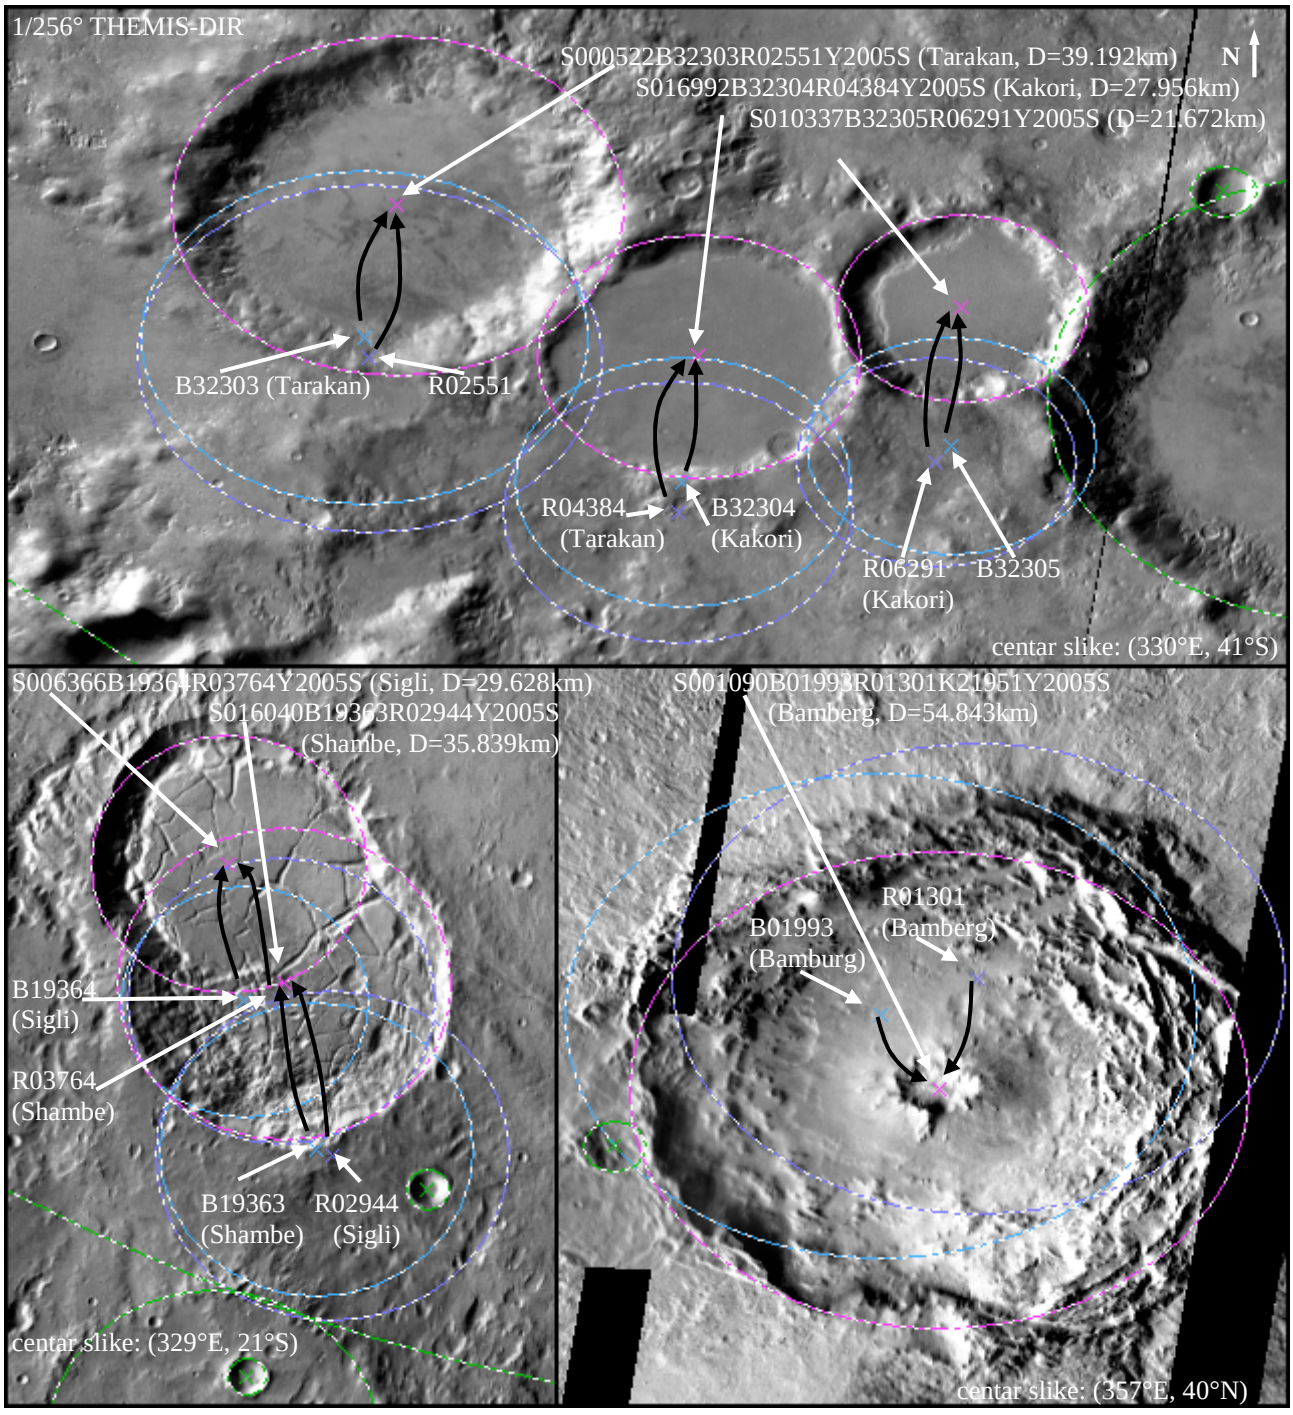
Može se primijetiti da katalog MA57633GT sadrži gotovo sve kratere koji se mogu vidjeti na 1/64° MOLA slici. No već na 1/128° MOLA slici vide se mali krateri koji se ne nalaze u MA57633GT katalogu. To je bio prvi pokazatelj mogućeg korištenja CDA-a ovoga rada u pronalaženju prethodno nekatalogiziranih kratera. Također se može primijetiti da se na 1/256° THEMIS-DIR vide mnogi detalji koji se ne vide ni na 1/128° MOLA slici. To je važno za utvrđivanje pogrešnih detekcija prilikom registracije kratera CDA-ova, kako bi se iste obrisale, a one dobre registrirale u referentni katalog (s, po potrebi, korigiranim koordinatama i dijametrom).



Slika 43. Dio početnog MA17582GT (gore), proširenog MA18711GT (sredina) i rezultirajućeg MA57633GT (dolje) kataloga. © 2008 Elsevier (Salamunićcar i Lončarić, 2008e).

Osnovna provjera MA57633GT kataloga izvršena je metodom za traženje potencijalnih duplih unosa, kako je opisano u prethodnom potpoglavlju. Zahvaljujući tome što mnogi krateri u katalozima MA42279B i MA19308R sadrže i ime, dodatno su provjerene i metode koje su rezultirale MA57633GT katalogom, pa time i sam katalog MA57633GT. Slika 44 prikazuje rezultate ove provjere. U prvom slučaju (gornji dio slike) provjerom je utvrđena pridijeljenost imena kratera Tarakan i Kakori u katalogu MA42279B skroz lijevom krateru i krateru u sredini, a u katalogu MA19308R krateru u sredini i skroz desnom krateru. Provjerom ostalih dostupnih izvora informacija na Internetu utvrđena je točnost imena iz kataloga MA42279B te pogreška u MA19308R katalogu. U drugom slučaju (donji dio slike lijevo), sličnom provjerom imena kratera Sigli i Shambe, ponovo je utvrđena točnost imena iz kataloga MA42279B te pogreška u

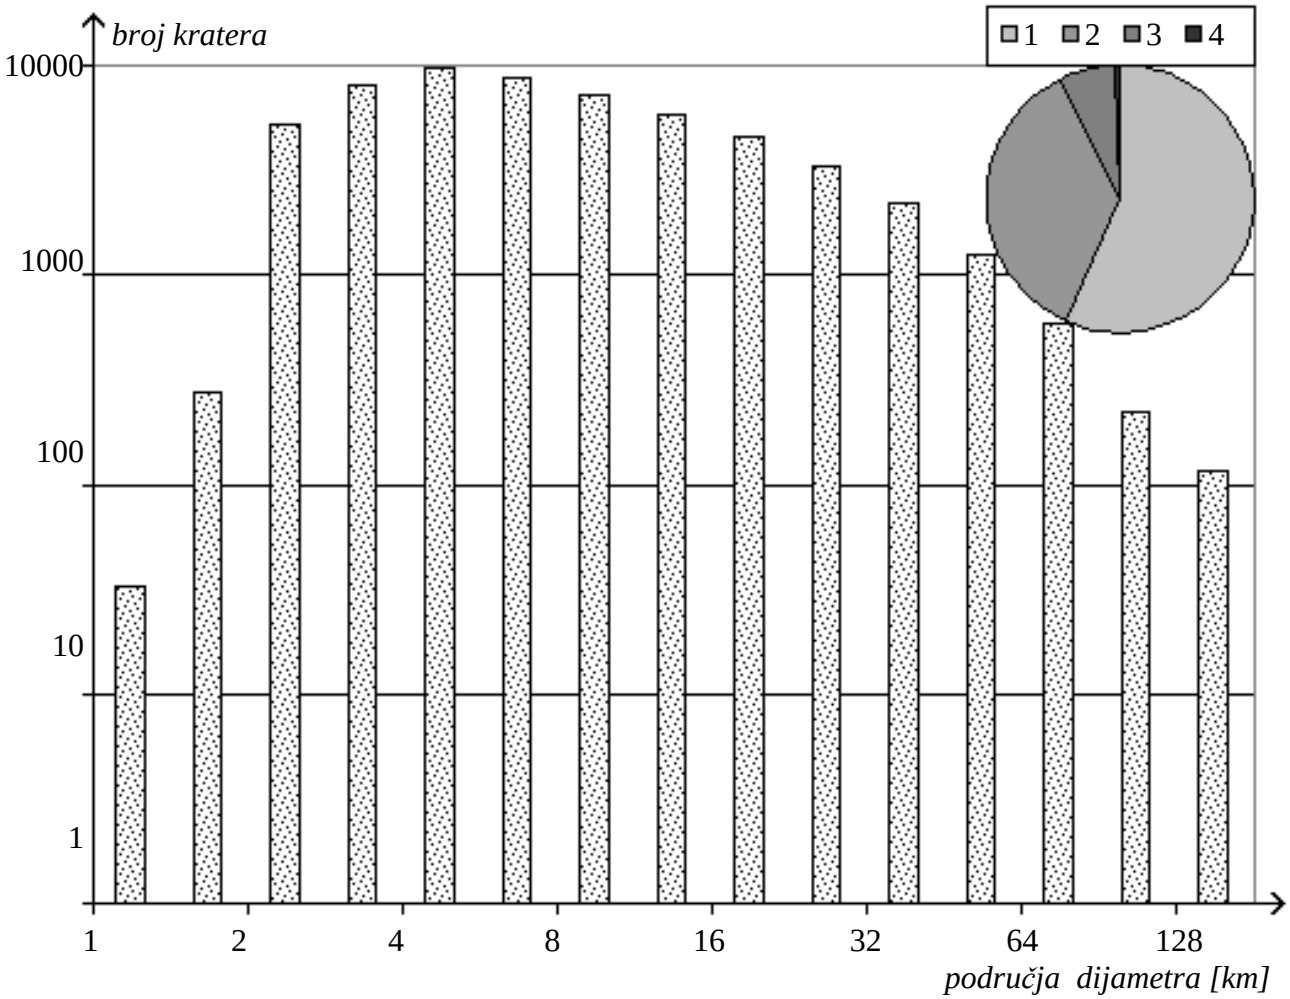
MA19308R katalogu. U trećem slučaju utvrđeno je suprotno, točnost imena iz MA19308R kataloga te pogreška u MA42279B katalogu (tipfeler u nazivu grada po kojem je krater Bamberg dobio ime). No niti u jednom slučaju, iako su dobri primjeri gdje se može dogoditi pogreška u registraciji, nije pronađena pogreška prilikom registracije u MA57633GT katalog. Time je dodatno potvrđena ispravnost korištenog pristupa.



Slika 44. Verifikacija MA57633GT kataloga korištenjem imena kratera koja su dostupna iz prethodnih kataloga, MA42279B i MA19308R. © 2008 Elsevier (Salamunićcar i Lončarić, 2008e).

Slika 45 prikazuje distribuciju kratera iz kataloga MA57633GT. Veliki graf prikazuje $\log_{10}$ broja kratera za područja dijametra od 1 km do 1.414 km, od 1.415 km do <2 km, od ≥2 km do 2.828 km, …, te od ≥128 km do 1200 km. Pridruženi brojevi kratera su 33, 277, 5226, 8085, 9780, 8822, 7293, 5888, 4550, 3311, 2206, 1246, 579, 222 i 115. Mali graf prikazuje distribuciju kratera s

obzirom na broj prethodnih kataloga (razmatrani su MA42279B, MA19308R, MA2268C i MA24380K) u kojima se nalazi svaki od kratera iz rezultirajućeg MA57633GT kataloga: 1 (32 602 kratera – 56.57%), 2 (20 709 kratera – 35.93%), 3 (3989 kratera – 6.92%) i 4 (333 kratera – 0.58%).



Slika 45. Distribucija kratera iz kataloga MA57633GT (veliki graf) te distribucija broja kataloga iz kojeg potječe pojedini krater (mali graf). © 2008 Elsevier (Salamunićcar i Lončarić, 2008e).

Zahvaljujući prethodno opisanoj metodologiji došlo se do referentnog kataloga koji ima znatno više kratera nego prethodna verzija, MA17582GT, koja se koristila za razvoj CDA-ova (verzija MA18711GT je međukorak i nije se koristila za razvoj ili vrednovanje CDA-ova). S druge strane, metodologijom se osiguralo puno manje pogrešnih detekcija u MA57633GT (nijedna nije pronađena) nego u prethodnim katalozima, MA42279B, MA19308R, MA2268C, MA24380K i MA22044N. To je potvrđeno metodom za provjeru konzistentnosti kataloga (koja traži potencijalne duple unose) te potvrdom svakog kratera s najmanje dvama nezavisnim izvorima (jedan izvor su korišteni katalozi, a drugi potvrda prilikom registracije u rezultirajući katalog MA57633GT).

Time se osigurao referentni katalog koji je po svojstvima puno bolji od svih koji su prethodno bili dostupni, te time on zasigurno može osigurati kvalitetno vrednovanje CDA-ova ovoga rada.

7.6. Zaključak

Rezultati postignuti razvojem referentnog kataloga za vrednovanje CDA-ova (Salamunićcar i Lončarić, 2008e) su metode i pripadni podaci koji su razvijeni kako bi se osiguralo sve potrebno za objektivno vrednovanje CDA-ova: (1) MA57633GT referentni katalog; (2) metoda za integraciju kratera iz različitih kataloga; (3) metoda za provjeru konzistentnosti kataloga.

Uz navedeno koriste se globalne topografske slike u višoj horizontalnoj rezoluciji od prethodno korištenih (1/128° MOLA podaci), kao i globalni optički mozaici u još višoj horizontalnoj rezoluciji od topografskih slika (1/256° THEMIS-DIR, 1/256° MDIM i 1/256° MOC) koje se koriste tijekom vrednovanja. Time se može značajno bolje vrednovati neki CDA nego što je to bilo moguće inicijalnim okruženjem za razvoj CDA-ova.

Katalog MA57633GT značajno je potpuniji od prethodnog referentnog kataloga MA17582GT, te time može dati daleko bolji uvid u stvarne karakteristike CDA-ova koji se vrednuju.

Metoda za integraciju kratera iz različitih kataloga može se koristiti i prilikom obrade kandidata za kratere koje je detektirao CDA. Time su ostvarene i mogućnosti za daljnja proširenja kataloga MA57633GT kraterima koje su detektirali CDA-ovi.

Metoda za provjeru konzistentnosti kataloga koristila se za provjere korištenih kataloga, ali isto tako i za provjeru konzistentnosti MA57633GT kataloga. Provjera je pokazala da MA57633GT ne sadrži duple unose istih kratera, kao što su sadržavali korišteni katalozi.

Ovime je osigurana puno bolja okolina za objektivno vrednovanje CDA-ova. Tom okolinom će se u poglavljima koja slijede pokazati doprinos metoda za detekciju kratera, razvijenih u ovome radu.

Katalog MA57633GT u svom radu koristili su i drugi, i to za znanstvena istraživanja koja nisu o algoritmima za detekciju kratera. Primjer je znanstveno istraživanje u kojem je bio cilj ispitati ovisi li oblik kratera o geografskoj širini te može li se to iskoristiti za uvid u promjene klime na Marsu (Conway et al., 2011a, 2011b).

8. METODE ZA VREDNOVANJE ALGORITAMA ZA DETEKCIJU KRATERA

U ovom poglavlju opisuju se metode vrednovanja CDA-ova, kroz sljedeća potpoglavlja:

- 8.1. Uvod;
- 8.2. Priprema globalnih topografskih i optičkih slika;
- 8.3. Uparivanje kratera iz različitih kataloga korištenjem konteksta;
- 8.4. Interaktivna metoda za provjeru i registraciju kratera u kataloge;
- 8.5. Površina ispod A-ROC krivulje i ostale mjere za vrednovanje;
- 8.6. Postupak usporedbe algoritama za detekciju kratera;
- 8.7. Zaključak.

U potpoglavlju 8.1. daje se uvod u problematiku i opisuje cilj koji se želi ostvariti novim metodama za vrednovanje algoritama za detekciju kratera. U potpoglavlju 8.2. opisuju se metode i rezultati pripreme globalnih topografskih i optičkih slika. U potpoglavlju 8.3. opisuje se napredna metoda za uparivanje kratera iz različitih kataloga. Ista je pokazala daleko bolje rezultate od temeljne metode za uparivanje kratera iz različitih kataloga, prvenstveno zahvaljujući tome što se analizira i kontekst u kojem se nalaze krateri koji se registriraju. U potpoglavlju 8.4. opisuje se interaktivna metoda za provjeru i registraciju kratera u kataloge. Ista je posebno razvijena kako bi se što efikasnije mogli obraditi i oni kandidati za kratere kojima je pridijeljena vrlo mala vjerojatnost da su zaista krateri. U potpoglavlju 8.5., uz površinu ispod A-ROC krivulje, opisane su i razne druge metode koje se mogu koristiti kao mjere za vrednovanje CDA-ova. U potpoglavlju 8.6. opisuje se postupak usporedbe algoritama za detekciju kratera, koji rezultira proširenjima referentnog kataloga s točnim detekcijama oba CDA-a koja se žele usporediti, kako bi sama usporedba i verifikacija istih bila što točnija. U potpoglavlju 8.7. naveden je zaključak o postignutom s novim metodama i pripremljenim podacima.

Ovaj dio rada napravljen je u suradnji s Pedrom Pinom, Lourençom Bandeirom i Joséom Saraivom (Salamunićcar et al., 2011a), čiji je doprinos detekcija kratera iz optičkih slika njihovim CDA-om (Bandeira et al., 2007b) te konstruktivna diskusija koja je rezultirala poboljšanjima metodologije za vrednovanje CDA-ova.

8.1. Uvod

Okolina za razvoj algoritama za detekciju kratera, opisana u poglavlju 3, uspješno se koristila tijekom razvoja metoda za detekciju kratera. No kao što je u prethodnom poglavlju opisano, katalog MA17582GT nije bio dostatan za najbolje moguće vrednovanje, pa je proširen dodatnim kraterima, što je rezultiralo katalogom MA57633GT.

Uz sam referentni katalog, za vrednovanje metode koja može obraditi globalne podatke, važne su i globalne topografske, odnosno optičke slike. Također su važne i metode koje će efikasno uparivati rezultate detekcije s kraterima iz referentnog kataloga.

Kako je u prethodnom poglavlju napomenuto, uz 1/64° MOLA podatke postali su dostupni i 1/128° MOLA podaci. No uz njih postali su dostupni i 1/256° MOLA te 1/512° MOLA podaci za područja blizu Sjevernog i Južnog pola. Time su se i ti podaci mogli iskoristiti za vrednovanje CDA-ova.

Globalni optički mozaici koji se koriste su 1/256° THEMIS-DIR, 1/256° MDIM i 1/256° MOC. Te slike međutim nisu i najpogodnije za CDA-ove koji obrađuju optičke slike, a ponekad ni za ručnu provjeru detektiranih kandidata za kratere. Ponekad je problem kontrast, odnosno svjetlina, gdje su slike presvijetle, pretamne, ili nedovoljnog kontrasta. Dodatni problem kod globalnih optičkih mozaika je nepostojanje slike za neki dio površine, pa je taj dio obično zacrnjen (slikovni elementi kojima su vrijednosti crvene, zelene i plave boje jednake nuli). To također može biti problem za CDA-ove koji obrađuju optičke slike, s obzirom na to da veliki iznosi promjene gradijenta mogu rezultirati primjerice detekcijama rubova na mjestima gdje ih ustvari nema. Važnost mogućnosti korištenja okoline za vrednovanje CDA-ova, kako za one koji koriste topografske slike, tako i one koji koriste optičke slike, u njihovoj je međusobnoj usporedbi te korištenju za katalogizaciju što više kratera. Stoga je navedene globalne optičke mozaike potrebno obraditi.

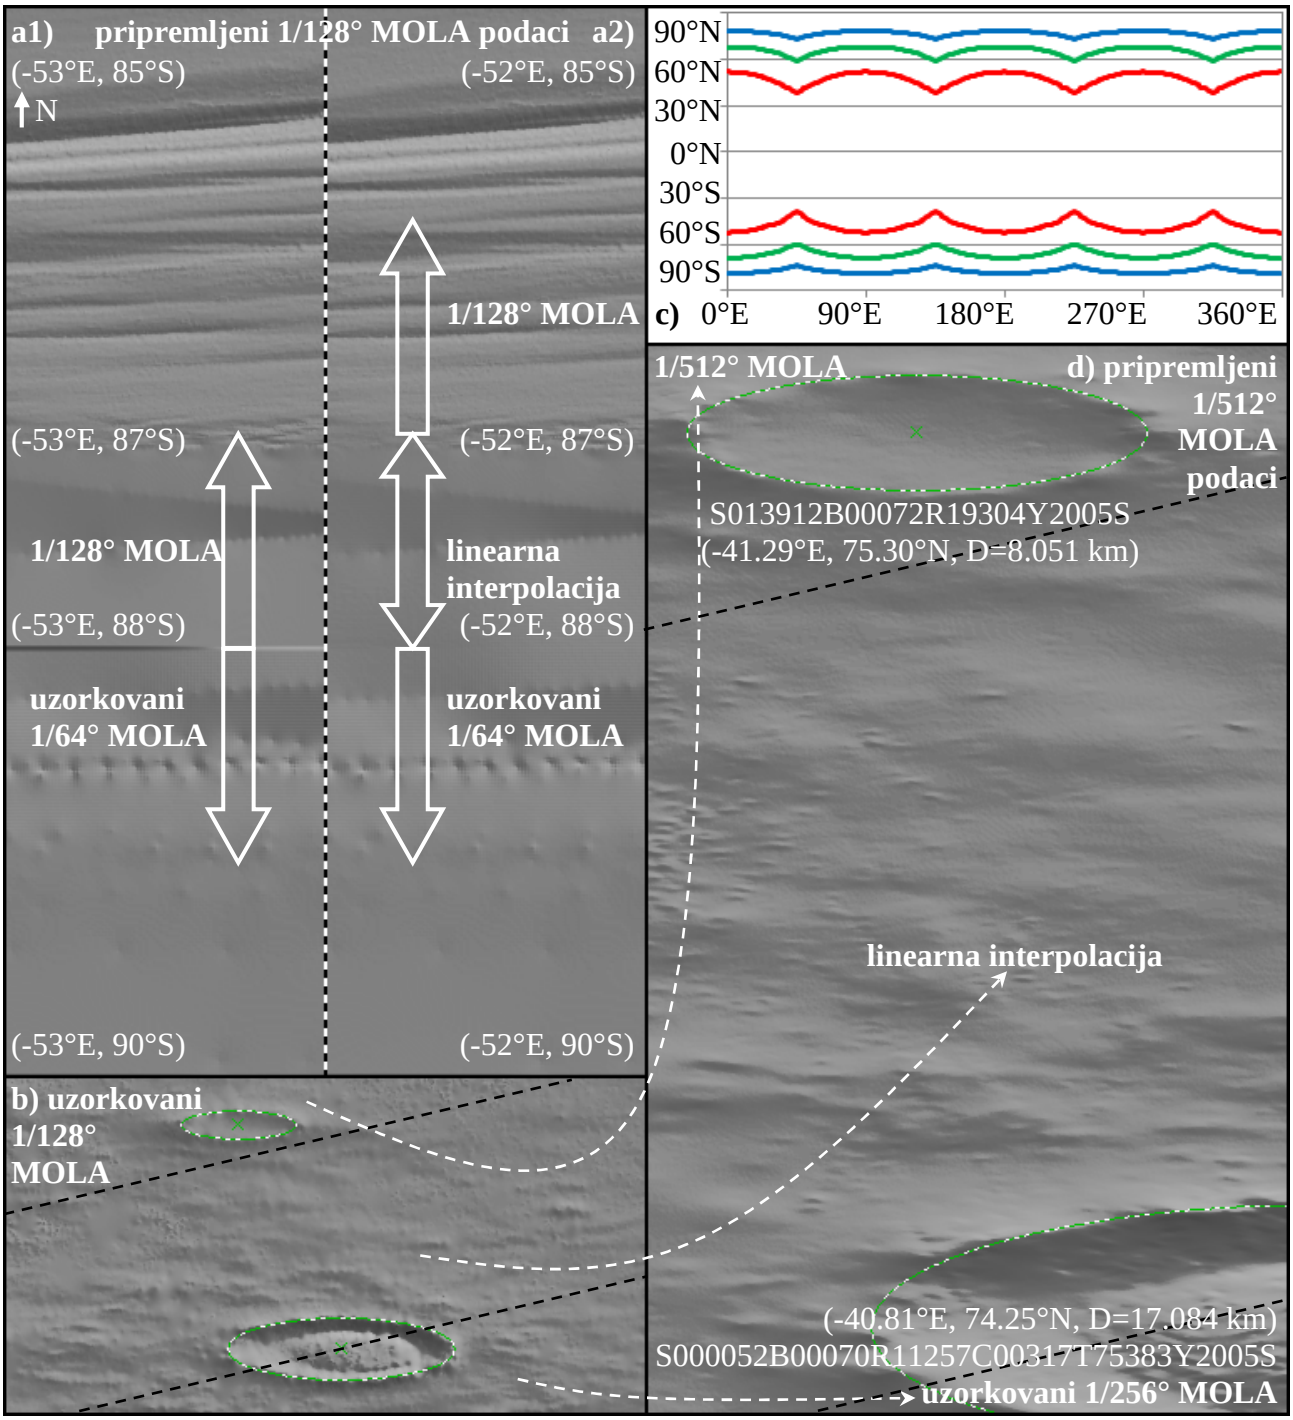
Dodatni problem bila je sama registracija kratera. Prethodna metoda koja uzima u obzir samo one kratere iz dva različita kataloga kada je $f_m < 0.5$, objektivno vrednuje dva različita CDA-a s obzirom na to da ih vrednuje na isti način. No prilikom analize rezultata Stepinskovog i Urbachovog CDA-a (2008), odnosno kataloga MA75919T, primijećeno je postojanje znatnog broja kratera, pretežno onih malih, koji su određeni nedovoljno preciznim koordinatama i dijametrima da bi se mogli uparivati s kraterima iz referentnog kataloga prethodno razvijenom metodom. Stoga je razvijena znatno naprednija metoda za uparivanje rezultata CDA-a s kraterima iz referentnog kataloga. Nova metoda je temeljena na kontekstu, odnosno ona uparivanje kratera prilagođava veličini kratera (malim, odnosno velikim kraterima) te položajima susjednih kratera (nakupinama kratera gdje ih ima puno na relativno maloj udaljenosti, odnosno individualnim kraterima koji su relativno udaljeni od ostalih). Ovime su se postigla puno bolja svojstva u uparivanju kratera, pa samim time i osigurale daleko korisnije metode vrednovanja. Iste mogu dati daleko više informacija o samom CDA-u. Posebne je to korisno prilikom razmatranja mogućnosti poboljšanja CDA-a.

Prilikom provjere kandidata za kratere, nakon što se obradi većina detektiranih s visokom pridruženom vjerojatnosti, i kada se počnu provjeravati oni s niskom vjerojatnosti da su krateri, ponekad je mnoge potrebno obrisati dok se ne dođe do nove točne detekcije. Stoga je razvijena i posebna interaktivna metoda koja znatno ubrzava registraciju u ovom slučaju.

I na samom kraju podržano je desetak različitih metoda vrednovanja, kako bi svaki autor CDA-a mogao izabrati one koje najviše odgovaraju njegovoj primjeni. Također je razvijen i način za usporedbu CDA-ova, koji uz prethodnu objektivnost pruža i najvišu točnost u vrednovanju.

8.2. Priprema globalnih topografskih i optičkih slika

U prvom koraku pripremljene su globalne topografske slike u višoj horizontalnoj rezoluciji od 1/64°, u kojoj su prvotno bili dostupni MOLA podaci. Slika 46 prikazuje rezultate.



Slika 46. Priprema 1/128° i 1/512° MOLA globalne topografije. © 2008 Elsevier (Salamunićcar et al., 2011a).

Globalne topografske slike u horizontalnoj rezoluciji 1/128° dostupne su samo za područje od 88° sjeverno do 88° južno. Stoga je preostali dio (od 88° do 90° sjeverno i od 88° južno do 90° južno) kod pripreme 1/128° MOLA podataka interpoliran korištenjem 1/64° podataka. Kako je prikazano na prethodnoj slici (a1), problem je umjetni rub između 1/64° i 1/128°, na paralelama

koje se nalaze na 88° sjeverno i 88° južno. Isto nije posljedica interpolacije, nego korištenih podataka. Stoga je između 88° sjeverno i 87° sjeverno te između 87° južno i 88° južno dodana linearna interpolacija za postepen prijelaz s horizontalne rezolucije 1/128° na 1/64°. Time se ovaj problem u potpunosti otklonio, kako je prikazano na prethodnoj slici (a2), a ujedno i osiguralo da se između 87° sjeverno i 87° južno koriste isključivo podaci u horizontalnoj rezoluciji 1/128°.

S obzirom na to da su dostupni i topografski podaci u horizontalnim rezolucijama 1/256° i 1/512° za najsjevernija i najjužnija područja, kako je prikazano na prethodnoj slici (c), isto je iskorišteno za pripremu globalnih MOLA podataka i u te dvije horizontalne rezolucije. Pritom se također koristila linearna interpolacija, kako je prikazano na prethodnoj slici, dijelovima (b) i (d), kako bi se osigurao postupan prijelaz s jedne horizontalne rezolucije na drugu kroz područje od 1°. Kako je prikazano na prethodnoj slici (d), to se na kraju i postiglo.

U drugom koraku pripremljene su globalne optičke slike u horizontalnoj rezoluciji 1/256°, kako bi se i njima proširila okolina za vrednovanje CDA-ova (Salamunićcar i Lončarić, 2008c). Slika 47 prikazuje metodologiju i rezultate te pripreme.

U dijelu (a) prikazana je 1/128° MOLA topografska slika, kako bi se ta horizontalna rezolucija topografskih mogla usporediti s 1/256° horizontalnom rezolucijom optičkih slika.

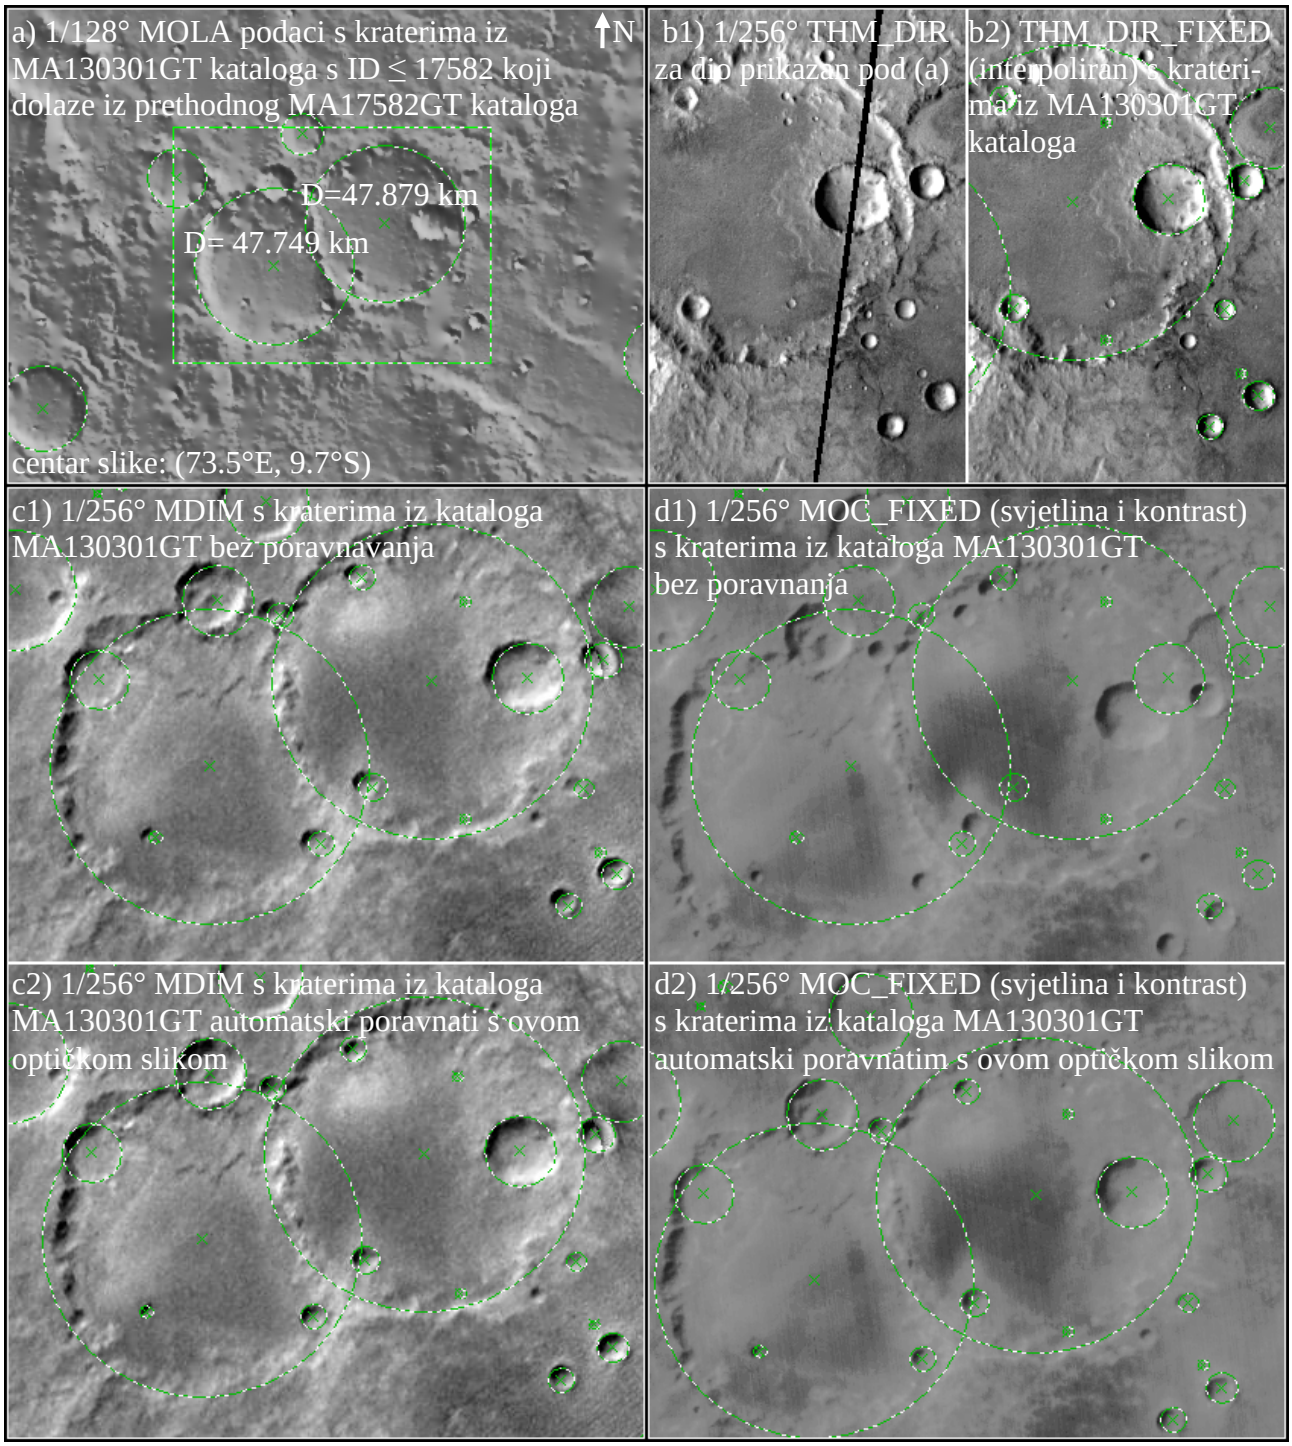
U dijelu (b1) prikazana je izvorna 1/256° THM_DIR optička slika. Može se primijetiti da dio slike nedostaje. U dijelu (b2) prikazan je rezultat algoritma za popunjavanje vrijednosti koje nedostaju na temelju vrijednosti susjednih slikovnih elemenata. Kako je prikazano, gotovo da se i ne primjećuje koji dio slike je nedostajao. Ovime se olakšava detekcija optičkim CDA-ovima, ali i ručno provjeravanje kandidata za kratere.

U dijelovima (c1) i (c2) prikazani su primjeri za 1/256° MDIM podatke. Ovdje nije bila potrebna obrada slika, no može se primijetiti da one nisu sasvim poravnate s MOLA podacima (nisu niti 1/256° THM_DIR u potpunosti, no puno bolje su poravnate nego 1/256° MDIM), kako je prikazano u (c1). Međutim, zahvaljujući tome što je svaki krater u referentnom katalogu registriran sa svim korištenim optičkim slikama, svi krateri iz kataloga se mogu automatski pomaknuti, svaki za potreban iznos, i tako se poravnati. Rezultat je prikazan u (c2).

U dijelovima (d1) i (d2) prikazani su primjeri za 1/256° MOC slike. Tu je bilo potrebno napisati algoritam koji će popraviti i kontrast i svjetlinu. Obje slike prikazuju rezultat obrade jer je slika prije rezultata obrade bila toliko tamna da se ništa nije vidjelo. Dodatno, neregistriranost tih slika puno je veća od neregistriranosti svih ostalih. Početno ideja bila je korištenje nekog od dostupnih programa za pojačavanje kontrasta i korekcije svjetline, međutim tu je bilo više problema. Prije svega, globalni optički mozaici su tako veliki da ih isprobani alati za obradu slika jednostavno nisu mogli učitati. Kad bi se slika podijelila na dijelove, problem bi bili rubovi vidljivi nakon obrade između dijelova slika, u slučaju korištenja adaptivnih metoda za korekciju kontrasta i svjetline. Ako se adaptivne metode pak ne koriste, onda neke slike ispadaju presvijetle, a neke pretamne. Stoga je razvijena metoda u svrhu popravljanja kontrasta i svjetline kod globalnih optičkih mozaika. Metoda definira prozor određene veličine, koji se koristi za određivanja optimalnih parametara za doradu kontrasta i svjetline. Nakon toga, vrijednosti ovako dobivenih parametara se interpoliraju kako se po slici pomičemo od područja jednog prema području drugog prozora. Tako se može obraditi cijela globalna optička slika, da je ona na kraju po svim dijelovima ujednačene svjetline i kontrasta, a da se ne vide umjetne linije između prozora koji su korišteni prilikom rada metode. Ono što korisnik može birati su parametri, primjerice koliki iznos kontrasta će se primijeniti na globalni mozaik.

Koristeći kratere kataloga MA57633GT, kao i sljedećih kataloga među kojima je jedan i prikazan na sljedećoj slici (kao primjer, više će biti opisan u poglavlju koje slijedi), moguće je i napraviti transformaciju optičkih slika kako bi bile registrirane s MOLA podacima. No to zasad nije napravljeno, jer se pritom slika na nekim dijelovima mora skupljati, a na nekim rastezati. Time bi

izgubila na kvaliteti potrebnoj prilikom detekcije kratera. Ovo bi mogao biti problem posebno za najmanje kratere, s obzirom da su prikazani vrlo malim brojem slikovnih elemenata. Isto bi mogao biti problem i prilikom registracije najmanjih kratera u referentni katalog. Zbog ovoga je odlučeno da se koordinate ne transformiraju u MOLA koordinatni sustav, nego da se ulazne optičke slike koriste u obliku u kojem su inicijalno preuzete.

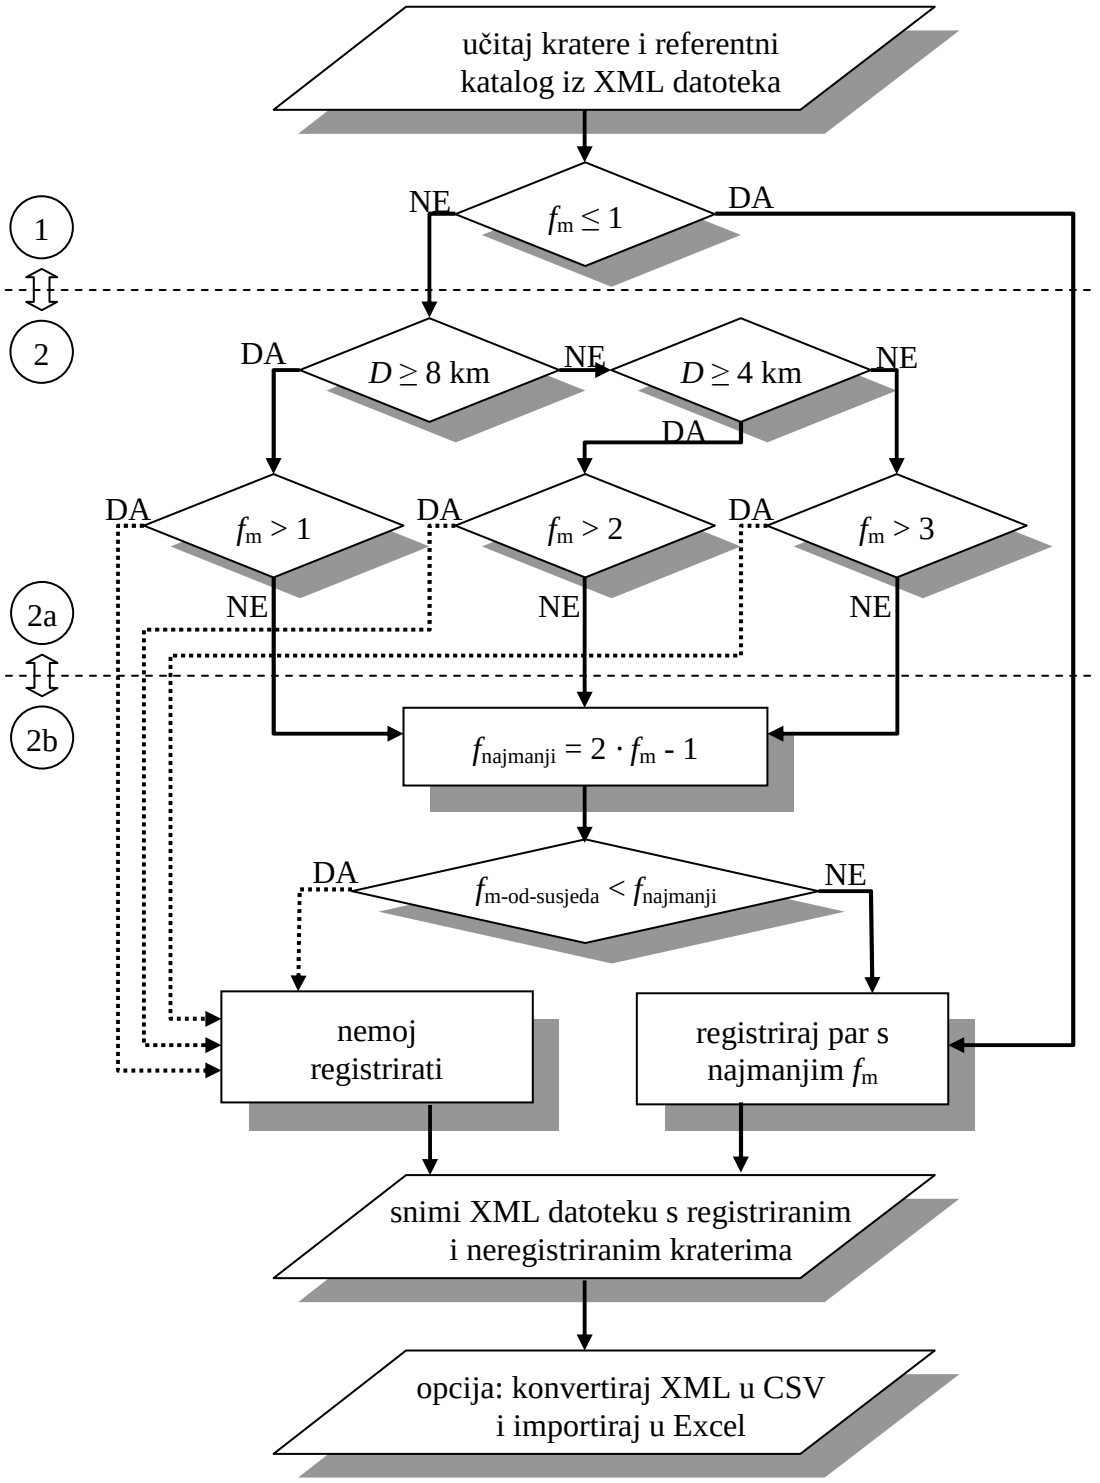


Slika 47. Priprema globalnih optičkih mozaika u horizontalnoj rezoluciji 1/256°. © 2008 Elsevier (Salamunićcar et al., 2011a).

Ovime su se pripremili svi potrebni podaci kako bi se i CDA-ovi koji koriste topografske slike i CDA-ovi koji koriste optičke slike mogli puno bolje i vrednovati i koristiti nego što je to bilo moguće u početku.

8.3. Uparivanje kratera iz različitih kataloga korištenjem konteksta

Napredna metoda za uparivanje kratera iz različitih kataloga koja je temeljena na kontekstu (Lončarić i Salamunićcar, 2010), razvijena je za analizu i onih kratere koje CDA uspije detektirati, koji su točne detekcije, ali detektirani su s nedovoljno preciznim koordinatama ili dijametrom (ili oboje). Slika 48 prikazuje dijagram toka i osnovne korake obrade te metode.



Slika 48. Metoda za napredno uparivanje kratera iz različitih kataloga. © 2008 Elsevier (Salamunićcar et al., 2011a).

Metoda koristi informacije kao što su veličina kratera i kontekst. Ako je krater blizu drugima, registracija je teža. Ako je udaljen od drugih kratera, vjerojatnost pogrešne registracije je puno manja. Metoda ne uzima u obzir neporavnatost korištenih globalnih podataka, među ostalim i zato što se referentni katalog, zahvaljujući koordinatama pohranjenim za svaki krater, može automatski poravnati s bilo kojim korištenim globalnim mozaikom optičkih slika.

U odnosu na početnu verziju metode zamijenio se prolaz u jednom s prolazom u dva koraka. U prethodnoj verziji, za uspješno uparivanje, udaljenost u LLR prostoru definirana formulom (1) morala je biti $f_m < 0.5$, a jednom upareni krateri nisu se dalje obrađivali.

Kod nove se metode u prvom prolazu kreira lista mogućih uparivanja, uz uvjet $f_m \leq 1$. Iz te liste najmanja vrijednost f_m-a za svaki par uzima se kao osnova za registraciju.

Potreba za drugim prolazom proizlazi iz činjenice da postoje mnogi parovi kojima je $f_m > 1$, a koji se ipak mogu registrirati, koristeći nekoliko pravila temeljenih na kontekstu.

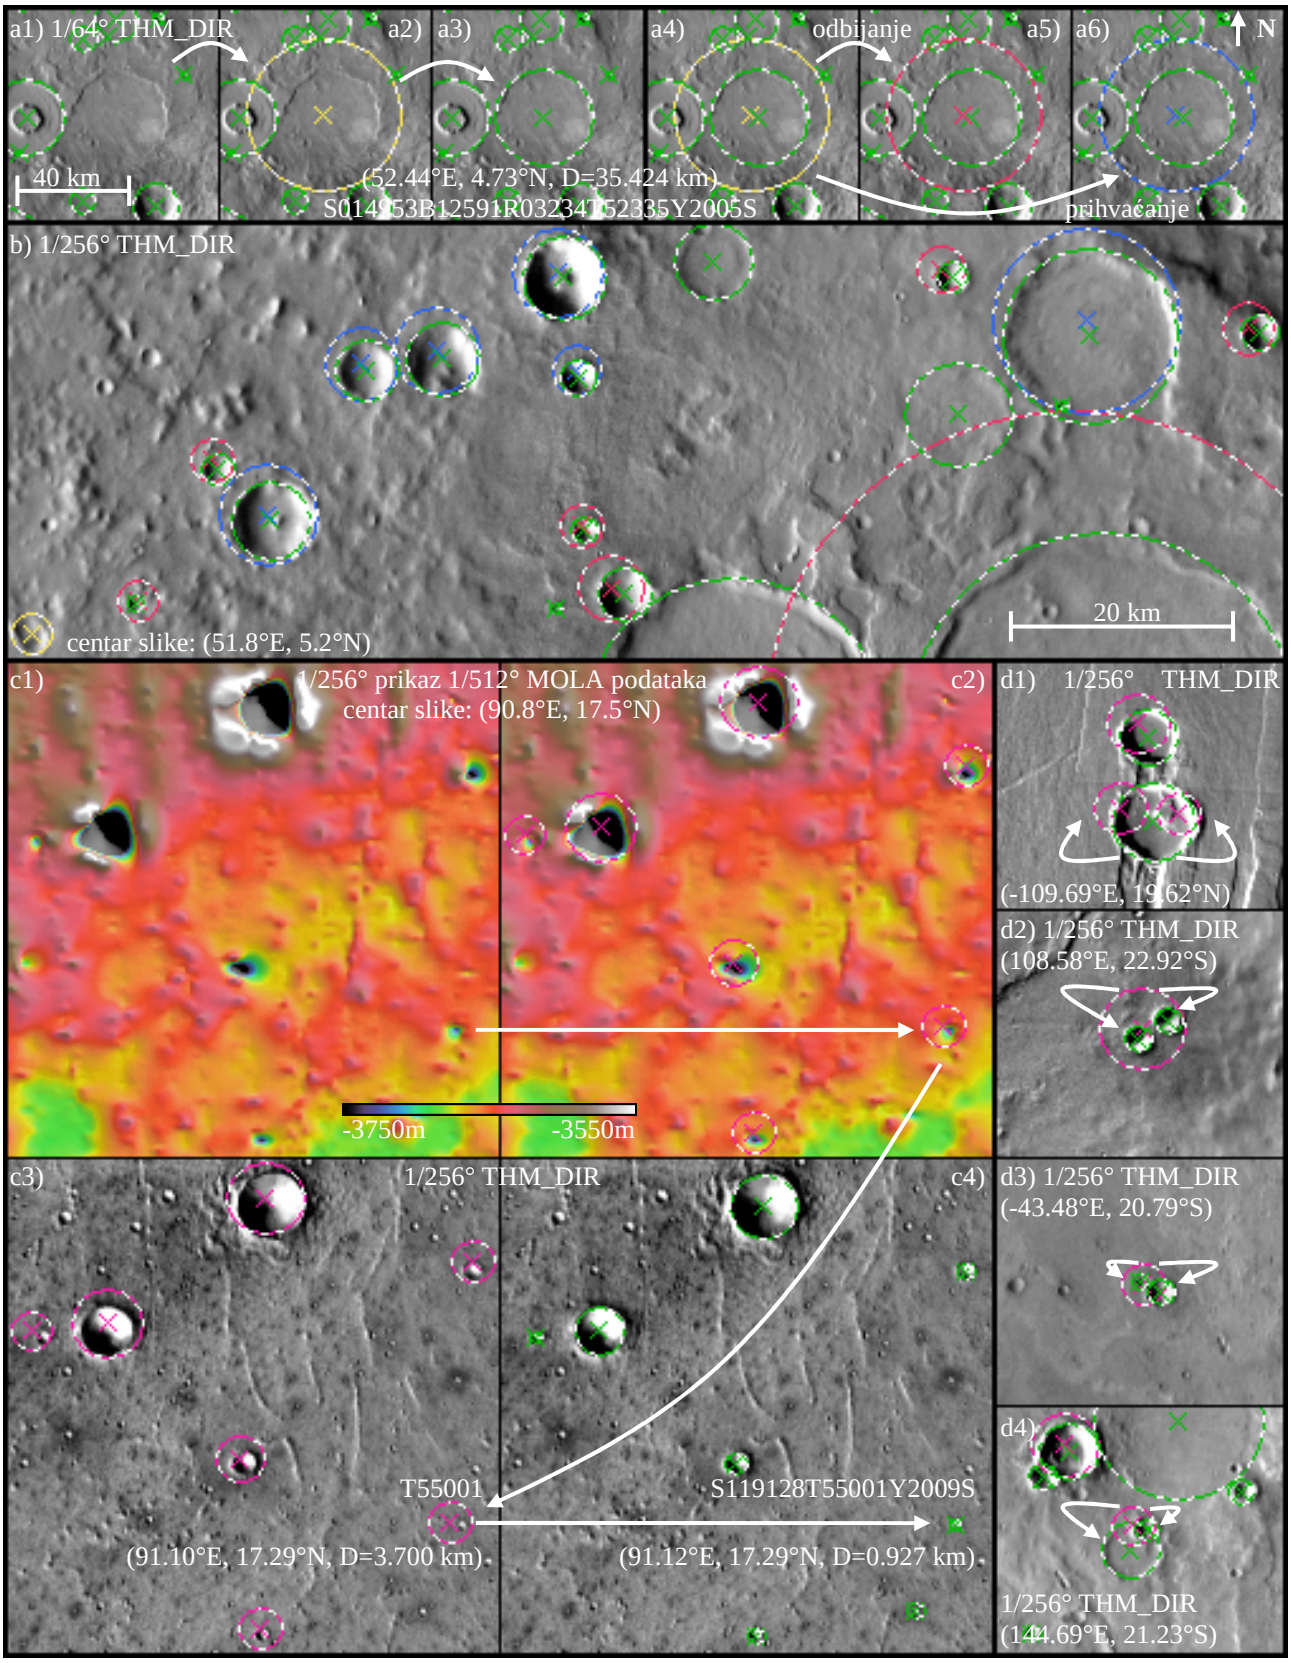
Stoga se definiralo prvo pravilo koje se temelji na veličini kratera. Lista mogućih uparivanja se kreira za svaki krater, koristeći kao uvjet $f_m < 6$. Vrijednost najmanjeg f_m-a koristi se za odbijanje svih parova s liste, ovisno o dijametru, ako je zadovoljeno jedno od sljedećeg:

- $D \geq 8$ km, a najmanji $f_m > 1$;
- 4 km $\leq D < 8$ km, a najmanji $f_m > 2$;
- $D < 4$ km, a najmanji $f_m > 3$.

Drugo pravilo se naknadno primjenjuje i odnosi se na kontekst, odnosno određivanje grupacija kratera, kako bi se poboljšala robusnost metode. U ovom koraku nova vrijednost se računa kao $f_{najmanji} = 2 \cdot f_m - 1$, i koristi za sprečavanje registracije bilo kojeg para s prethodno pripremljene liste (prvo pravilo) ako bilo koji od susjednih kratera ima f_m koji je manji od $f_{najmanji}$. Isto se provjerava i u suprotnom smjeru. Jedan smjer je uparivanje kratera iz kataloga koji je rezultat CDA-a s kraterima iz referentnog kataloga, a drugi uparivanje kratera iz referentnog kataloga s kraterima iz kataloga koji je rezultat CDA-a.

Na kraju drugog prolaza par s najmanjim f_m-om svake pojedine liste se uzima za registraciju. Pristup je provjeren korištenjem MA75919T kataloga i tada najdostupnijeg referentnog kataloga. Metoda niti jedan kratera nije pogrešno registrirala iz MA75919T u referentni katalog, što potvrđuje njezinu ispravnost. S druge strane je registrirala značajno više kratera nego prethodna metoda koja je bila temeljena samo na jednom prolazu i jednostavnom pravilu $f_m < 0.5$.

Slika 49 prikazuje kontekst korištenja metode, konkretne primjere iz kojih se vidi potreba za ovom metodom te neke karakteristične slučajeve koje metoda prepoznaje kako bi izbjegla pogrešne registracije. Dijelovi slike, (a1), (a2) i (a3), prikazuju uobičajen slučaj kada CDA detektira neki krater koji još nije katalogiziran, a korisnik mu korigira koordinate i dijametar prije registracije. Ako se sada taj krater nalazi u referentnom katalogu, a CDA detektira ponovo isti krater (a4), isti se ne mora prihvatiti za registraciju (a5) ako nas zanimaju samo oni krateri kojima je CDA precizno odredio koordinate i dijametar. No isti se može i prihvatiti za registraciju ako nas zanimaju i oni kandidati za kratere čije koordinate ili dijametar CDA nije precizno odredio. Na dijelu slike (b) prikazan je primjer za MA75919T katalog. Plavom bojom označeni su krateri koje može registrirati i inicijalna metoda za registraciju, a crvenom bojom oni krateri koje inicijalna metoda ne može registrirati dok metoda opisana u ovom potpoglavlju može. Kao što se vidi iz slike, radi se zaista o točnim detekcijama s neprecizno određenim koordinatama, odnosno dijametrima. Na dijelu slike (c) prikazani su najekstremniji slučajevi gdje je f_m svega neznatno manji od 3. Na dijelu slike (d) prikazani su slučajevi gdje se krateri ne registriraju, s obzirom na to da postoji više mogućih uparivanja. Ovakvih slučajeva nema puno pa je bolje da ih korisnik osobno pogleda i odluči koja registracija je ispravna.



Slika 49. Primjeri naprednog uparivanja kratera iz različitih kataloga. © 2008 Elsevier (Salamunićcar et al., 2011a).

8.4. Interaktivna metoda za provjeru i registraciju kratera u kataloge

Ova metoda nadogradnja je metode prethodno opisane u potpoglavlju 7.3., a razvijena je sa svrhom što učinkovitije obrade kataloga koje generiraju CDA-ovi. Metoda ubrzava postupak pregleda kandidata za kratere prilikom pregledavanja onih kojima je vjerojatnost da su krateri iznimno mala. Dok se ne počnu obrađivati i ti krateri, prethodna metoda je zadovoljavajuća, no kada se počnu obrađivati, metoda može značajno ubrzati obradu. Metoda je definirana sljedećim koracima:

(1) učitava se XML datoteka s kraterima koji su već registrirani i koje je tek potrebno registrirati, kao i pripadni globalni optički mozaici, s tim da se za topografske podatke odmah učitava unaprijed pripremljena slika kako bi se dovoljno brzo prikazala na ekranu;

(2) korisnik bira hoće li preostale kandidate za kratere pregledavati od većih prema manjima, od sjevera prema jugu ili obrnuto, i slično;

(3) korisnik pokreće pripremu za registraciju kojom se automatski pronalazi prvi sljedeći kandidat za kratere te se svi pripadni globalni optički mozaici pomiču na lokaciju kandidata za krater, traži se najbliži neregistrirani krater u LLR prostoru korištenjem formule (1), računa se za koliko se slikovnih elemenata u smjeru dužine i širine slike moraju pomaknuti globalni mozaici na temelju informacije o najbližem registriranom krateru, i za toliko se pomiču te se korisniku prikazuje aktivni optički mozaik s kružnicom pridijeljenom kandidatu za krater;

(4) nakon prethodnog koraka u prikazanom dijelu slike može biti jedan ili više kandidata za kratere, korisnik pokazivačem miša prilazi onom kojeg želi prvog obraditi, a za vrijeme dok pokazivač miša prilazi kandidatu za krater, pridijeljena kružnica se briše i ponovo prikazuje kako bi korisnik mogao bolje vidjeti dio aktivnog globalnog mozaika gdje se nalazi kandidat za krater;

(5) ako korisnik smatra da se radi o pogrešnom unosu, pokazivačem miša se udaljuje od kandidata za krater i on se samim time automatski briše;

(6) u protivnom, ako smatra da se radi o točnom unosu, korisnik može odabrati krater i pomaknuti mu pridijeljenu kružnicu, kako bi bolje bio registriran sa slikom, a može i povećati ili smanjiti njezin radijus, a pritom može mijenjati i aktivni globalni mozaik koji se prikazuje;

(7) kad je korisnik zadovoljan poravnanjem kružnice i pozadinske slike, registrira krater, a pritom se, ako korisnik nije pogledao sve globalne mozaike, isti prikazuju kako bi korisnik ili nastavio s registracijom daljnjih kratera ili dodatno pomaknuo neke od ostalih globalnih mozaika radi što boljeg poklapanja s kružnicom pridijeljenom krateru koji se registrira, također se u ovom koraku generira ime novoregistriranog kratera koje u sebi sadrži i ime kataloga te identifikator unutar tog kataloga, kako bi za svaki krater znali koji od kataloga je njegov izvor;

(8) ako na slici ima još kratera, korisnik može nastaviti registraciju kroz ponavljanje koraka od (4) do (7);

(9) nakon što korisnik obradi sve kratere na dijelu globalnog mozaika koji mu je prikazan, ponavlja korake od (3) do (8);

(10) rezultati obrade snimaju se u XML datoteku.

Osnovna razlika ove i prethodne metode (opisane u potpoglavlju 7.3.) je mogućnost pregledavanja i brisanja velikog broja pogrešnih detekcija bez korištenja tipkovnice. Nakon što se naiđe na točnu detekciju, može se izvršiti registracija kao u prethodnom slučaju. Ovime se znatno ubrzava sam proces obrade. Da ova metoda nije bila razvijena, moglo bi se ručno pregledati puno manje kandidata za kratere, pa bi time i katalozi koji su rezultat ovoga rada sadržavali puno manje istih.

8.5. Površina ispod A-ROC krivulje i ostale mjere za vrednovanje

Analizom prethodnih radova, kako je pokazano u poglavlju 2, različiti autori koristili su raznolike metode za vrednovanje CDA-ova. Kako bi se kroz ovaj rad što učinkovitije mogli koristiti napravljeni referentni katalozi kao što je MA57633GT, te metoda za uparivanje kratera iz različitih kataloga, podržane su vrlo raznolike mjere za vrednovanje CDA-ova.

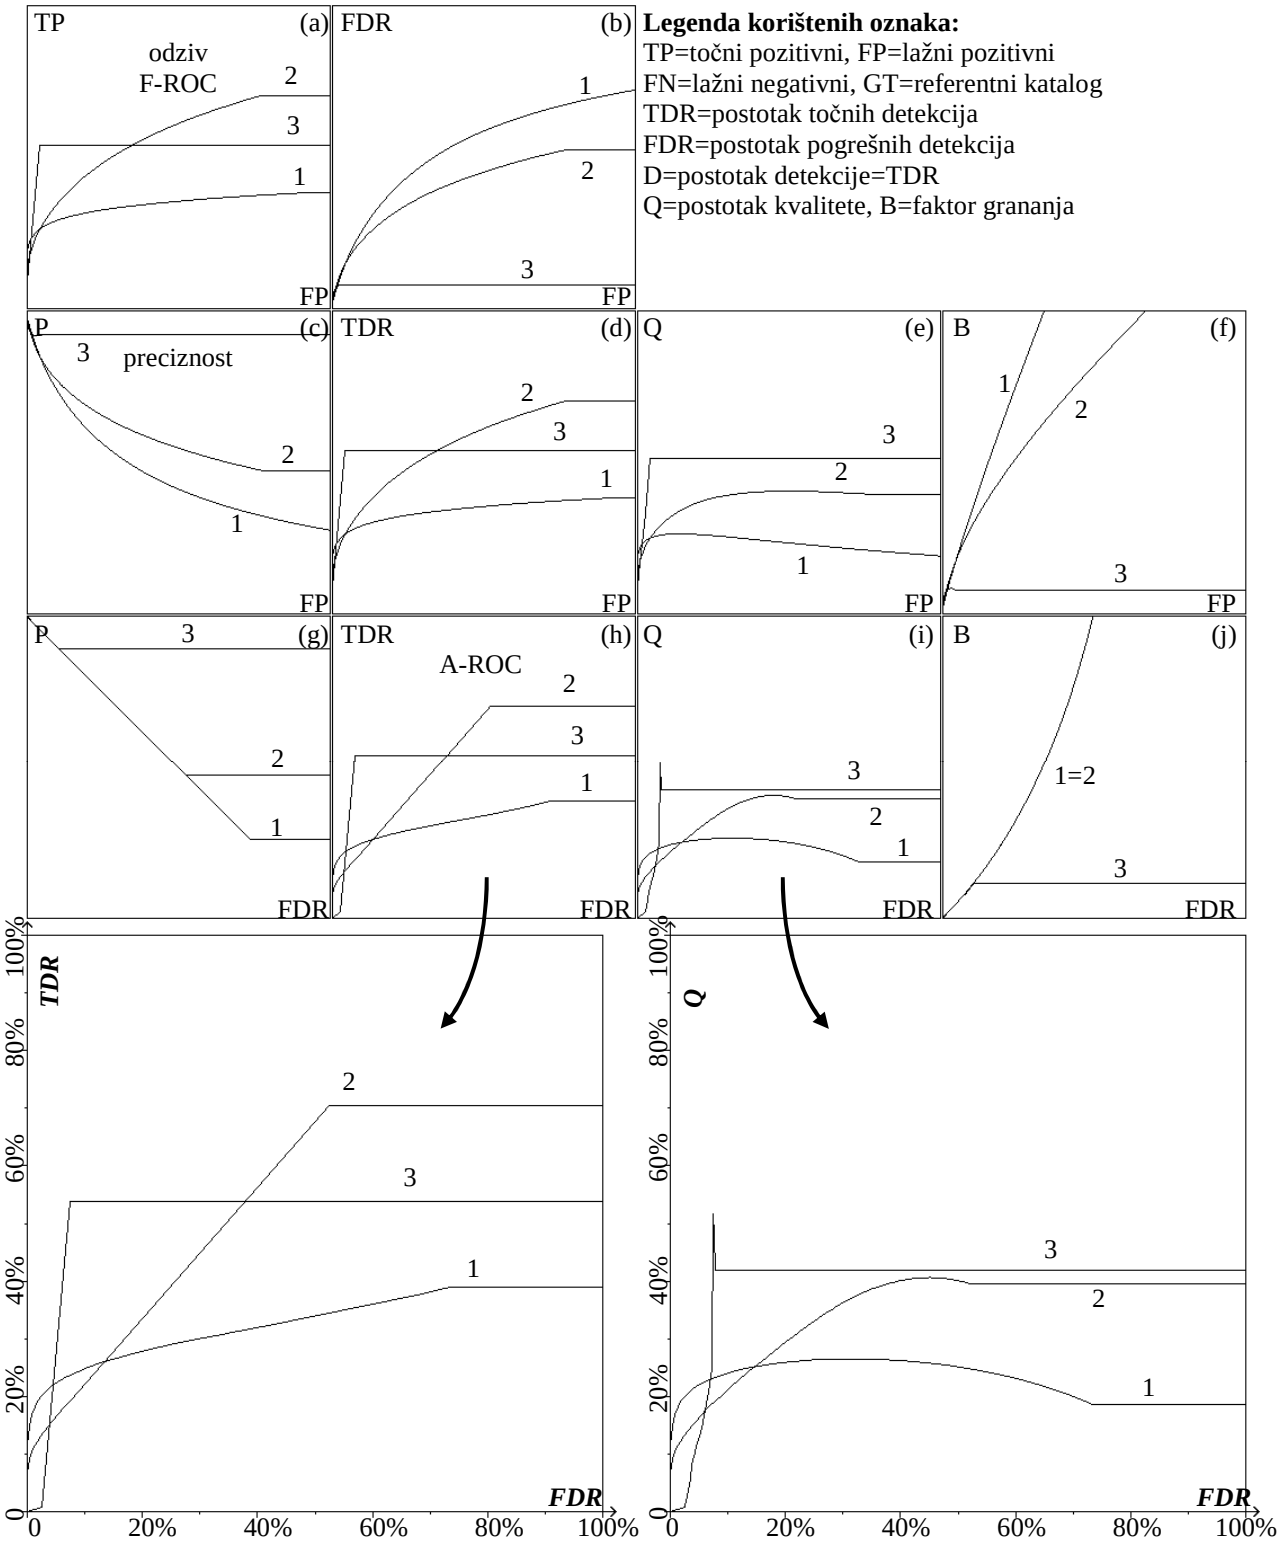
Tablica 7 prikazuje korištene definicije i podržane grafove. Za CDA-ove se ne mogu definirati točni negativni primjeri (TN), pa time niti ROC krivulja u skladu s njezinom definicijom. Stoga se u inicijalnom okruženju za razvoj CDA-ova koristila F-ROC krivulja. Međutim, A-ROC krivulja sličnija je ROC krivulji, pa je ona bolji odabir za vrednovanje CDA-ova. Horizontalna os A-ROC krivulje umjesto broja sadrži postotak pogrešnih detekcija, a vertikalna os umjesto broja sadrži postotak točnih detekcije. Njezine obje osi idu od 0 do 100%, pa se ne mora kao kod F-ROC krivulje odabrati područje pogrešnih detekcija o kojem ovisi vrednovanje. S druge strane, svi zaključci temeljeni na odnosu dvije F-ROC krivulje ili površini ispod njih vrijede i za A-ROC. Stoga su se F-ROC usporedbe vremenom zamjenjivale A-ROC usporedbama. Posebno važna je i dodatna krivulja *Q*, odnosno krivulja kvalitete. Ona je uobičajeno u prvom dijelu rastuća, a u drugom padajuća. Maksimum *Q* krivulje može se koristiti kao optimalan kriterij za korištenje CDA-a, odnosno za definiciju praga pridijeljene vjerojatnosti kandidata za kratere.

Tablica 7. Korištene definicije i podržani grafovi prilikom vrednovanja CDA-ova.

korištene definicije	**podržani grafovi**
HR = (horizontalno područje) VR = (vertikalno područje)	F-ROC (odziv, F-ROC) [TP / FP] (6a)
TP = (točni pozitivni) FP = (lažni pozitivni) FN = (lažni negativni)	FDR (postotak pogrešnih detekcija) [FDR / FP] (6b)
GT = (referentni katalog) = TP+FN	P (preciznost) [P / FP] (6c)
F-ROC[0 do HR, 0 do VR] = odziv = TP/(TP+FN) = TP/GT	TDR (postotak točnih detekcija, D (postotak detekcije)) [TDR / FP] (6d)
P[0 to HR, 0 to 100%] = preciznost = TP/(TP+FP)	Q (postotak kvalitete) [Q / FP] (6e)
FDR[0 to HR, 0 to 100%] = FP/(TP+FP)	B (faktor grananja) [B / FP] (6f)
TDR[0 to HR, 0 to 100%] = TP/(TP+FN) = TP/GT	P/FDR [P / FDR] (6g)
D[0 to HR, 0 to 100%] = TP/(TP+FN)	A-ROC [TDR / FDR] (6h)
Q[0 to HR, 0 to 100%] = TP/(TP+FP+FN) = TP/(GT+FP)	Q/FDR [Q / FDR] (6i)
B[0 to HR, 0 to 100%] = FP/TP	B/FDR [B / FDR] (6j)
P/FDR[0 to 100%, 0 to 100%]	
A-ROC = TDR/FDR[0 to 100%, 0 to 100%]	
Q/FDR[0 to 100%, 0 to 100%]	
B/FDR[0 to 100%, 0 to 100%]	

Slika 50 prikazuje grafove navedene u prethodnoj tablici. Korisnik odabire XML datoteku s katalogom koji je rezultat detekcija CDA-a, te referentni katalog kao što je primjerice MA57633GT. Nakon toga se sve vrijednosti izračunaju i svi grafovi nacrtaju pomoću aplikacije

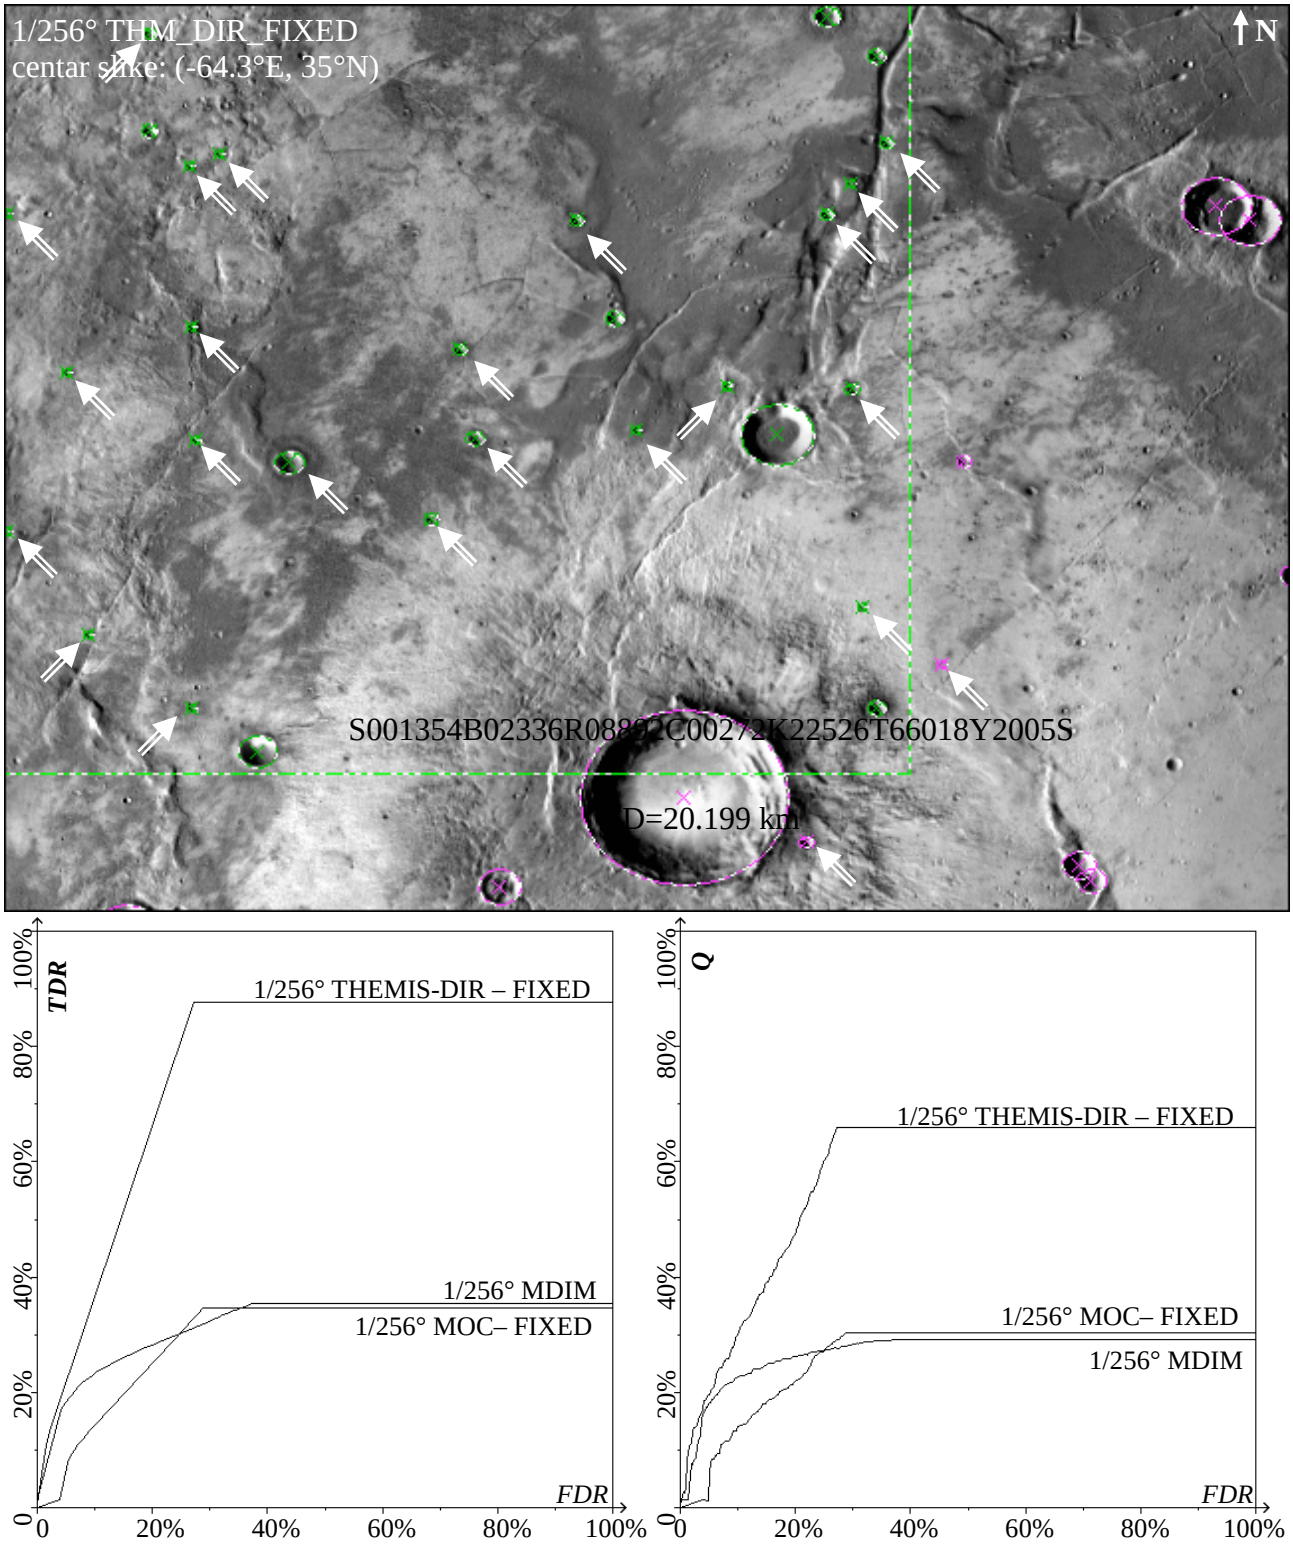
Topolyzer koja je razvijena u ovome radu. Korisnik također može birati iznos mjere do kojeg će se krateri u LLR prostoru uparivati, pa ako izabere $f_m < 0.5$, rezultati su isti kao i kod metode za registraciju iz prethodnog, 7. poglavlja, a ako odabere $f_m < 3$, iz ovog, 8. poglavlja (8.3.).



Slika 50. Podržana vrednovanja CDA-ova. © 2008 Elsevier (Salamunićcar et al., 2011a).

Okruženje je dodatno prošireno i za vrednovanje CDA-ova koji kratere detektiraju iz globalnih optičkih slika. Definirana su četiri područja, i ista su podijeljena u 522 slike (174 po svakom korištenom optičkom mozaiku slika) veličine 512x512 slikovnih elemenata s preklapanjem

od 25%, potom su se koristili rezultati (kandidati kratera) CDA-a razvijenog za detekciju kratera iz optičkih slika (Bandeira et al., 2007b), te proširio referentni katalog s onim kraterima koji prethodno nisu bili u njemu, a točne su detekcije. Slika 51 prikazuje rezultate vrednovanja i proširenja referentnog kataloga novopronađenim kraterima. Ovim vrednovanjem se ne uspoređuje više različitih CDA-ova, nego više globalnih optičkih mozaika. Time procjenjujemo koliko se kratera iz kojeg može uspješno detektirati koristeći navedeni CDA, no princip usporedbe je isti.



Slika 51. Primjer vrednovanja CDA-a koji kratere detektira iz optičkih slika. © 2008 Elsevier (Salamunićcar et al., 2011a).

8.6. Postupak usporedbe algoritama za detekciju kratera

Sve prethodno razvijeno i pokazano kroz ovo poglavlje osigurava optimalne usporedbe algoritama za detekciju kratera. Slika 52 prikazuje postupak usporedbe.

Korištenje referentnog kataloga MA57633GT važno je jer sadrži samo one kratere koji su se ručno katalogizirali, bez korištenja CDA-ova. Time je zajamčena objektivnost usporedbe dva CDA-a. Međutim, s obzirom na to da postoje mnogi krateri koji nisu u tom katalogu, vrednovanju kojem je prije svega osnovni cilj objektivnost dodano je i vrednovanje kojem je osnovni cilj točnost.

Da bi vrednovanje bilo što točnije, referentni katalog mora biti što potpuniji. U tom se smislu rezultati CDA-a koriste za proširenje referentnog kataloga, te se nakon toga CDA vrednuje proširenim katalogom.

Na prvi pogled čini se da je ovo vrednovanje neispravno, jer se među ostalim rezultat CDA-a koristi kako bi se on sam vrednovao. Međutim, treba uzeti u obzir da se kandidati za kratere koje CDA predloži ne dodaju automatizmom u referentni katalog. Prvo se napravi automatska analiza, kako bi se vidjelo koji kandidati za kratere se već nalaze u referentnom katalogu, a koji ne. Oni kandidati za kratere koji se ne nalaze u referentnom katalogu, ručno se provjeravaju. Pritom osoba koja radi na novom referentnom katalogu u njega dodaje samo one kratere za koje je provjerom utvrdila da su zaista krateri. Na taj način se samo točne detekcije dodaju u referentni katalog, te svaki novi zapis u referentnom katalogu ima dva nezavisna izvora koji potvrđuju da se zaista radi o krateru (jedan je CDA, a drugi osoba koja registrira kratere u referentni katalog). Ovaj način ne preferira jedan CDA u odnosu na drugi. Rezultati oba se obrađuju identično, gdje oba mogu proširiti referentni katalog, pri čemu nije važan redoslijed kojim se obrađuju.

Ove metode za vrednovanje mogu se koristiti kod CDA-ova koji obrađuju globalne podatke, kao i kod onih koji mogu obraditi samo pojedine slike. Također se ove metode mogu koristiti i kod CDA-ova koji koriste topografske slike.

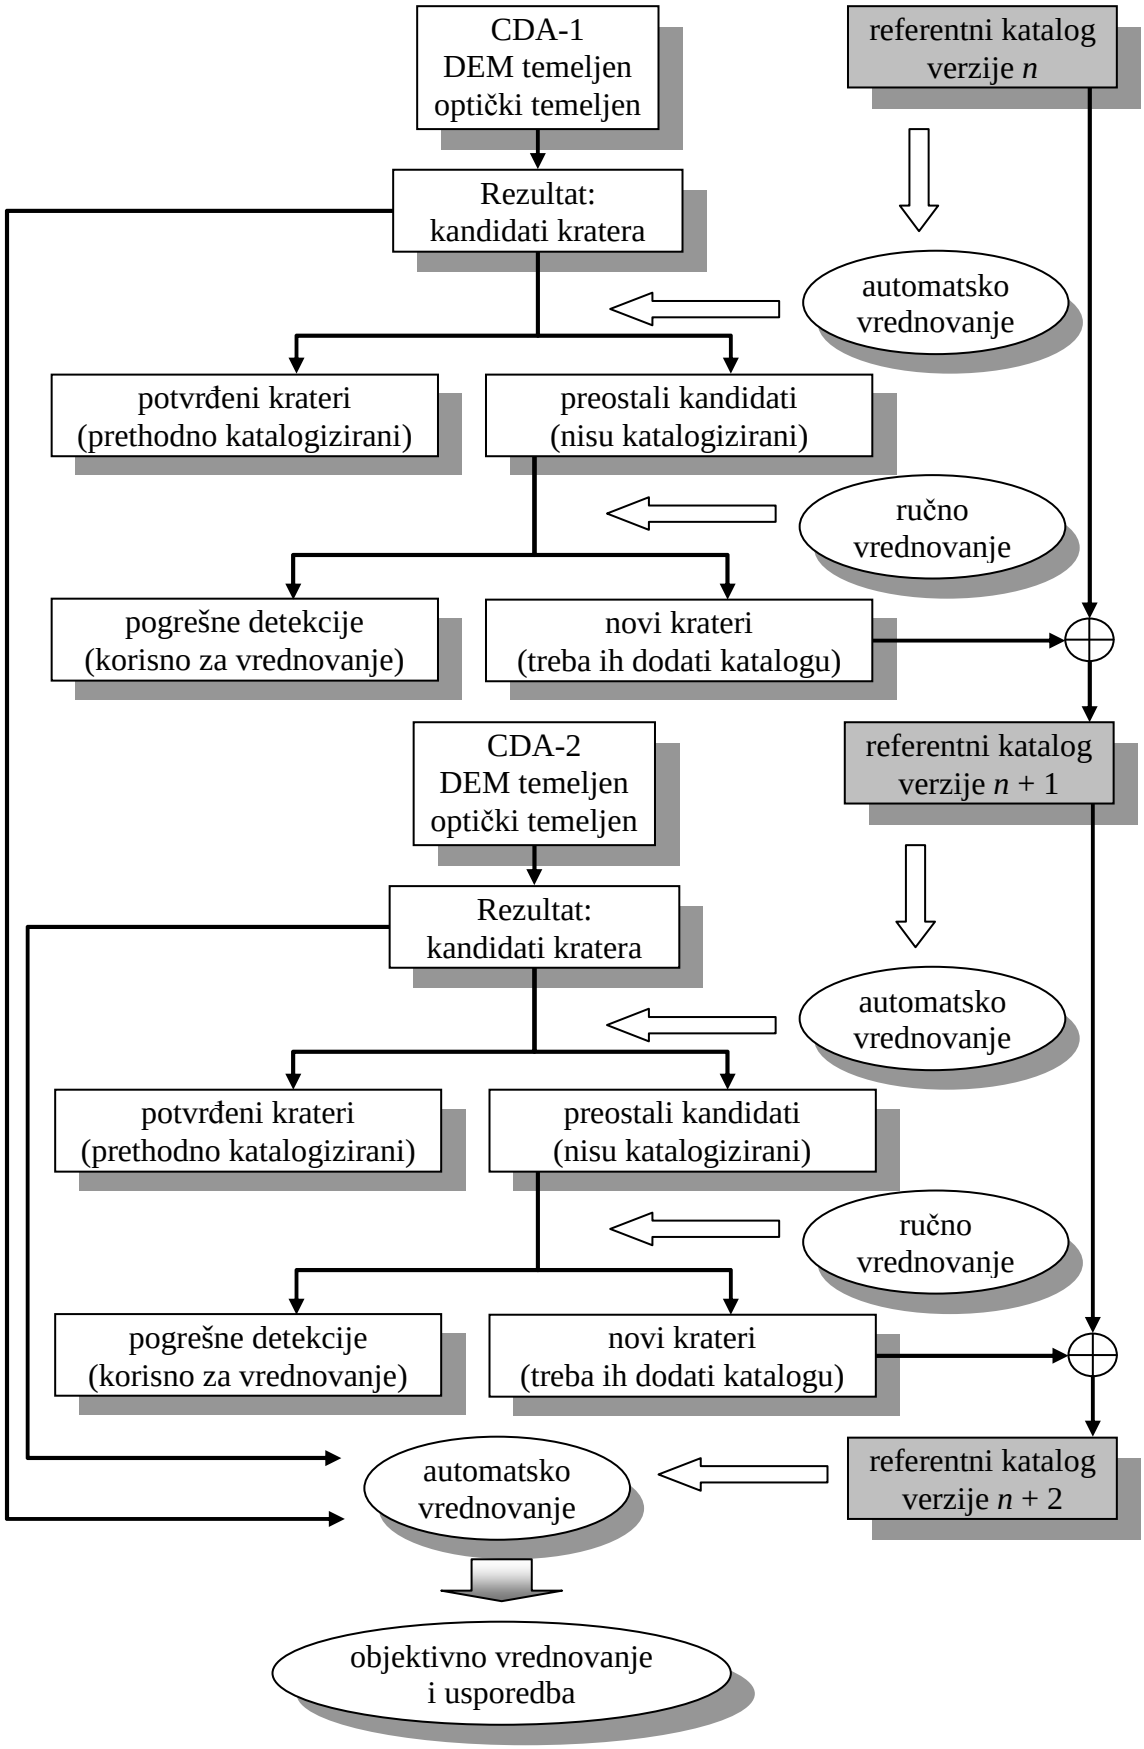
Samim time je osigurana okolina za vrednovanje CDA-ova, koja uz objektivnost vrednovanja osiguranu referentnim katalogom MA57633GT, pruža točnost vrednovanja koju osigurava trenutno najpotpuniji referentni katalog.

Ovo okruženje korišteno je za analizu CDA-a temeljenog na interpolaciji, kako bi se usporedio sa Stepinskovim i Urbachovim (2008) CDA-om koji je rezultirao MA75919T katalogom. Cilj je ispitivanje smjera u kojem se CDA može dodatno poboljšati. To nije bilo moguće postići s prethodnim okruženjem za razvoj CDA-ova. Rezultati vrednovanja pokazali su da treba smanjiti broj pogrešnih detekcija. To je postignuto CDA-om koji, uz sve module koje imaju temeljni i interpolacijski CDA, dodatno koristi i strojno učenje.

Ovakva analiza svojstava različitih CDA-ova ne bi bila moguća bez ove metodologije, pa time ni razvoj CDA-a ovoga rada, temeljenog na primjeni strojnog učenja. Time se na praktičnom primjeru pokazala korisnost metoda razvijenih u ovom poglavlju, kako za vrednovanje CDA-ova, tako i za određivanje smjernica njihovog daljnjeg razvoja.

Također, ovdje razvijena metodologija može se koristiti i za usporedbu različitih topografskih i optičkih podataka, kako bismo procijenili količinu kratera koje CDA-ovi mogu detektirati. Primjer navedenog također je prikazan na prethodnoj slici.

Time se pokazalo da je razvijena metodologija višestruko upotrebljiva, kako prilikom analize CDA-ova i određivanja smjernica njihovog daljnjeg razvoja, tako i prilikom analize podataka koje CDA-ovi koriste u svom radu.



Slika 52. Postupak usporedbe CDA-ova. © 2008 Elsevier (Salamunićcar et al., 2011a).

8.7. Zaključak

Rezultati proširenja okruženja kojim se osigurava sve potrebno za što točnije vrednovanje CDA-ova su (Salamunićcar et al., 2011a): (1) metoda za uparivanje kratera iz različitih kataloga, temeljna na kontekstu; (2) interaktivna metoda za provjeru i registraciju kratera u kataloge; (3) raznolikost podržanih mjera za vrednovanje; (4) postupak usporedbe algoritama za detekciju kratera, kako iz topografskih, tako i onih koji koriste optičke slike.

Uz navedeno koristile su se i globalne topografske slike u višoj horizontalnoj rezoluciji od prethodno korištenih (1/512° MOLA podaci), kao i globalni optički mozaici (1/256° THEMIS-DIR, 1/256° MDIM i 1/256° MOC). Optički mozaici su dodatno obrađeni: (1) interpolacijom vrijednosti koje nedostaju na temelju vrijednosti susjednih slikovnih elemenata; (2) pojačavanjem kontrasta; i (3) podešavanjem svjetline. Time je osigurana metodologiju koja osigurava i objektivnost (temeljenu na MA57633GT katalogu) i točnost (temeljenu na još potpunijim katalozima koji će biti opisani u sljedećom poglavlju) u vrednovanju CDA-ova.

Objektivnošću i točnošću vrednovanja stvoreni su svi preduvjeti da se CDA-ovi mogu vrednovati i analizirati, sa svrhom određivanja daljnjih smjernica njihovog razvoja. Isto je korišteno i za razvoj metoda za detekciju kratera iz topografskih slika ovoga rada (temeljna metoda, metoda koja dodatno koristi interpolaciju, metoda koja dodatno koristi i strojno učenje), čije vrednovanje i usporedba s rezultatima drugih su dani u sljedećom poglavlju.

9. EKSPERIMENTALNI REZULTATI I VREDNOVANJE METODA ZA DETEKCIJU KRATERA

U ovom poglavlju opisuju se eksperimentalni rezultati i vrednovanje metoda za detekciju kratera ovoga rada te se daju primjeri preliminarnih istraživanja njihove moguće primjene u budućim znanstvenim istraživanjima, i to kroz sljedeća potpoglavlja:

- 9.1. Optimalne vrijednosti parametara;
- 9.2. Rezultirajući katalozi Marsa s 132 843 i Mjeseca s 60 645 kratera;
- 9.3. Vrednovanje metoda za detekciju kratera;
- 9.4. Strojna detekcija i globalni katalog kratera Fobosa s 1102 kratera;
- 9.5. Testni poligon za vrednovanje laboratorijskih kratera;
- 9.6. Detekcija kratera Mjeseca iz topografije rekonstruirane iz optičkih slika;
- 9.7. Strojna detekcija kratera Venere;
- 9.8. Strojna detekcija kratera Zemlje;
- 9.9. Ukupni doprinos metoda za detekciju u katalogizaciji kratera.

U potpoglavlju 9.1. daju se vrijednosti optimalnih parametara metoda za detekciju kratera ovoga rada. U potpoglavlju 9.2. opisuje se korištenje metoda za detekciju kratera i njihovu obradu prilikom katalogizacije kratera, pri čemu su rezultat najpotpuniji javno dostupni katalozi Marsa i Mjeseca. U potpoglavlju 9.3. opisuje se vrednovanje metoda za detekciju kratera ovoga rada, korištenjem raznih referentnih kataloge, podataka, metoda za uparivanje kratera iz različitih kataloga te se daje usporedba s CDA-ovima drugih autora. U potpoglavlju 9.4. opisuju se preliminarni rezultati detekcije i katalogiziranja kratera Fobosa. U potpoglavlju 9.5. opisuju se preliminarni rezultati okoline za vrednovanje laboratorijskih kratera, pri čemu se koriste metode za detekciju kratera ovoga rada. U potpoglavlju 9.6. opisuju se preliminarni rezultati okoline za rekonstrukciju topografskih slika iz optičkih, kako bi se za detekciju kratera mogle koristiti metode ovoga rada. U potpoglavljima 9.7. i 9.8. opisuju se preliminarni koraci u istraživanju mogućnosti korištenja metoda ovoga rada za detekciju kratera Venere i Zemlje. Naposljetku se u potpoglavlju 9.9. daje pregled ukupnog doprinosa metoda za detekciju kratera ovoga rada u katalogizaciji kratera.

9.1. Optimalne vrijednosti parametara

Optimalne vrijednosti parametara CDA-ova ovoga rada izračunate su okolinom za razvoj CDA-ova. Ista se vremenom proširivala, kako sve novijim i potpunijim referentnim katalozima, tako i sve potpunijim i boljim globalnim slikama te metodama za vrednovanje rezultata. Vrijednosti parametara koji su korišteni prilikom prezentacije rezultata detekcije kratera metoda ovoga rada te prilikom vrednovanja tih istih metoda, opisane su sljedećim potpoglavljima:

- 9.1.1. Parametrizacija temeljne metode za detekciju kratera;
- 9.1.2. Parametrizacija metode za detekciju kratera temeljene na interpolaciji;
- 9.1.3. Parametrizacija metode za detekciju kratera temeljene na strojnom učenju.

9.1.1. Parametrizacija temeljne metode za detekciju kratera

Optimalne vrijednosti za fiksne parametre (korisnik ih uobičajeno ne mijenja, a nisu se ni mijenjale tijekom ovoga rada) su: por=148, cpp_1=0.74, $vcpp_1$=0.66, rpp_1=0.64, rpp_2=3.2, rpp_3=0.62, rpp_4=1.0, $cppp_1$=0.17, $cppp_2$=5.5, $cppp_3$=0.05, $cppp_4$=1.0, i *radial-calibration*={0.00, 0.10, 0.20, 0.30, 0.40, 0.50, 0.56, 0.74, 0.82, 0.85, 1.00}. Parametrizacija radijalne kalibracije koristi se unutar metode koja određuje područje gdje je krater očuvan, dok su svi ostali parametri navedeni u prethodnim formulama.

Područja u kojima se koriste drugi parametri su: $2 \leq r_1 \leq 5$; $10 \leq r_2 \leq 28$; $0 \leq$ *vrijednosti-kalibracije-kataloga* ≤ 1, s tim da im vrijednosti moraju biti rastuće.

CDA temeljen na Cannyjevom (1986) detektoru ruba daje optimalne rezultate za: *kernel*=3 (veličina korištene maske), σ=0.25 (definira Gaussovu funkciju) i $grad_1$=$grad_2$=30 (gradijenti u ‰). CDA temeljen na Shen-Castanovom (1992) detektoru ruba daje optimalne rezultate za njegove parametre: *ratio*=0900, *smoothing_factor*=0750, *window_size*=3, *do_hysteresis*=1. U primjeni Cannyjev detektor ruba se pokazao boljim po većini kriterija, dok se Shen-Castanov detektor ruba pokazao boljim u detekciji nekih kratera koje Cannyjev detektor ruba nije uspio detektirati. Svi ostali korišteni detektori ruba pokazali su se lošijima i u ovome su radu korišteni kako bi se pokazalo da su Cannyjev i Shen-Castanov detektor ruba bolji. S druge strane, metode za detekciju kratera temeljene na Cannyjevom i Shen-Castanovom detektoru ruba primijenjene su prilikom katalogizacije kratera.

S obzirom na to da detektiranih kratera koji su manji od 1 km u dijametru ima vrlo malo te da su oblikom gotovo istovjetni kraterima koji su veliki 1 km u dijametru, za njih nije potrebna posebna kategorija. Također isto vrijedi i za kratere koji su veći od 128 km u dijametru. Stoga se navedeno područje dijeli tako da se svaki krater ovisno o dijametru razvrstava u jednu od sljedećih 15 kategorija: (1) $D < 2^{0.5}$ km; (2) $2^{0.5}$ km $\leq D < 2$ km; (3) 2 km $\leq D < 2 \cdot 2^{0.5}$ km; (4) $2 \cdot 2^{0.5}$ km $\leq D < 4$ km; (5) 4 km $\leq D < 4 \cdot 2^{0.5}$ km; (6) $4 \cdot 2^{0.5}$ km $\leq D < 8$ km; (7) 8 km $\leq D < 8 \cdot 2^{0.5}$ km; (8) $8 \cdot 2^{0.5}$ km $\leq D < 16$ km; (9) 16 km $\leq D < 16 \cdot 2^{0.5}$ km; (10) $16 \cdot 2^{0.5}$ km $\leq D < 32$ km; (11) 32 km $\leq D < 32 \cdot 2^{0.5}$ km; (12) $32 \cdot 2^{0.5}$ km $\leq D < 64$ km; (13) 64 km $\leq D < 64 \cdot 2^{0.5}$ km; (14) $64 \cdot 2^{0.5}$ km $\leq D < 128$ km; (15) 128 km $\leq D$.

Za kalibraciju kataloga (*catalogue-calibration*) u ovome radu su se koristile četiri serije optimalnih vrijednosti, ovisno o tome koji referentni katalog i kriterij se koristio za traženje istih:

- *serija-a* je: {0.10,0.10,0.10,0.10,0.10,0.10,0.48,0.71,0.81,0.84,0.95,0.96,0.96,1.00,1.00};
- *serija-b* je: {0.41,0.41,0.41,0.41,0.52,0.61,0.74,0.92,0.99,1.00,1.00,1.00,1.00,1.00,1.00};
- *serija-c* je: {0.38,0.38,0.38,0.38,0.54,0.61,0.72,0.92,0.99,0.99,1.00,1.00,1.00,1.00,1.00};
- *serija-d* je: {0.35,0.35,0.35,0.37,0.50,0.61,0.72,0.92,0.99,0.99,1.00,1.00,1.00,1.00,1.00}.

Serija-a pokazala se optimalnom pri korištenju MA17582GT kataloga i 1/64° MOLA podataka (Salamunićcar i Lončarić, 2010b). *Serija-b* pokazala se optimalnom pri korištenju MA57633GT kataloga i 1/128° MOLA podataka (Salamunićcar i Lončarić, 2010b). *Serija-c* pokazala se optimalnom pri korištenju 1/128° MOLA podataka, MA115225GT kataloga i novog algoritma za uparivanje kratera iz odziva CDA-a s referentnim katalogom (Lončarić i Salamunićcar, 2010). *Serija-d* pokazala se optimalnom pri korištenju maksimalne vrijednosti postotka točnih detekcija, CDA-a temeljenog na interpolaciji i referentnog kataloga s 130 234 kratera (verzija dostupna neposredno prije nego što je dovršen MA130301GT). Parametri *serije-d* koristili su se za zadnje proširenje kataloga, što je rezultiralo: (1) MA132843GT katalogom kratera Marsa (Salamunićcar et al., 2011f); (2) LU60645GT katalogom kratera Mjeseca koji je napravljen korištenjem LALT i LOLA topografskih podataka (Salamunićcar et al., 2011f); (3) PH504GT i PH1102GT kataloga kratera Fobosa (Salamunićcar et al., 2011c, 2011d). Parametri *serije-d* dodatno su korišteni u analizi laboratorijskih kratera interpolacijskim CDA-om (Vojković et al., 2010a, 2010b; Salamunićcar et al., 2010b; Vinković et al., 2011) te za istraživanja mogućnosti detekcije kratere iz topografskih podataka dobivenih obradom optičkih slika (Lončarić et al., 2011). *Serija-d*, što vidimo iz navedenog, imala je brojne primjene, bez potrebe za dodatnim optimizacijama. Time će se vrlo vjerojatno moći koristiti i u budućem radu, bez potrebe za dodatnim optimizacijama.

Kao optimalne vrijednosti za r_1 i r_2 su se početno koristili 5 i 10, dok se nakon svih izmjena pokazalo da se za najbolje rezultate r_1 može smanjiti na 2, a r_2 povisiti na 28.

9.1.2. Parametrizacija metode za detekciju kratera temeljene na interpolaciji

Parametrizacija metode za detekciju kratera temeljene na interpolaciji koristi sve one parametre koje koristi temeljna metoda za detekciju kratera, uz neke dodatne parametre.

Prvi dodatni parametar određuje koristi li se interpolacija (*q=1*) ili ne (*q=0*). Ime parametra dolazi od pojma četverostruke preciznosti (*quad-precision*), s obzirom na to da se kod interpolacije koriste četiri vrijednosti za izračunavanje vrijednosti na lokaciji interpolacije.

Za parametrizaciju su se koristili i sljedeći radijusi planetarnih tijela: za Mars 3390 km, za Mjesec 1737.4 km, za Fobos 11.1 km, za Veneru 6051 km i za Zemlju 6371 km.

9.1.3. Parametrizacija metode za detekciju kratera temeljene na strojnom učenju

Osnovna je razlika između parametrizacije metode za detekciju koja koristi strojno učenje te prethodne dvije metode što sama parametrizacija strojnog učenja nije dana u ulaznoj XML datoteci. Ona je definirana prilikom dohvata značajki strojnog učenja, izvršavanjem skripte koja poziva metodu strojnog učenja te integracijom rezultata strojnog učenja. Sva ostala parametrizacija ista je kao i u prethodno opisanoj metodi koja koristi interpolaciju.

Tablica 5 daje pregled značajki koje se mogu koristiti pri strojnom učenju, odnosno koje su se koristile u dva koraka (serija 1 i serija 2). Ako se parametri prve serije primjerice označe slovom *R*, a druge slovom *S*, tada se ta ista slova navode i prilikom integracije rezultata strojnog učenja. Tablica 10, koja se nalazi u prilogu rada, prikazuje skripte koje je pritom potrebno pokrenuti.

Skripte *R1* i *R2* napisane su za paralelno izvršavanje, kako bi ukupno vrijeme potrebno za izvršenje na dvojezgrenim ili višejezgrenim računalima bilo dva puta kraće. Optimizacija s ciljem dodatnog skraćenja potrebnog vremena za izvršenje nije se dodatno razmatrala zbog značajnog korištenja memorije kod najvećeg mogućeg podskupa atributa za učenje. No princip prikazan ovdje lako bi se mogao generalizirati u svrhu još bržeg izračunavanja. Skripte su optimizirane korištenjem LIBSVM i LIBLINEAR biblioteka (Lin, 2010), kako bi se dobili što bolji rezultati prilikom procjene vjerojatnosti da je detektirani objekt krater. Ukupno vrijeme učenja i predikcije je oko 5 sati za LIBSVM i oko 5 minuta za LIBLINEAR.

9.2. Rezultirajući katalozi Marsa s 132 843 i Mjeseca s 60 645 kratera

Postoji puno objavljenih radova o detekciji kratera, kao što je opisano u poglavlju 2, no postoji svega nekoliko CDA-ova koji su, kako je opisano u dostupnim publikacijama, korišteni u praksi: (1) Stepinskov i Urbachov (2008) CDA za topografske slike, koji je rezultirao MA75919T katalogom; (2) Stepinskov et al. (2009) CDA za topografske slike, kojim je pokazano da u *Terra Cimmeria* dijelu Marsa krateri imaju manji omjer dubine i dijametra, što implicira postojanje leda u tlu; (3) Bandeirov et al. (2007b) CDA za optičke slike, koji je korišten prilikom izrade MA130301GT kataloga kratera Marsa (Salamunićcar et al., 2011a) te PH504GT i PH1102GT kataloga kratera Fobosa (Salamunićcar et al., 2011c, 2011d); (4) CDA-ovi ovoga rada, za topografske slike. Doprinos temeljnog CDA-a, kao i doprinos CDA-a temeljenog na interpolaciji, prilikom izrade kataloga kratera Marsa i Mjeseca opisani su u sljedećim potpoglavljima:

- 9.2.1. Doprinos temeljnog CDA-a prilikom izrade kataloga 115 225 kratera Marsa;
- 9.2.2. Metodologija za evaluaciju i izrada kataloga 130 301 kratera Marsa;
- 9.2.3. Doprinos CDA-a temeljenog na interpolaciji u izradi rezultirajućih najpotpunijih kataloga Marsa s 132 843 i Mjeseca s 60 645 kratera.

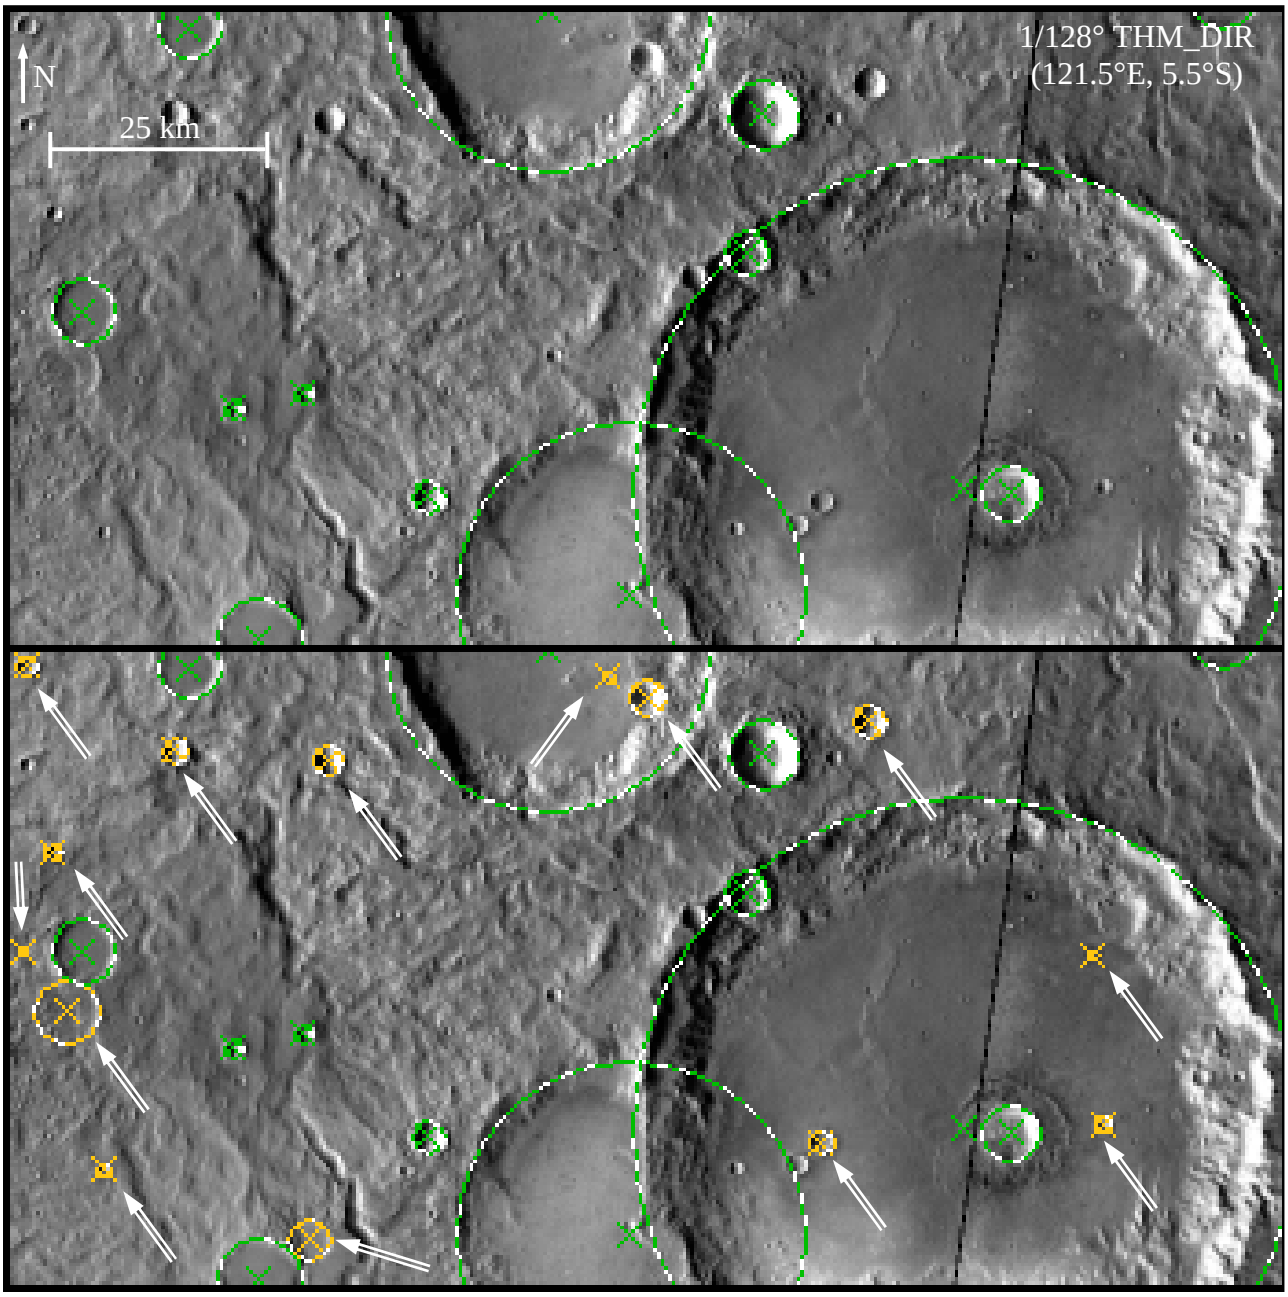
U budućem radu planira se integracija s katalogom kratera Marsa Robbinsa i Hyneka (2010, 2011) koji 21.12.2011. još nije bio javno dostupan, a čiji autori su najavili da sadrži još više kratera.

9.2.1. Doprinos temeljnog CDA-a prilikom izrade kataloga 115 225 kratera Marsa

Za temeljni CDA ovoga rada postignut je toliko visok postotak detekcije da svega ~2.7% kratera nije detektirano (17108/17582 je detektirano). Isti se postiže tek kada se svih 193 402 kratera s najvišom vjerojatnosti da su krateri uzmu u razmatranje. U takvom slučaju broj pogrešnih detekcija je znatno viši od broja točnih detekcija (kad CDA radi u modu viske osjetljivosti). Međutim, temeljni CDA, kao i ostali CDA-ovi ovoga rada, mogu raditi i u modu gdje je velika većina kratera još uvijek detektirana, a gdje je broj pogrešnih detekcija puno manji od broja točnih detekcija. Rad u modu visoke osjetljivosti je međutim neophodan u pronalaženju što većeg broja nekatalogiziranih kratera, te je stoga korišten u traženju istih.

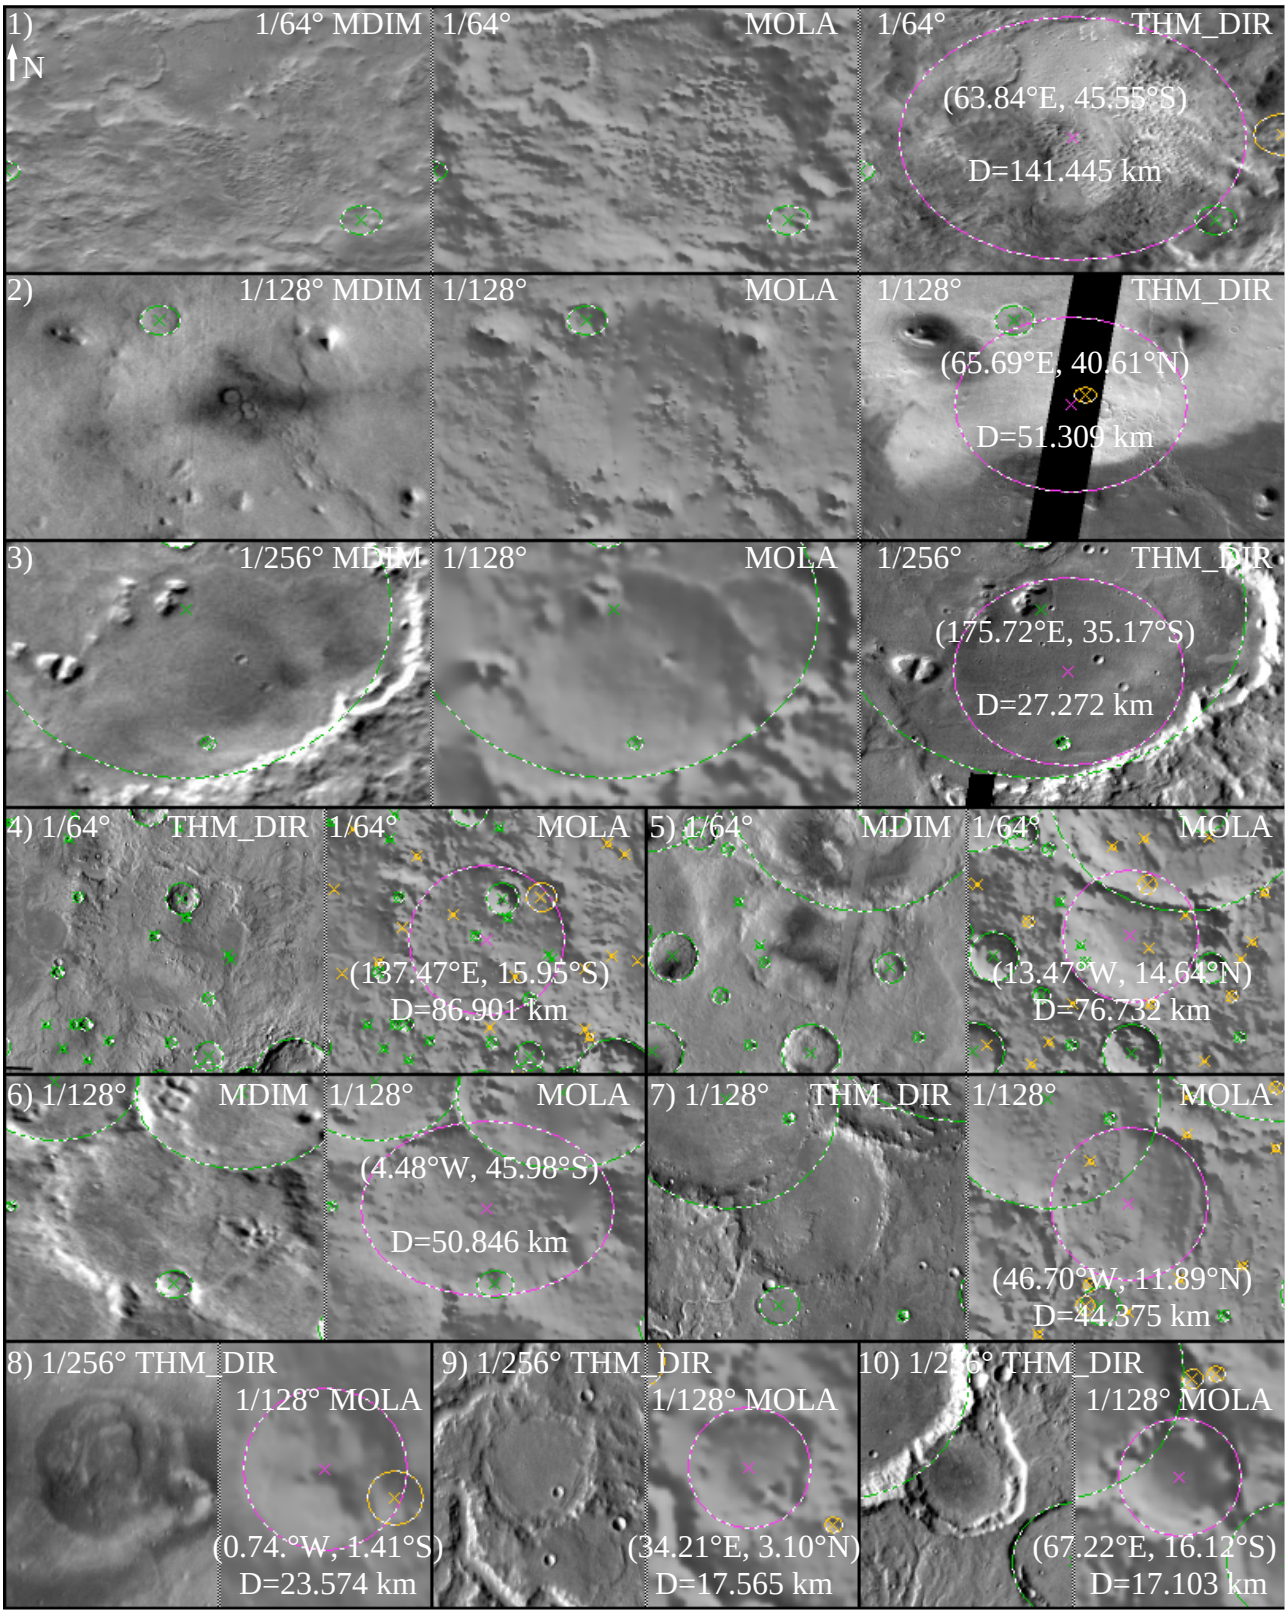
Polazni katalog je bio MA57633GT, a cilj je bio, koristeći CDA, pronaći i katalogizirati kratere koji se mogu detektirati iz 1/128° MOLA podataka, a koji prethodno nisu bili katalogizirani u MA57633GT. Za to postoje dva razloga: (1) kratere koji se već nalaze u MA57633GT nije potrebno ponovo katalogizirati; (2) kratere koje je CDA pronašao, a koji se nalaze u MA57633GT, mogu se automatski detektirati prilikom vrednovanja CDA-a i obrisati. Ručna obrada kandidata za kratere koje je detektirao CDA podrazumijeva sljedeće. Ako se radi o pogrešnoj detekciji, ista se briše, a ako se radi o točnoj detekciji, ista se registrira u referentni katalog. Pritom se po potrebi korigiraju koordinate i dijametar te se detektiran krater registrira sa svim korištenim globalnim optičkim mozaicima.

Zamijenjena je 1/64° MOLA globalna topografska slika koja se koristila za pronalaženje optimalnih parametara CDA-a s 1/128° MOLA podacima. Dodatno su postavljene sve vrijednosti kalibracije kataloga na 1. Nakon toga, 157 840 (193 402 minus svi pronađeni automatskom procedurom u MA57633GT) kandidata za kratere je ručno provjereno i katalog MA57633GT je proširen s 5985 novih kratera. U sljedećim koracima smanjio se r_1 s 5 na 4, 3 i 2 slikovnih elemenata, dodatno se ručno pregledalo 77 629 (193 402 minus svi krateri iz MA57633GT i kad je r_1 bio jednak 5), 80 460 (193 402 minus svi krateri iz MA57633GT i kad je r_1 bio jednak 5 i 4) i 98 702 (193 402 minus svi krateri iz MA57633GT i kad je r_1 bio jednak 5, 4 i 3) kratera i katalog proširio s 5047, 9463 i 37097 novih kratera. Sveukupno je provjereno 414 631 kratera i 57 592 je potvrđeno kao točne detekcije. Slika 53 prikazuje primjere novopronađenih kratera.



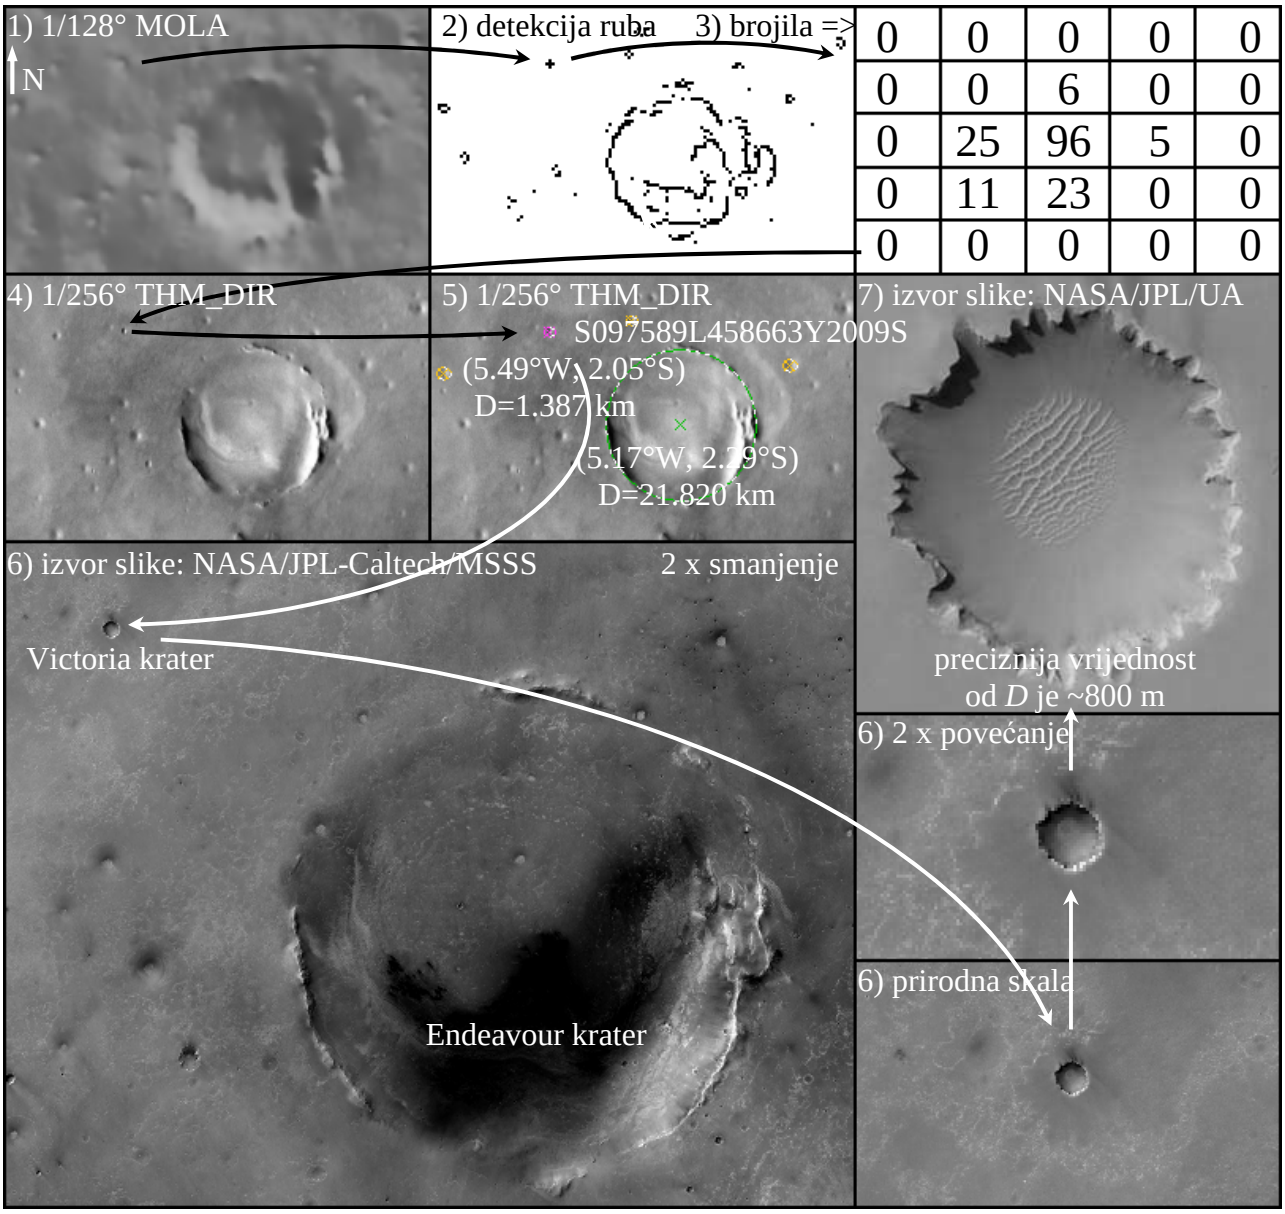
Slika 53. Dio MA57633GT kataloga (gore) i novopronađeni krateri (dolje). Može se primijetiti da su brojni novi krateri, detektirani korištenjem CDA-a ovoga rada temeljenog na Cannyjevom detektoru ruba, nakon toga potvrđeni kao točne detekcije. Oni su značajno proširili prethodni katalog, sa sveukupno 57 592 novih kratera. © 2010 IEEE (Salamunićcar i Lončarić, 2010b).

Neki od novopronađenih kratera su vrlo veliki, no razlog zašto prethodno nisu bili katalogizirani je njihova velika erodiranost zbog koje više nisu vidljivi na optičkim slikama. Zahvaljujući temeljnom CDA-u ovoga rada koji obrađuje topografske podatke, oni se ipak mogu pronaći i katalogizirati. Slika 54 prikazuje tri takva primjera (1, 2 i 3), od kojih je najveći veći od 100 km u dijametru. S druge strane, neki od novopronađenih velikih kratera, među kojima ima i kratera većih od 50 km u dijametru, vidljivi su na optičkim slikama. Unatoč tome isti prethodno nisu bili katalogizirani, iako postoje dva kataloga kojima je cilj bio katalogizirati sve kratere veće od 10 km (MA42284B) i od 5 km (MA19308R) u dijametru. Slika 54 dodatno prikazuje takve primjere (4, 5, itd.). Razlog je nemogućnost ručne katalogizacije desetaka tisuća kratera a da se pritom neki ne propuste. U tom slučaju pomaže CDA za sistematično pretraživanje cijelog planetarnog tijela kako bi pronašao takve kratere i isti se katalogizirali.



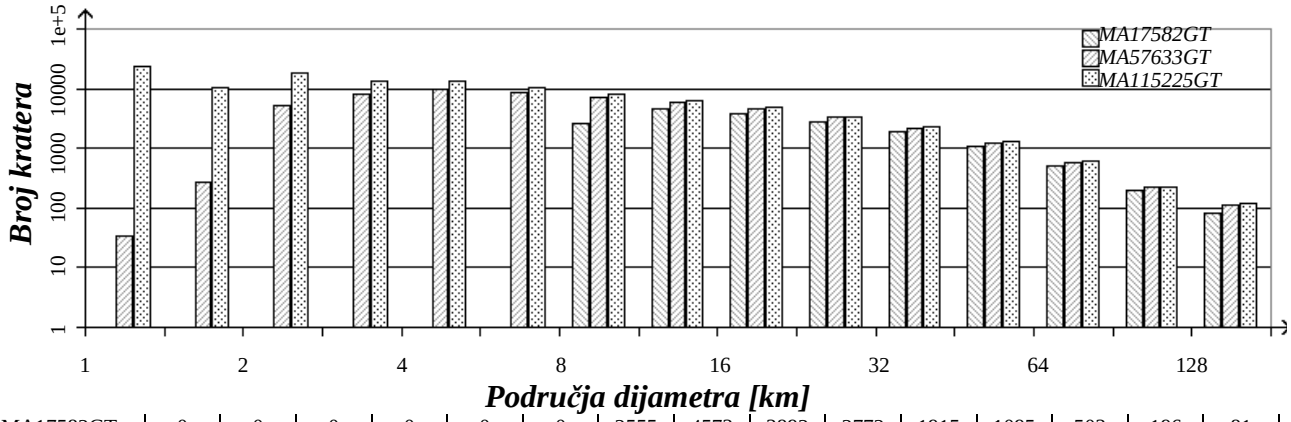
Slika 54. Tri primjera novopronađenih velikih kratera koji nisu vidljivi na optičkim slikama, ali još uvijek jesu na topografskim, su: (1) *D*>64km S061933L042573Y2009S, (2) 64km>*D*>32km S060937L038709Y2009S, (3) 32km>*D*>16km S059179L003332Y2009S. Sedam primjera novopronađenih velikih kratera, vidljivih na optičkim slikama, ali prethodno propuštenih, su: S061610L029473Y2009S (4), S061135L030357Y2009S (5), S059253L002378Y2009S (6), S060194L011558Y2009S (7), S060326L012804Y2009S (8), S058846L004130Y2009S (9), S058505L001644Y2009S (10). © 2010 IEEE (Salamunićcar i Lončarić, 2010b).

Drugo ekstremno područje rada CDA-a je detekcija po mogućnosti što manjih kratera. Detekcijom sve manjih kratera postiže se detekcija sve većeg broja kratera iz iste slike. To je važno jer su slike svih dijelova površine obično dostupne samo do određene horizontalne rezolucije. Slika 55 prikazuje primjer detekcije jednog vrlo malog kratera. Kao što se vidi na dijelu (1), depresija je toliko mala da je kod detekcije ruba (2) rezultirala sa svega 5 slikovnih elemenata u obliku križića, te sa svega šest slikovnih elemenata u parametarskom području gdje lokalni maksimum vrijednosti brojila upravo odgovara detektiranom krateru.



Slika 55. Ilustracija detekcije malih kratera. Za 1/128° MOLA podatke (1) prikazani su rezultati detekcije ruba (2), gdje je mala depresija rezultirala malim križićem. Rezultati izmijenjene Houghove transformacije (vrijednosti brojila) su dodatno pokazani, gdje je na lokaciji (22336, 11782) maksimum iznosa 96 (3). Tijekom ručne provjere korištene su slike 1/256° THM_DIR i 1/256° MDIM (4) i nakon odluke da je detekcija zaista krater, isti je registriran u referentni katalog (5). Provjerene su slike u višoj horizontalnoj rezoluciji (6 – NASA, 2009; 7 – NASA, 2008b), čime je potvrđeno da je detekcija Victoria krater. Crne strelice pokazuju korake ručne provjere svih kandidata za kratere. Bijele strelice prikazuju napravljeno samo za Victoria krater, isključivo u svrhu ilustracije. © 2010 IEEE (Salamunićcar i Lončarić, 2010b).

Rezultat proširenja MA57633GT kataloga s 57 592 prethodno nekatalogiziranih kratera je novi MA115225GT katalog s 115 225 kratera. Slika 56 prikazuje distribuciju kratera iz kataloga MA115225GT i uspoređuje je s distribucijama kratera iz prethodnih kataloga, MA17582GT i MA57633GT. Kao što je prikazano i u skladu s očekivanjem, većina novopronađenih kratera je iz područja dijametra koji nisu pokrili prethodni katalozi, MA42284B i MA19308R, odnosno manji su od 5 km u dijametru. No ima i znatan broj područja dijametra kratera većih od 5 km, a gdje je doprinos novopronađenih kratera viši od 5%. Time se dolazi do zaključka da je doprinos temeljnog CDA-a ovoga rada značajan i za velike i za male kratere.



MA17582GT	0	0	0	0	0	0	2555	4573	3892	2772	1915	1095	503	196	81
MA57633GT	33	277	5226	8085	9780	8822	7293	5888	4550	3311	2206	1246	579	222	115
MA115225GT	22811	10561	17823	13264	13508	10143	8050	6316	4807	3450	2270	1282	597	227	116
novih 57592	22778	10284	12603	5173	3727	1323	756	428	258	137	63	38	18	5	1
novi u %	99.86	97.38	70.71	39.00	27.59	13.04	9.39	6.78	5.37	3.97	2.78	2.96	3.02	2.20	0.86

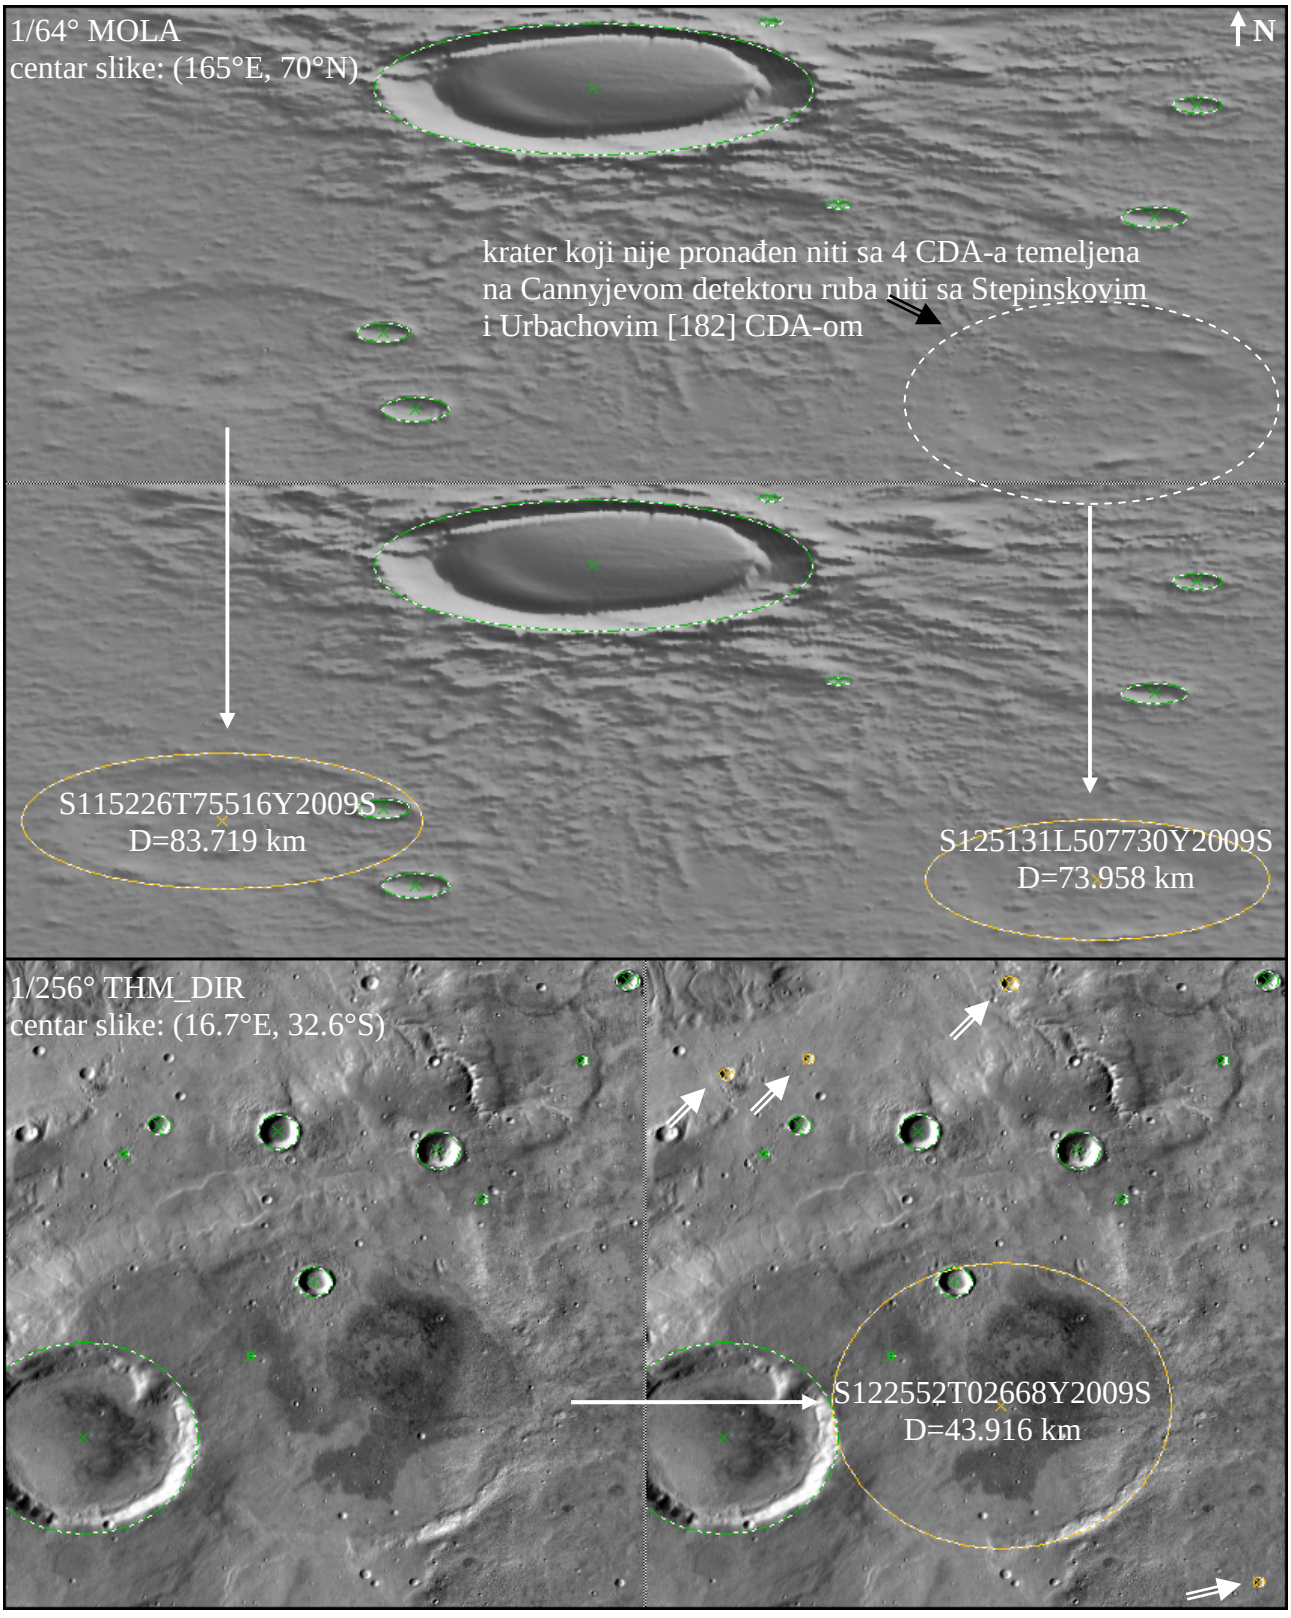
Slika 56. Distribucija kratera iz kataloga MA17582GT, MA57633GT i MA115225GT. Graf pokazuje $\log_{10}$ broja kratera za odgovarajuće područje dijametara. Vrijednosti iz grafa su u prva 3 retka. U 4. retku je distribucija kratera pronađenih s temeljnim CDA-om ovoga rada. Vrijednosti iz 4. retka nisu uvijek razlike vrijednosti iz 3. i 2. retka, s obzirom na to da su se tijekom registracije novopronađenih 57 592 kratera njihova lokacija i dijametar korigirali prilikom registracije u referentni katalog, kao i kod nekih kratera iz MA57633GT kataloga. Time su neki krateri promijenili pripadajuće područje koje im je pridruženo na temelju dijametra. U 5. retku je postotak novopronađenih kratera u MA115225GT katalogu. © 2010 IEEE (Salamunićcar i Lončarić, 2010b).

9.2.2. Metodologija za evaluaciju i izrada kataloga 130 301 kratera Marsa

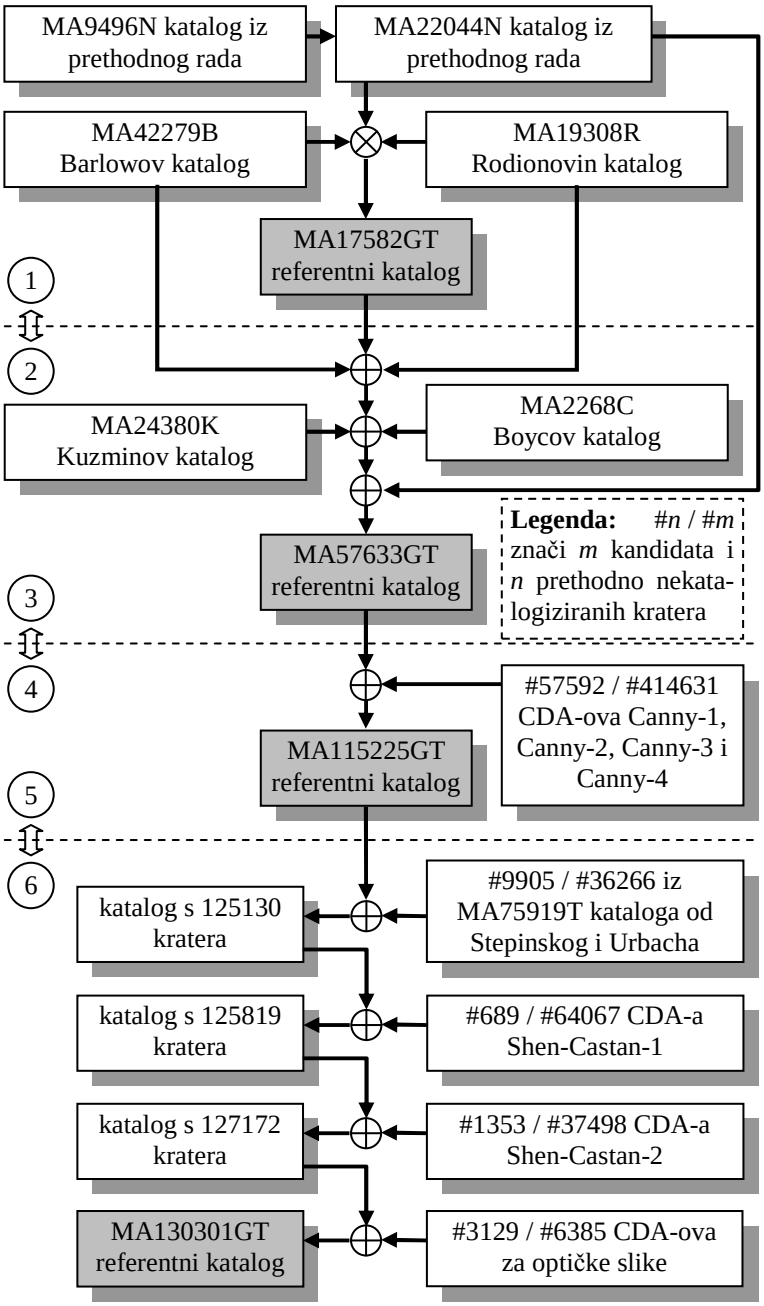
Analizom MA115225GT kataloga ustanovljeno je da neki krateri još uvijek nisu katalogizirani. Temeljni CDA ovoga rada koji koristi Cannyjev detektor ruba nije ih naime pronašao. Iako temeljni CDA koji koristi taj detektor ruba pokazuje najbolje rezultate prilikom vrednovanja, temeljni CDA koji koristi neki drugi detektor ruba može detektirati neke od kratera koje prvi CDA ne može. Slika 57 (gore) prikazuje primjer kratera koji nije uspio detektirati ni temeljni CDA koji koristi Cannyjev (1986) detektor ruba, ni Stepinskov i Urbachov (2008) CDA (ne nalazi se u MA75919T katalogu). S druge strane taj isti krater može detektirati temeljni CDA ovoga rada koji koristi Shen-Castanov (1992) detektor ruba. Stoga se nakon integracije kratera iz MA75919T kataloga koristio temeljni CDA koji koristi Shen-Castanov detektor ruba, kako bi se pronašli i katalogizirali dodatni krateri. U prvom koraku koristile su se vrijednosti kalibracije kataloga *serije-a*, a u drugom *serije-c*. Slika 57 (dolje) prikazuje uobičajene novopronađene kratere.

Kako bi se okruženje za vrednovanje CDA-ova moglo koristiti i za vrednovanje onih CDA-ova koji koriste optičke slike, CDA za optičke slike (Bandeira et al., 2007b) koristio se kako bi se za 4 regije dodatno katalogizirali krateri koje prethodno nisu pronašli CDA-ovi koji koriste

topografske podatke. Slika 58 prikazuje glavne faze u izradi MA130301GT kataloga, kao i referentnih kataloga, MA17582GT, MA57633GT i MA115225GT, koji su mu prethodili.

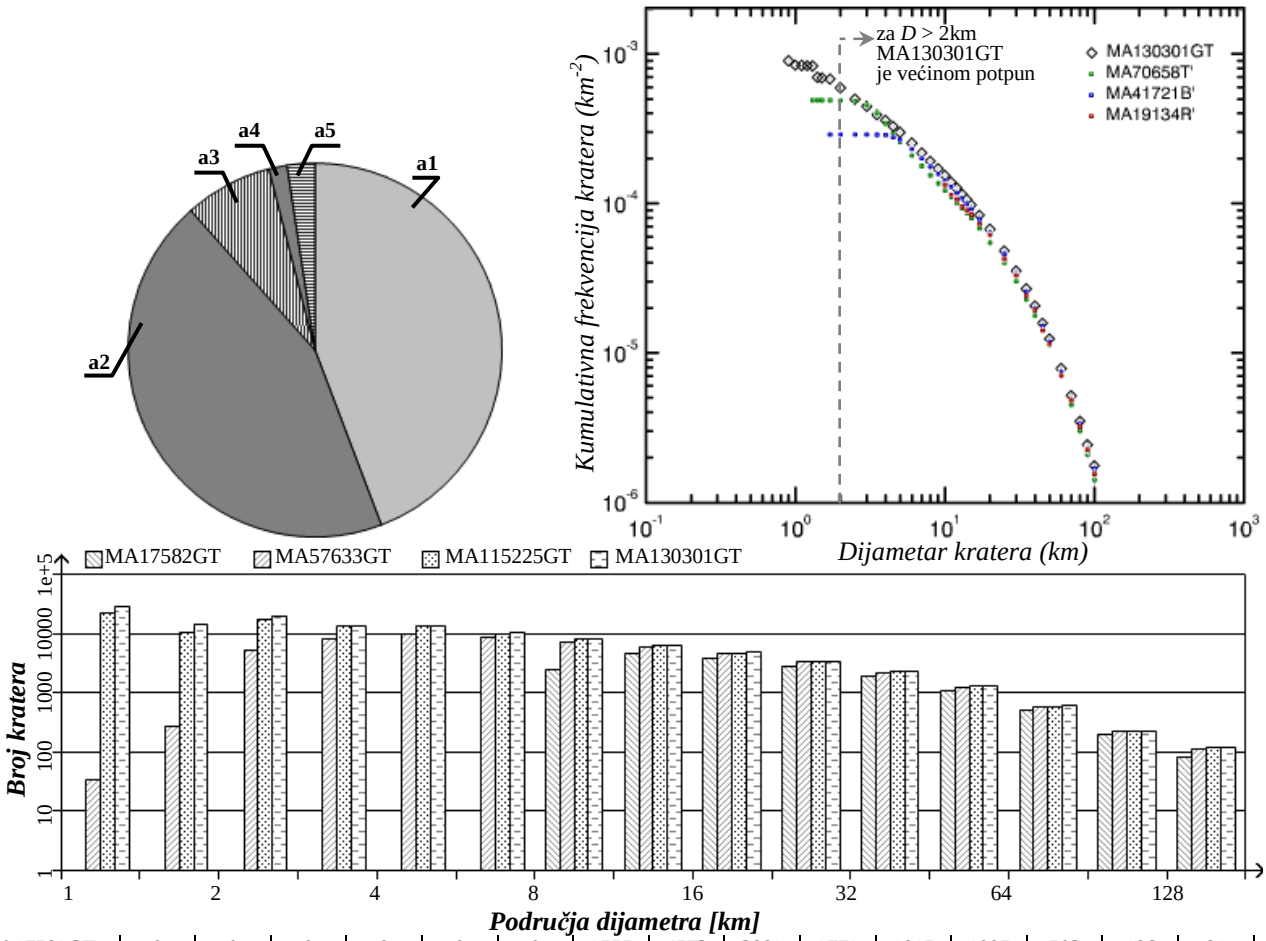


Slika 57. Prethodni MA115225GT katalog (zelena) i novi krateri iz MA130301GT kataloga (žuta, označeni strelicama): veliki krateri koji nisu vidljivi na optičkim slikama, ali su još uvijek na topografskim (gore); mali krateri kao uobičajena proširenja (dolje). © 2008 Elsevier (Salamunićcar et al., 2011a).



Slika 58. Glavni koraci u izradi MA130301GT kataloga: (1) MA17582GT katalog iz početne okoline za razvoj CDA-ova; (2) rad na naprednoj okolini za razvoj i vrednovanje CDA-ova; (3) MA57633GT kao rezultat objedinjavanja svih ručno napravljenih kataloga; (4) korištenje CDA-ova za traženje prethodno nekatalogiziranih kratera; (5) MA115225GT katalog koji je rezultat doprinosa temeljnog CDA-a koji koristi Cannyjev detektor ruba; (6) rad opisan u ovom poglavlju koji je rezultirao MA130301GT katalogom, a koji sadrži i dodatan doprinos temeljnog CDA-a koji koristi Shen-Castanov detektor ruba. © 2008 Elsevier (Salamunićcar et al., 2011a).

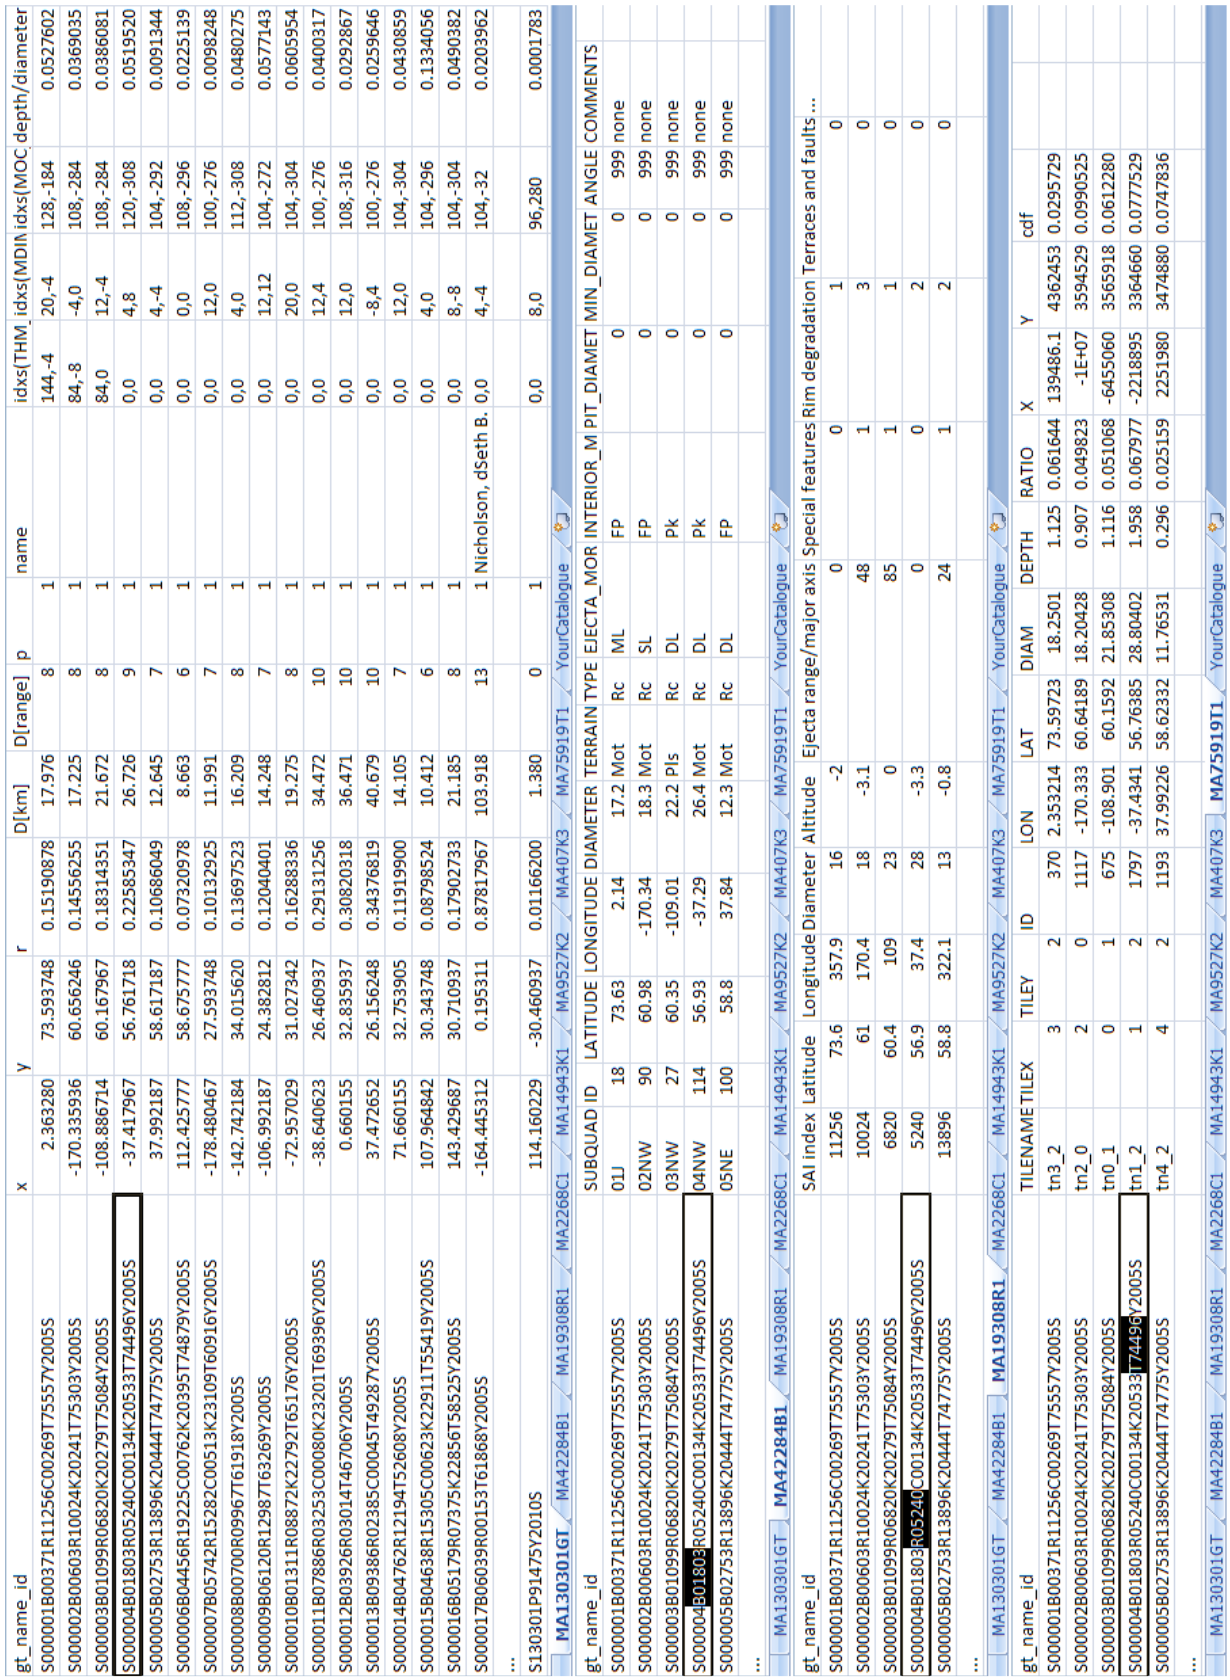
Distribucija kratera važna je radi procjene potpunosti nekog kataloga. Slika 59 prikazuje distribuciju MA130301GT kataloga te je uspoređuje s distribucijama ostalih kataloga. Iz analize proizlazi da je MA130301GT potpuniji od svih ostalih kataloga, i to za sva područja dijametra. Većinom je potpun za kratere veće od 2 km u dijametru, dok sadrži i znatan broj manjih kratera. Ista slika prikazuje i doprinos različitih izvora u MA130301GT katalogu. Iako su najznačajniji doprinosi krateri iz kataloga MA57633GT te krateri koje je pronašao temeljni CDA koji koristi Cannyjev detektor ruba, radi postizanja što potpunijeg rezultirajućeg, MA130301GT kataloga, značajni su i ostali doprinosi, npr. doprinos temeljnog CDA-a koji koristi Shen-Castanov detektor ruba.



MA17582GT	0	0	0	0	0	0	2555	4573	3892	2772	1915	1095	503	196	81
MA57633GT	33	277	5226	8085	9780	8822	7293	5888	4550	3311	2206	1246	579	222	115
MA115225GT	22811	10561	17823	13264	13508	10143	8050	6316	4807	3450	2270	1282	597	227	116
MA130301GT	29700	14818	19888	14026	13848	10382	8225	6448	4895	3512	2308	1304	603	227	117
novih 15076	6889	4257	2065	762	340	239	175	132	88	62	38	22	6	0	1
novi u %	30.20	40.31	11.59	5.74	2.52	2.36	2.17	2.09	1.83	1.80	1.67	1.72	1.01	0.00	0.86
zadnjih 3129	2799	263	57	7	3	0	0	0	0	0	0	0	0	0	0
MA19308R	0	0	0	0	0	0	3830	4221	4433	2737	2175	1074	548	201	89
MA19134R'	0	0	2	0	4	91	3874	4735	3832	2788	1924	1085	511	202	86
MA42284B	0	1	6	423	6818	9125	7721	5813	4647	3329	2235	1230	604	213	119
MA41721B'	2	2	39	615	7478	8719	7190	5750	4428	3236	2155	1220	561	217	109
MA75919T	1	119	3245	19088	18687	11081	7441	5248	4158	2832	1950	1171	587	231	80
MA70658T'	5744	7810	11326	9367	9480	7357	5968	4583	3507	2443	1598	904	393	130	48

Slika 59. Glavni graf prikazuje $\log_{10}$ broja kratera iz kataloga MA17582GT, MA57633GT, MA115225GT i MA130301GT za različite veličine dijametra. Vrijednosti iz grafa nalaze se u recima 1-4. Distribucija novih kratera u MA130301GT i njihov postotak nalaze se recima 5-6. Distribucija zadnjih 3129 kratera koji su rezultat CDA-a za optičke slike (Bandeira et al., 2007b) nalaze se u retku 7. Distribucija kratera iz MA19308R, MA42284B i MA75919T nalaze se u recima 8-13. Distribucija kratera iz MA130301GT, s obzirom na izvor, prikazana je malim grafom: (a1) 57 633 kratera iz MA57633GT; (a2) 57 592 kratera iz MA115225GT koje su pronašli DEM temeljeni CDA-ovi, Canny-1 do Canny-4; (a3) 9 905 kratera iz MA75919T koje je pronašao Stepinskov i Urbachov (2008) CDA; (a4) 2 042 kratera pronađenih korištenjem DEM temeljenih CDA-ova, Shen-Castan-1 i Shen-Castan-2; (a5) 3 129 kratera pronađenih s CDA-om za optičke slike (Bandeira et al., 2007b). Procjena potpunosti prikazana je grafom, gore desno: (1) MA19134R' je potpun za ~ $D \geq 10$ km; (2) MA41721B' je potpun za ~ $D \geq 5$ km; (3) MA70658T' je potpun za ~ $D \geq 3$ km, no manje potpun nego MA19134R' i MA41721B' za ~ $D \geq 5$ km; (4) MA130301GT je potpun za ~ $D \geq 2$ km i potpuniji od svih ostalih. © 2008 Elsevier (Salamunićcar et al., 2011a).

U završnom koraku napravljena je integracija sa svim korištenim katalozima. Slika 60 prikazuje dostupnost svih atributa iz prethodnih kataloga za svaki krater.



gt_name_id	x	y	r	D[km]	D[range]	p	name	idxs(THM	idxs(MDIN	idxs(MOC	depth/diameter
S000001B00371R11256C00269T75557Y2005S	2.363280	73.593748	0.15190878	17.976	8	1		144,-4	20,-4	128,-184	0.0527602
S000002B00603R10024K20241T75303Y2005S	-170.335936	60.656246	0.14556255	17.225	8	1		84,-8	-4,0	108,-284	0.0369035
S000003B01099R06820K20279T75084Y2005S	-108.886714	60.167967	0.18314351	21.672	8	1		84,0	12,-4	108,-284	0.0386081
S000004B01803R05240C00134K20533T74496Y2005S	-37.417967	56.761718	0.22585347	26.726	9	1		0,0	4,8	120,-308	0.0519520
S000005B02753R13896K20444T74775Y2005S	37.992187	58.617187	0.10686049	12.645	7	1		0,0	4,-4	104,-292	0.0091344
S000006B04456R19225C00762K20395T74879Y2005S	112.425777	58.675777	0.07320978	8.663	6	1		0,0	0,0	108,-296	0.0225139
S000007B05742R15282C00513K23109T60916Y2005S	-178.480467	27.593748	0.10132925	11.991	7	1		0,0	12,0	100,-276	0.0098248
S000008B00700R09967T61918Y2005S	-142.742184	34.015620	0.13697523	16.209	8	1		0,0	4,0	112,-308	0.0480275
S000009B06120R12987T63269Y2005S	-106.992187	24.382812	0.12040401	14.248	7	1		0,0	12,12	104,-272	0.0577143
S000010B01311R08872K22792T65176Y2005S	-72.957029	31.027342	0.16288336	19.275	8	1		0,0	20,0	104,-304	0.0605954
S000011B07886R03253C00080K23201T69396Y2005S	-38.640623	26.460937	0.29131256	34.472	10	1		0,0	12,4	100,-276	0.0400317
S000012B03926R03014T46706Y2005S	0.660155	32.835937	0.30820318	36.471	10	1		0,0	12,0	108,-316	0.0292867
S000013B09386R02385C00045T49287Y2005S	37.472652	26.156248	0.34376819	40.679	10	1		0,0	-8,4	100,-276	0.0259646
S000014B04762R12194T52608Y2005S	71.660155	32.753905	0.11919900	14.105	7	1		0,0	12,0	104,-304	0.0430859
S000015B04638R15305C00623K22911T55419Y2005S	107.964842	30.343748	0.08798524	10.412	6	1		0,0	4,0	104,-296	0.1334056
S000016B05179R07375K22856T58525Y2005S	143.429687	30.710937	0.17902733	21.185	8	1		0,0	8,-8	104,-304	0.0490382
S000017B06039R00153T61868Y2005S	-164.445312	0.195311	0.87817967	103.918	13	1	Nicholson, dSeth B.	0,0	4,-4	104,-32	0.0203962
...											
S130301P91475Y2010S	114.160229	-30.460937	0.01166200	1.380	0	1		0,0	8,0	96,280	0.0001783

MA130301GT / MA42284B1 / MA19308R1 / MA2268C1 / MA14943K1 / MA9527K2 / MA407K3 / MA75919T1 / YourCatalogue

gt_name_id	SUBQUAD	ID	LATITUDE	LONGITUDE	DIAMETER	TERRAIN	TYPE	EJECTA_MOR	INTERIOR_M	PIT_DIAMET	MIN_DIAMET	ANGLE	COMMENTS
S000001B00371R11256C00269T75557Y2005S	01J	18	73.63	2.14	17.2	Mot	Rc	ML	FP	0	0	999	none
S000002B00603R10024K20241T75303Y2005S	02NW	90	60.98	-170.34	18.3	Mot	Rc	SL	FP	0	0	999	none
S000003B01099R06820K20279T75084Y2005S	03NW	27	60.35	-109.01	22.2	Pls	Rc	DL	Pk	0	0	999	none
S000004B01803R05240C00134K20533T74496Y2005S	04NW	114	56.93	-37.29	26.4	Mot	Rc	DL	Pk	0	0	999	none
S000005B02753R13896K20444T74775Y2005S	05NE	100	58.8	37.84	12.3	Mot	Rc	DL	FP	0	0	999	none
...													

MA130301GT / MA42284B1 / MA19308R1 / MA2268C1 / MA14943K1 / MA9527K2 / MA407K3 / MA75919T1 / YourCatalogue

gt_name_id	SAI index	Latitude	Longitude	Diameter	Altitude	Ejecta range/major axis	Special features	Rim degradation	Terraces and faults ...
S000001B00371R11256C00269T75557Y2005S	11256	73.6	357.9	16	-2	0	0	1	0
S000002B00603R10024K20241T75303Y2005S	10024	61	170.4	18	-3.1	48	1	3	0
S000003B01099R06820K20279T75084Y2005S	6820	60.4	109	23	0	85	1	1	0
S000004B01803R05240C00134K20533T74496Y2005S	5240	56.9	37.4	28	-3.3	0	0	2	0
S000005B02753R13896K20444T74775Y2005S	13896	58.8	322.1	13	-0.8	24	1	2	0
...									

MA130301GT / MA42284B1 / MA19308R1 / MA2268C1 / MA14943K1 / MA9527K2 / MA407K3 / MA75919T1 / YourCatalogue

gt_name_id	TILENAME	TILEX	TILEY	ID	LON	LAT	DIAM	DEPTH	RATIO	X	Y	cdf
S000001B00371R11256C00269T75557Y2005S	tn3_2	3	2	370	2.353214	73.59723	18.2501	1.125	0.061644	139486.1	4362453	0.0295729
S000002B00603R10024K20241T75303Y2005S	tn2_0	2	0	1117	-170.333	60.64189	18.20428	0.907	0.049823	-1E+07	3594529	0.0990525
S000003B01099R06820K20279T75084Y2005S	tn0_1	0	1	675	-108.901	60.1592	21.85308	1.116	0.051068	-6455060	3565918	0.0612280
S000004B01803R05240C00134K20533T74496Y2005S	tn1_2	1	2	1797	-37.4341	56.76385	28.80402	1.958	0.067977	-2218895	3364660	0.0777529
S000005B02753R13896K20444T74775Y2005S	tn4_2	4	2	1193	37.99226	58.62332	11.76531	0.296	0.025159	2251980	3474880	0.0747836
...												

MA130301GT / MA42284B1 / MA19308R1 / MA2268C1 / MA14943K1 / MA9527K2 / MA407K3 / MA75919T1 / YourCatalogue

Slika 60. Katalog MA130301GT sadrži i sve prethodno korištene kataloge kratera Marsa pa time i sve atribute pridijeljene kraterima koje sadrže. © 2008 Elsevier (Salamunićcar et al., 2011a).

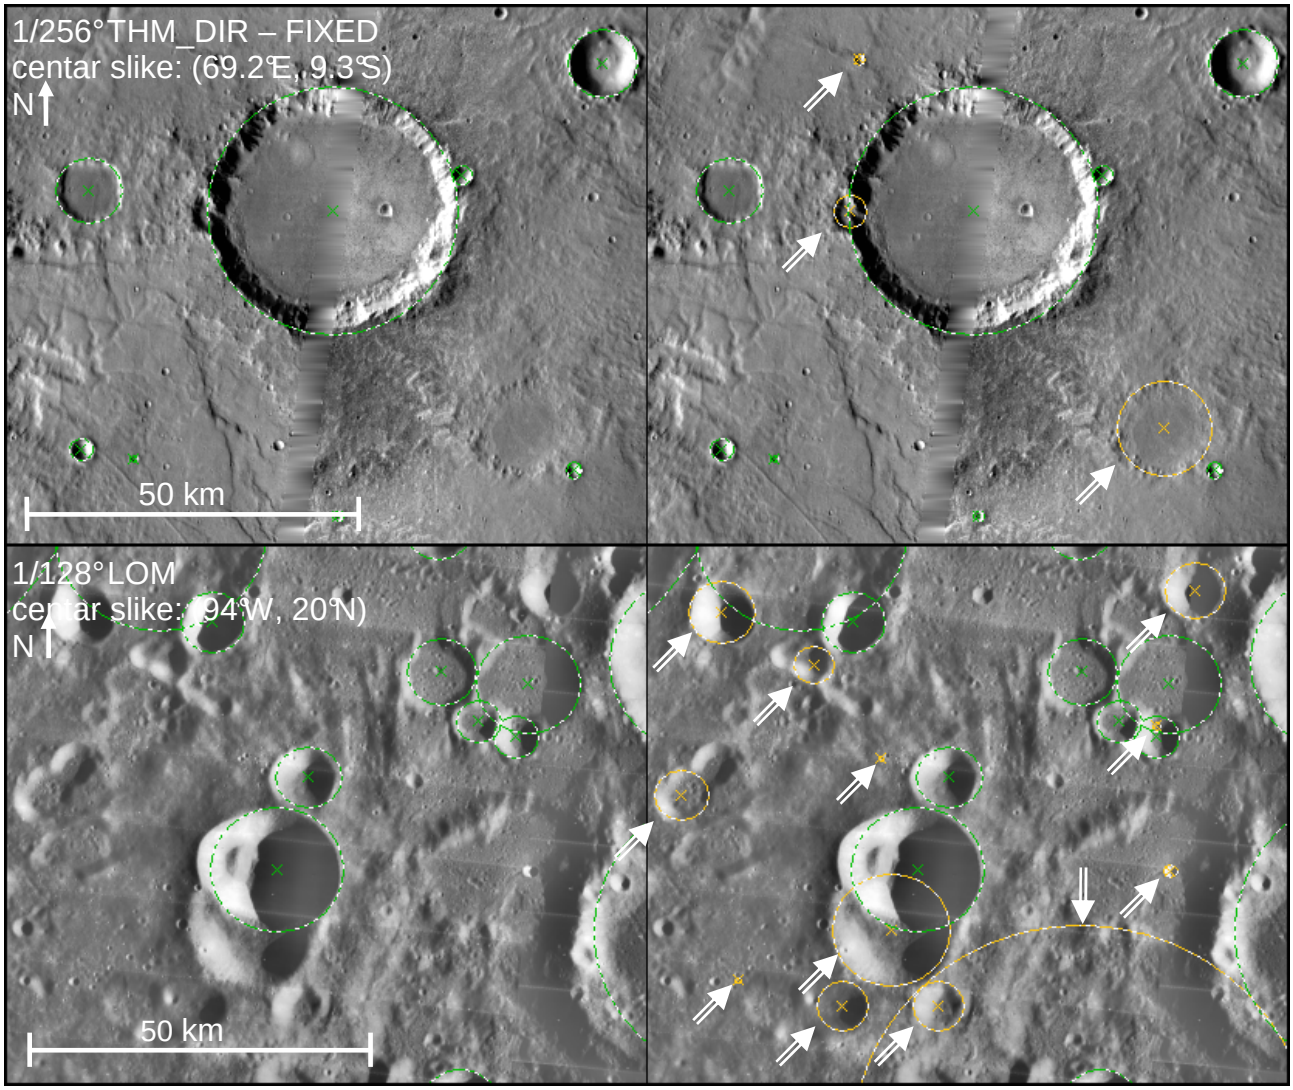
Katalog MA130301GT u svom radu koristili su i drugi, i to za znanstvena istraživanja koja nisu o algoritmima za detekciju kratera. Primjer je znanstveno istraživanje u kojem je bio cilj ispitati utjecaj površinskih procesa na degradaciju kratera Marsa (Conway et al., 2011c).

9.2.3. Doprinos CDA-a temeljenog na interpolaciji u izradi rezultirajućih najpotpunijih kataloga Marsa s 132 843 i Mjeseca s 60 645 kratera

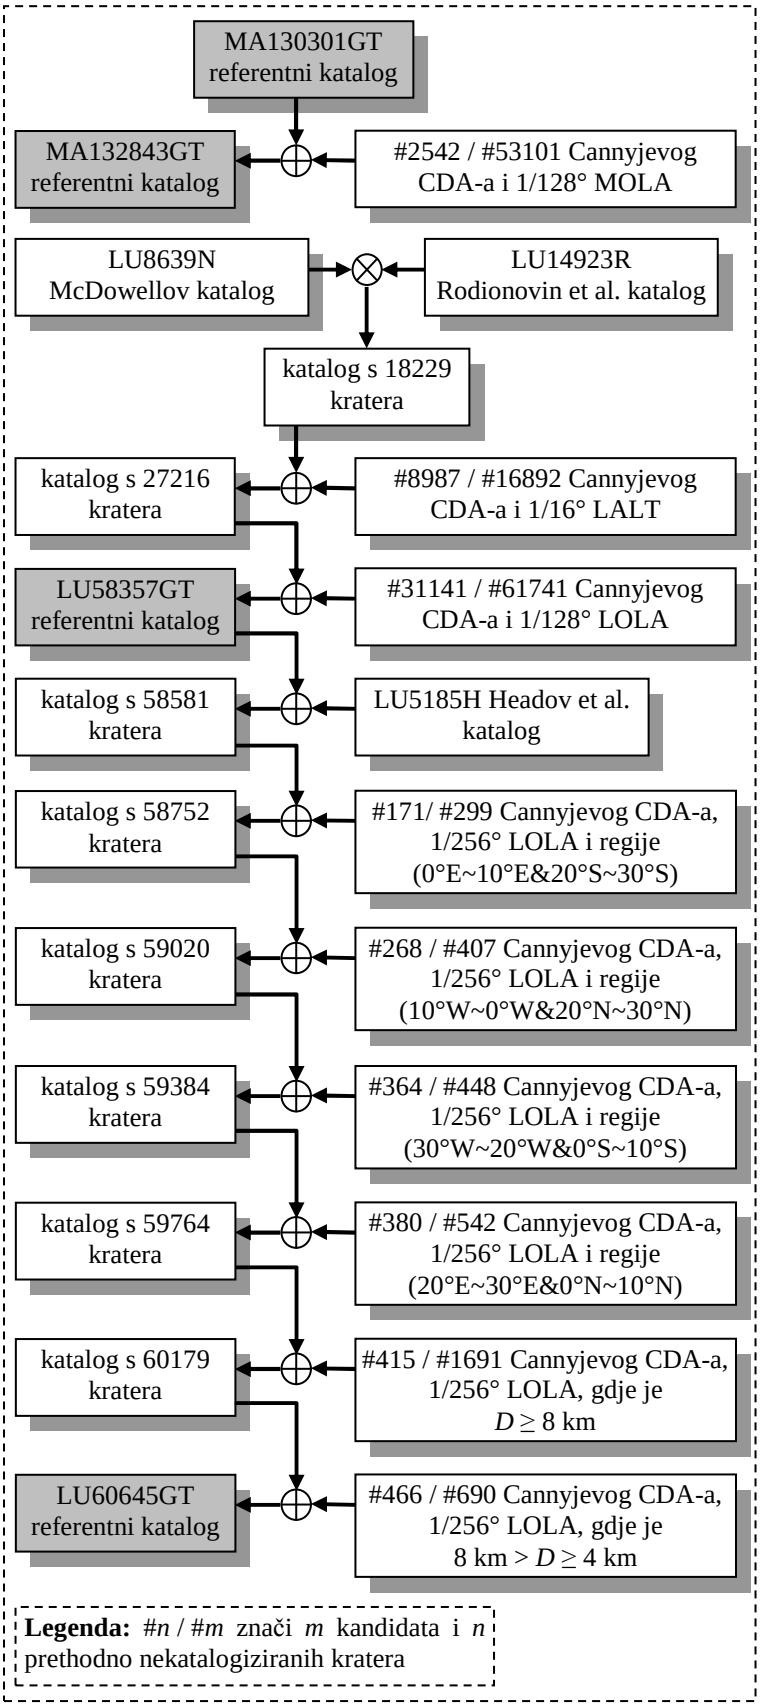
Ovaj dio rada napravljen je u suradnji s Erwanom Mazaricom (Salamunićcar et al., 2011f), čiji doprinos je priprema podataka i kataloga za Mjesec koji su se koristili (Head et al., 2010; Kadish et al., 2011). Prethodno napravljeni katalozi kratera Mjeseca su:

- LU8639N (McDowell, 2004~2007) katalog, sadrži 8639 kratera s dodijeljenim imenom, temelji se na Anderssonnovu i Whitakerovu (1982) katalogu (*NASA catalogue of Lunar nomenclature*) ;
- LU14923R (Rodionova et al., 1987) katalog (*Morphological catalogue of the craters of the Moon*), najpotpuniji prethodni katalog, sadrži 14 923 kratera većih od 10 km u dijametru;
- LU5185H (Head et al., 2010; Kadish et al., 2011) katalog, sadrži 5185 kratera, napravljen je korištenjem LOLA podataka te stoga sadrži i one kratere koje ne sadrže prethodna dva kataloga.

Slika 61 prikazuje uobičajene doprinose prilikom katalogizacije kratera: (1) Marsa (gore) – mali broj vrlo erodiranih ili vrlo malih kratera; (2) Mjeseca (dolje) – doprinos u puno većem broju kratera u odnosu na prethodne kataloge. Slika 62 prikazuje korake obrade.



Slika 61. Prethodni MA130301GT katalog (zelena) i novi krateri iz MA132843GT kataloga (žuta, označeni strelicama) Marsa (gore). Katalog s 18 229 prethodno ručno katalogiziranih kratera (zelena) i novi krateri iz LU60645GT kataloga (žuta, označeni strelicama) Mjeseca (dolje). © 2011 Elsevier (Salamunićcar et al., 2011f).



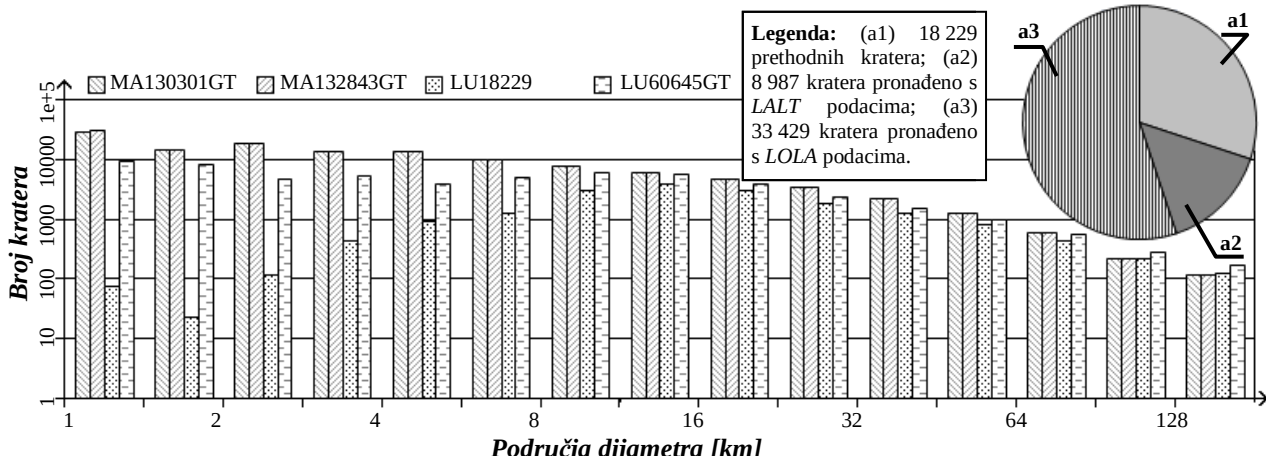
Slika 62. Doprinos CDA-a temeljenog na interpolaciji prilikom izrade kataloga Marsa i Mjeseca (MA132843GT i LU60645GT). © 2011 Elsevier (Salamunićcar et al., 2011f).

U slučaju Marsa doprinos su prije svega oni krateri koje prethodni temeljni CDA nije uspio detektirati, za razliku od CDA-a temeljenog na interpolaciji. U detekciji kratera Marsa i Mjeseca

koristila se parametrizacija kataloga *serije-d*. Katalog LU5185H postao je dostupan tek nakon što je LU58357GT već bio napravljen, stoga je naknadno integriran u LU60645GT katalog. Referentni katalog LU58357GT korišten je u istraživanju taljenja stijena prilikom nastanka kratera (Mazarico et al., 2011) prije nego što je LU5185H postao dostupan i integriran u LU60645GT.

Kao i za katalogizaciju kratera Marsa, i za Mjesec su se uz topografske podatke koristili i globalni optički mozaici: 1/64° LASGW (*Lunar Airbrushed Shaded Relief Warped to ULCN2005*); 1/256° CLEMBASE (*Clementine Basemap Mosaic version 2*); 1/512° LOM (*Lunar Orbiter Global Mosaic*). Kod obrade CLEMBASE podataka, nepostojeće vrijednosti interpolirane su najbližim postojećim (kao što je napravljeno za THEMIS-DIR Marsa), a svjetlina i kontrast su korigirani (kao što je napravljeno za MOC Marsa). Globalni mozaik LOM optimiziran je za upotrebu memorije.

SELENE LALT podaci su bili dostupni samo u horizontalnim rezolucijama do 1/16° (Araki et al., 2009). Isti su se koristili (Salamunićcar i Lončarić, 2010c) dok nisu bili dostupni LOLA podaci, što je bilo dostatno za katalogiziranje samo manjeg broja kratera. Nakon što su postali dostupni i LRO LOLA podaci do horizontalne rezolucije 1/512° (Smith et al., 2010), katalogizirani su brojni dodatni krateri. To je rezultiralo LU60645GT katalogom (Salamunićcar et al., 2011b). Međutim, LOLA podaci nisu odmah bili dostupni u horizontalnoj rezoluciji 1/512°. U prvom se koraku stoga koristila horizontalna rezolucija 1/128° koja se dobila uzorkovanjem horizontalne rezolucije preliminarnih podataka od ~1/91°, a u drugom horizontalna rezolucija 1/256° kako bi se procijenila mogućnost daljnjeg proširivanja referentnog kataloga te kako bi isti za kratere veće od 4 km bio što potpuniji. Iako su LOLA podaci dostupni i u horizontalnoj rezoluciji 1/512°, isti se nisu koristili s obzirom na to da se ni prethodne horizontalne rezolucije 1/128° i 1/256°, nisu mogle u potpunosti iskoristiti. Razlog je slabija pokrivenost globalnim optičkim mozaicima nego u slučaju Marsa. Situacija bi se trebala znatno popraviti korištenjem i nedavno objavljenog LRO globalnog mozaika optičkih slika, te je stoga procijenjen očekivan doprinos, korištenjem 1/256° LOLA podataka na onim dijelovima gdje su LOM slike bolje kvalitete. Slika 63 prikazuje distribucije završnih verzija kataloga kratera i uspoređuje ih s prethodnim verzijama. U manjem grafu (gore desno) prikazani su doprinosi LU60645GT katalogu s obzirom na izvor kratera.

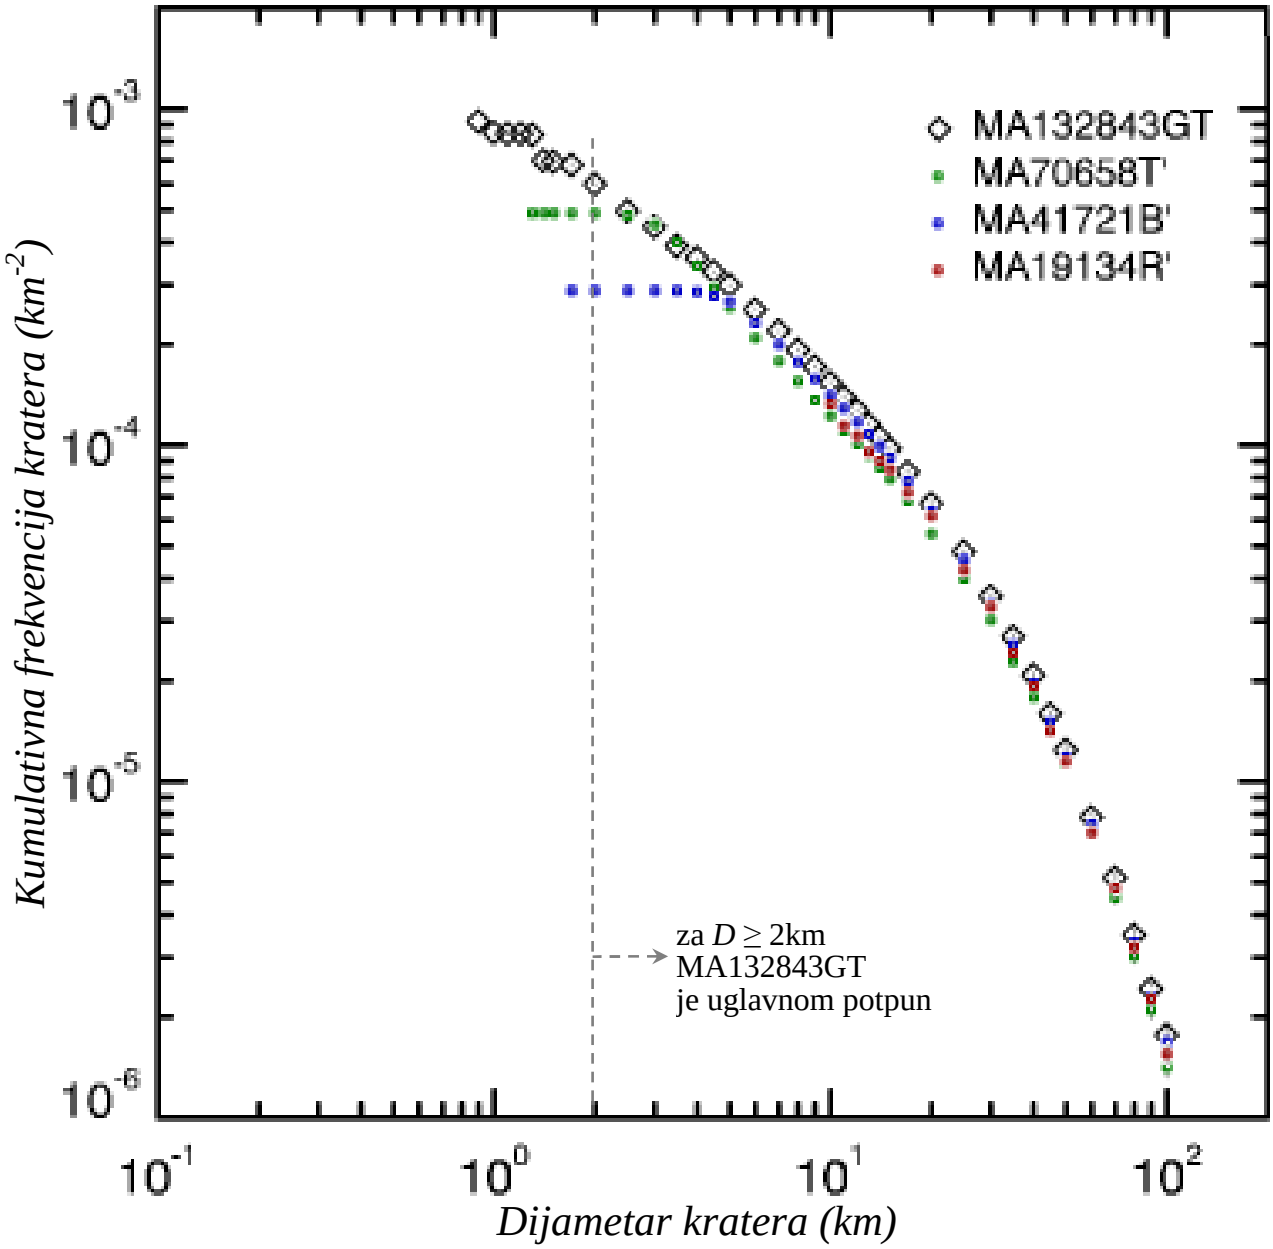


MA130301GT	29700	14818	19888	14026	13848	10382	8225	6448	4895	3512	2308	1304	603	227	117
MA132843GT	31630	15129	20073	14059	13876	10394	8238	6464	4901	3518	2309	1305	603	227	117
LU18229	78	23	122	456	972	1316	3165	4026	3194	1936	1311	816	459	229	126
LU60645GT	9755	8758	5005	5439	3994	5332	6282	5908	4069	2471	1606	1006	568	283	169

Slika 63. Glavni graf prikazuje distribuciju kratera iz kataloga MA130301GT, MA132843GT, LU18229 i LU60645GT, gdje je za različite veličine dijametra dan $\log_{10}$ broja kratera. Sporedni graf prikazuje distribuciju kratera za katalog LU60645GT, s obzirom na izvor. © 2011 Elsevier (Salamunićcar et al., 2011f).

Za analizu potpunosti kataloga Marsa koristio se program Craterstats (Michael, 2010). Slika 64 pokazuje kako je MA132843GT potpuniji od svih ostalih kataloga te uglavnom potpun za

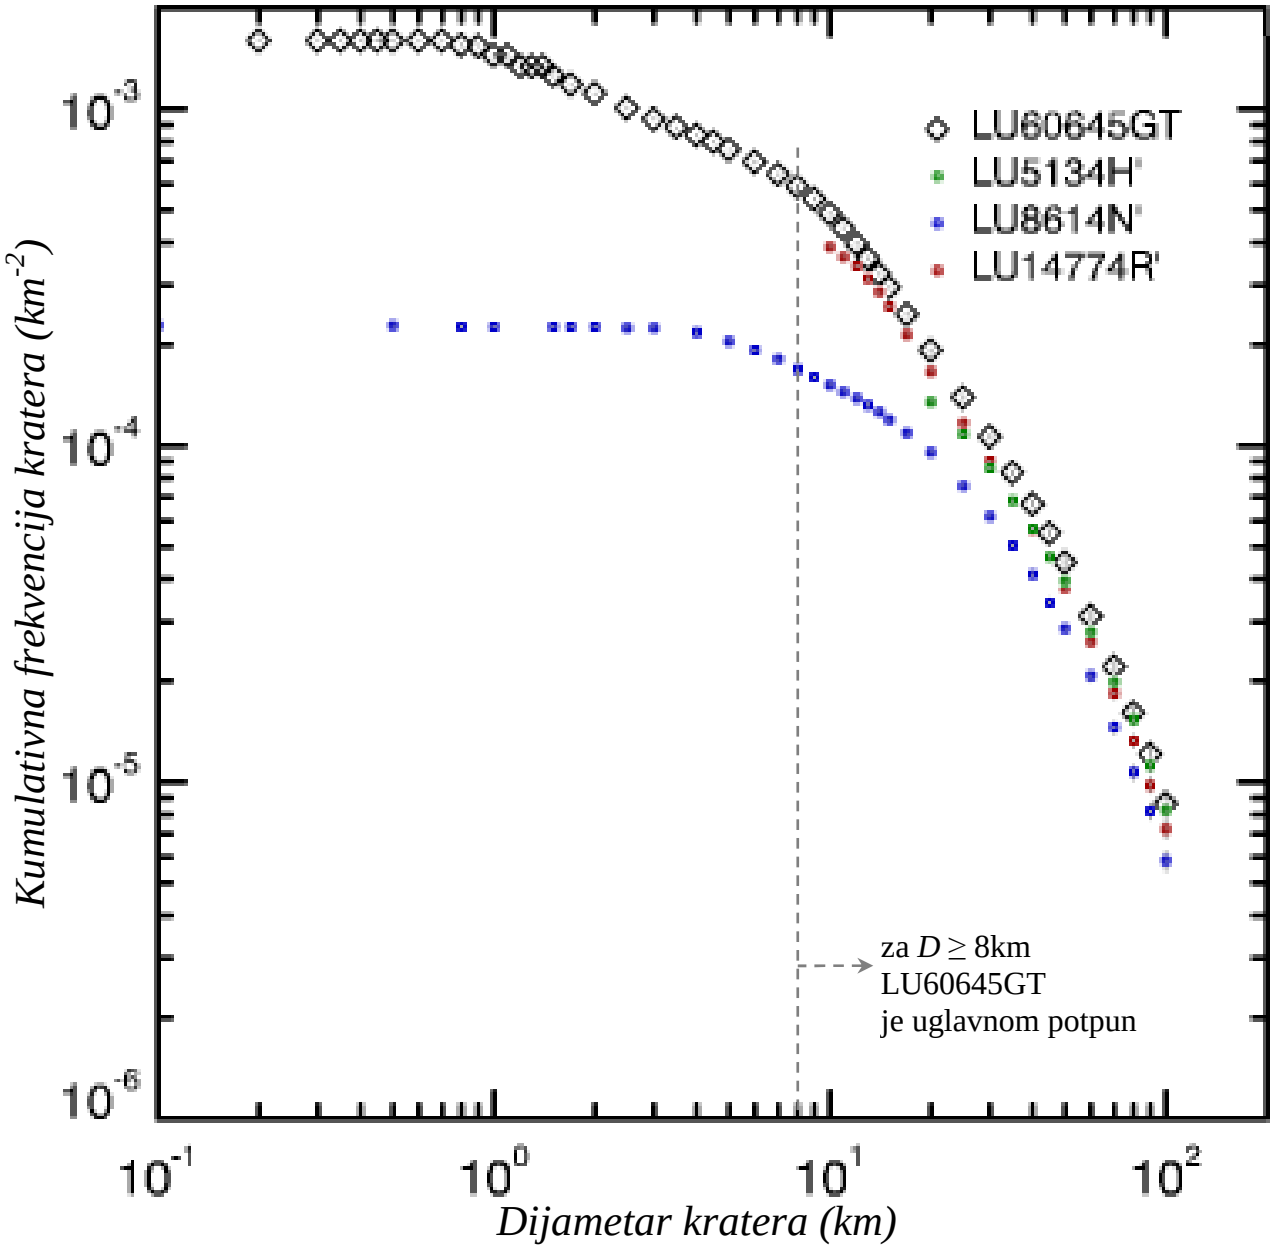
kratere kojima je dijametar veći od 2 km. Slika 59 prikazuje svega nešto lošije rezultate za prethodni MA130301GT katalog, s obzirom na to da između ta dva kataloga nema velike razlike. Značajna je bila katalogizacija i onih kratera koje temeljni CDA nije uspio detektirati, a CDA temeljen na interpolaciji jest. Cilj je što potpuniji konačni referentni katalog.



Slika 64. Procjena potpunosti kataloga; MA132843GT je uglavnom potpun za kratere veće od 2 km u dijametru te potpuniji od ostalih kataloga. © 2011 Elsevier (Salamunićcar et al., 2011f).

Potpunost kataloga Mjeseca također je analizirana programom Craterstats (Michael, 2010). Slika 65 prikazuje kako je katalog LU60645GT potpuniji od svih prethodnih kataloga za Mjesec te da je uglavnom potpun za kratere veće od 8 km u dijametru. Za Mars koristili su se globalni topografski podaci u horizontalnoj rezoluciji 1/128°, a za Mjesec su dostupni i u horizontalnim rezolucijama 1/256° te 1/512°. Uz to, Mjesec ima i manji radijus pa isti broj slikovnih elemenata u istoj rezoluciji odgovara manjim kraterima. Međutim, katalog Mjeseca nije potpuniji jer globalni optički mozaici za Mjesec nisu kvalitetni kao za Mars, iako je LOM za Mjesec dostupan u horizontalnoj rezoluciji 1/512°, što je više od 1/256° korištene za Mars. Razlog je puno lošija

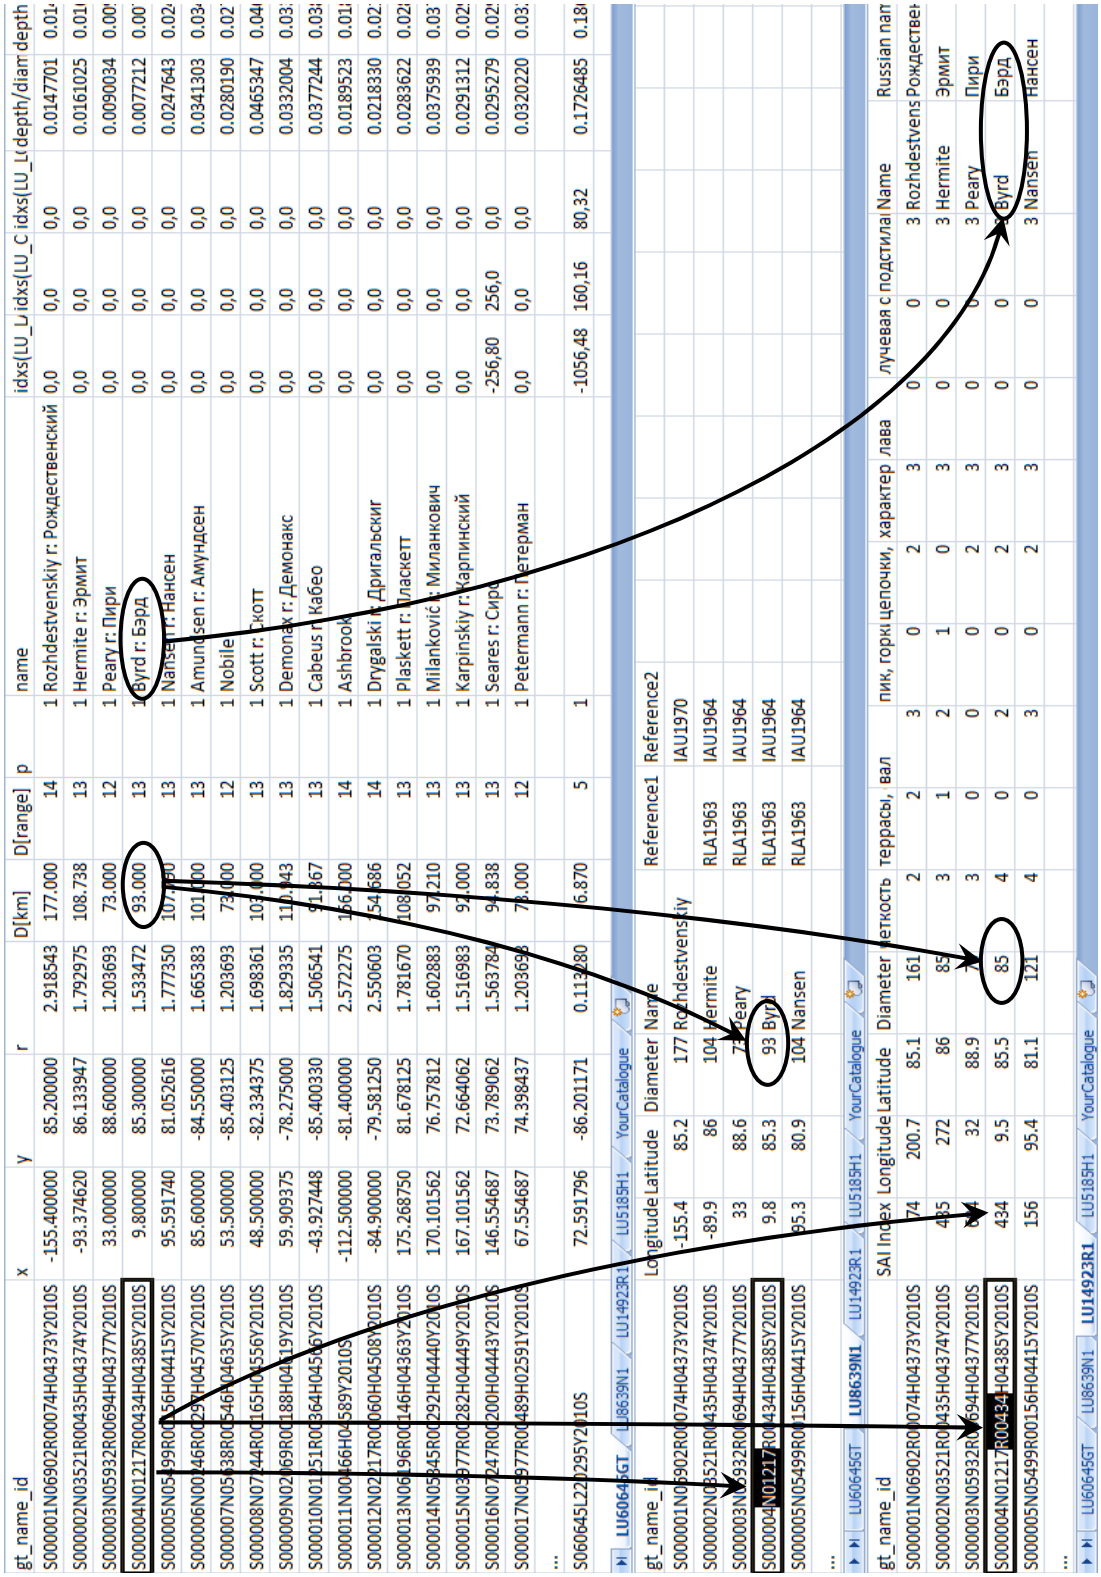
kvaliteta slika za Mjesec, posebno za udaljenu stranu te područja bliža polovima, stoga je i popunjenost kratera manjih od 8 km u dijametru manja za ta područja.



Slika 65. Procjena potpunosti kataloga; LU60645GT je potpun za kratere veće od 8 km u dijametru te je potpuniji od ostalih kataloga. © 2011 Elsevier (Salamunićcar et al., 2011f).

Završni katalog kratera Marsa, MA132843GT, integriran je sa svim ostalim katalozima, kao što je to pokazano za prethodnu verziju, MA130301GT. Istim pristupom i završni katalog kratera Mjeseca, LU60645GT, integriran je sa svim ostalim korištenim katalozima. Slika 66 prikazuje kako se, kao i kod kataloga kratera Marsa, mogu koristiti sve one značajke koje su kraterima pridijeljene u prethodnim katalozima. Svaki krater u katalogu LU60645GT ima reference na sve one zapise koji se nalaze u bilo kojem od korištenih kataloga, a koji odgovaraju istom krateru, na istom principu kao što to imaju i svi krateri u MA132843GT katalogu kratera Marsa. Tako je omogućeno korištenje svih dosad dostupnih značajki. Time se primjerice vrsta kratera koja je pridijeljena na temelju optičkih slika može uspoređivati s veličinama koje se mogu mjeriti iz topografskih slika. Primjer je omjer dubine i dijametra, koji može izmjeriti i temeljni CDA i CDA koji je temeljen na

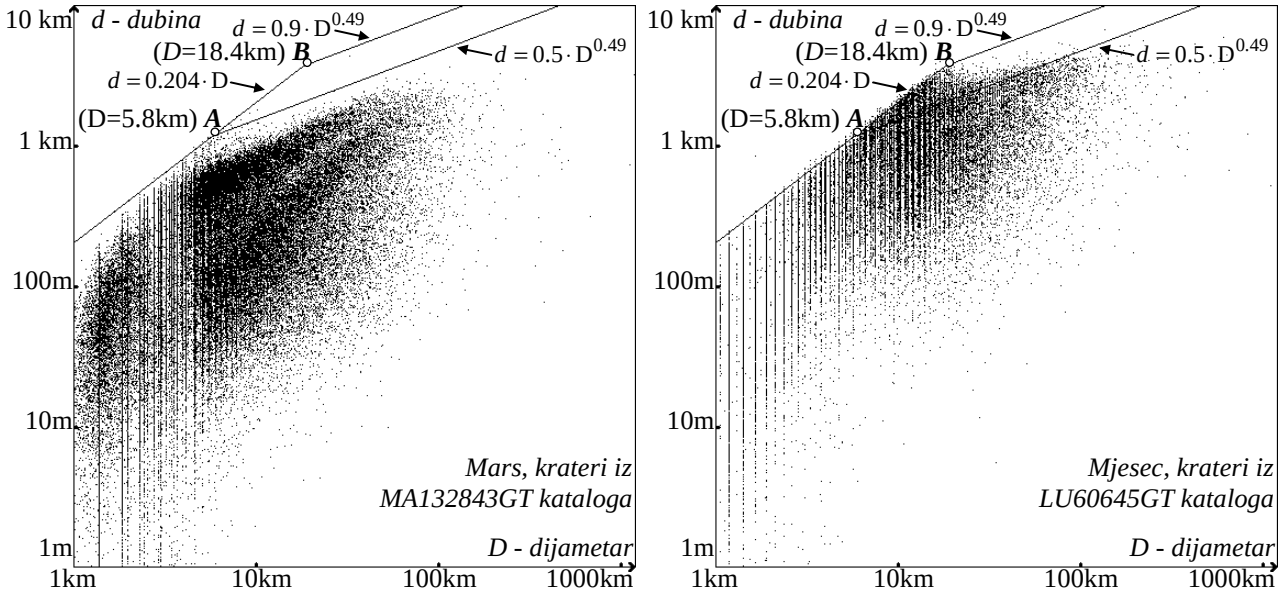
interpolaciji, stoga je i to mjerenje dodano u završni katalog kao primjer jedne od značajki. U budućem radu tako se mogu dodati i brojne druge značajke koje se mogu izmjeriti CDA-ovima.



Slika 66. Integracija prethodnih kataloga Mjeseca (LU8639N, LU14923R i LU5185H) u LU60645GT, po uzoru na referentni katalog Marsa. © 2011 Elsevier (Salamunićcar et al., 2011f).

Kad je uz MA132843GT katalog kratera Marsa postao dostupan i LU60645GT katalog kratera Mjeseca, omogućila se usporedba morfometrijskih mjerenja kratera Marsa i Mjeseca. CDA temeljen na interpolaciji ovdje se može koristiti za mjerenje odnosa dubine i dijametra svih kratera

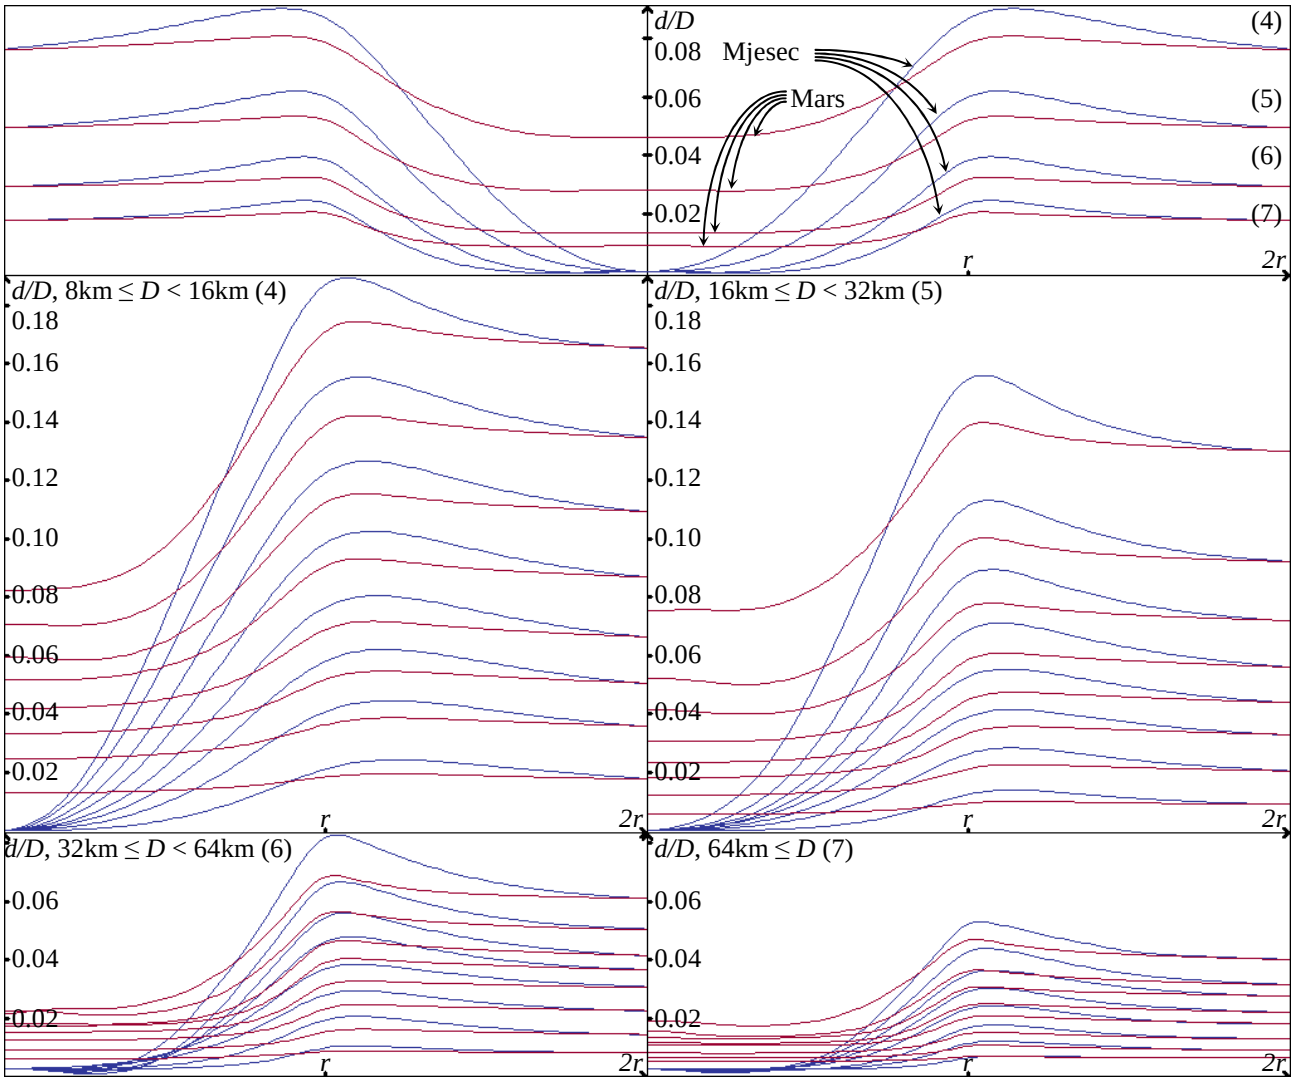
te izračunavanja njihovih topografskih profila. Slika 68 prikazuje tranziciju između velikih i malih kratera, različitih morfoloških karakteristika. Na Marsu je ona otprilike kod D=5.8 km, dok je na Mjesecu otprilike kod D=18.4 km.



Slika 67. Odnos dubine/dijametra u log/log grafu za Mars (gore lijevo) i Mjesec (gore desno). © 2011 Elsevier (Salamunićcar et al., 2011f).

Kako bi se detaljnije usporedili topografski poprečni profili, svaki krater klasificiran je u jedan od sedam sljedećih razreda: (1) 1km ≤ D < 2km; (2) 2km ≤ D < 4km; (3) 4km ≤ D < 8km; (4) 8km ≤ D < 16km; (5) 16km ≤ D < 32km; (6) 32km ≤ D < 64km; i (7) 64km ≤ D. Slika 68 (gore) pokazuje usporedbu prosječnih topografskih poprečnih profila kratera Mjeseca i Marsa četiriju odabranih razreda. Oni slijede trend različitosti koji je prethodno pokazan za najmlađe kratere, gdje je za kratere Mjeseca, kako vidimo iz ove dodatne analize, odnos dubine i dijametra oko dva puta veći nego za kratere Marsa. Kako bi se još detaljnije usporedili topografski poprečni profili, napravljena je i sljedeća analiza. Svakom krateru unutar razreda uspoređen je njegov odnos dubine i dijametra s prosječnom vrijednosti tog razreda, kako bi se izvršila klasifikacija u dva dodatna razreda, s obzirom na manji ili veći odnos dubine i dijametra od prosječnog za taj razred. Navedeni postupak ponovljen je tri puta i na taj način krateri svakog od sedam glavnih razreda dodatno su klasificirani u 8 podrazreda. Slika 68 (dolje) prikazuje rezultate ove dodatne analize. Trend različitosti kratera Marsa i Mjeseca konzistentan je za sve grupe kratera, od onih najmlađih i najbolje očuvanih, do onih najstarijih i najviše erodiranih.

Na prethodni način, na praktičnom primjeru, pokazano je kako se katalozi kratera koji su rezultat CDA-ova ovoga rada, te sami CDA-ovi, mogu koristiti u planetarnim istraživanjima. Važnost primjene CDA-ova je mogućnost mjerenja različitosti kratera na dva različita planetarna tijela, ili potencijalno i na dvjema različitim regijama istog planetarnog tijela, kako bi se pokazalo, odnosno dokazalo da su na njima bili različiti uvjeti, ili u vremenu nastanka kratera, ili tijekom erozije samih kratera.



Slika 68. Prosječni topografski poprečni profili za četiri grupe (sredina) i detaljnija analiza svake grupe (dolje). © 2011 Elsevier (Salamunićcar et al., 2011f).

9.3. Vrednovanje metoda za detekciju kratera

Vrednovanje metoda za detekciju kratera značajno ovisi o: vrsti slika koje CDA koristi; koji se referentni katalog i metoda za uparivanje kratera CDA-ovog kataloga i referentnog kataloga koriste; te koristi li se F-ROC, A-ROC, Q ili neka druga metoda vrednovanja. Također, vrednovanje je znatno realnije, odnosno kvalitetnije, ako se promatraju detektirani krateri cijelog lunarnog, odnosno planetarnog tijela, nego kada se vrednuju rezultati samo nekih slika koje predstavljaju vrlo mali postotak ukupne površine. Jedini CDA za koji je pokazana mogućnost obrade globalnih topografskih slike i pritom generiranje kataloga kratera je Stepinskov i Urbachov (2008) CDA, stoga će rezultati CDA-ova ovoga rada biti upravo s njime i uspoređeni. Vrednovanje metoda razvijenih u ovome radu opisano je u sljedećim potpoglavljima:

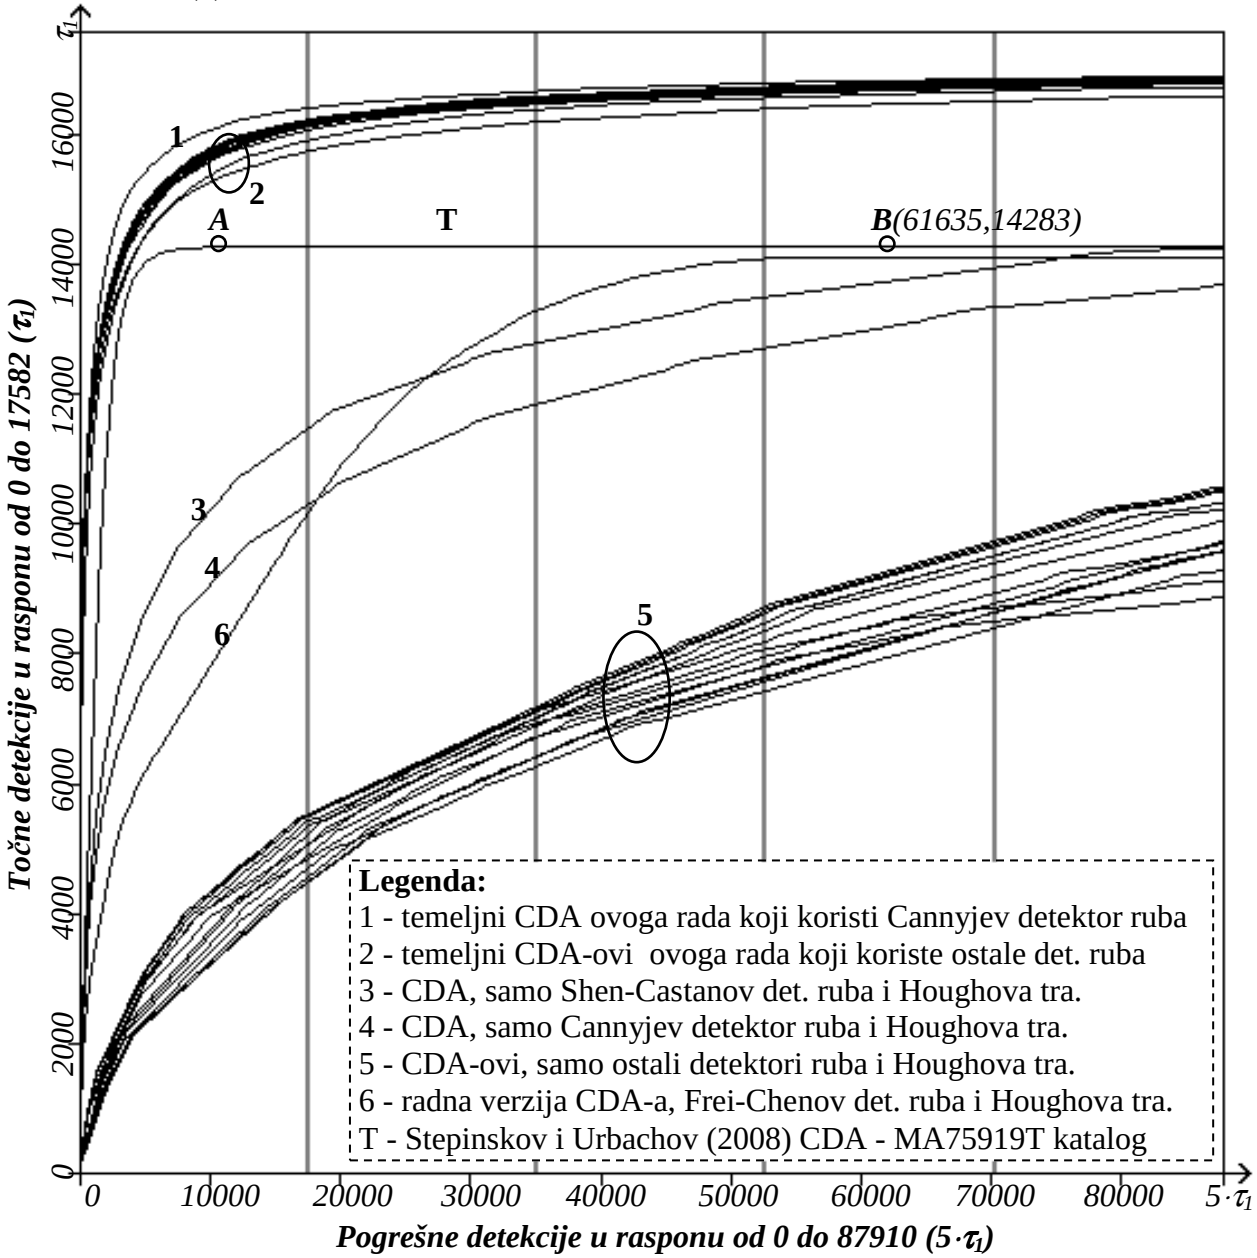
- 9.3.1. Vrednovanje temeljne metode za detekciju;
- 9.3.2. Vrednovanje metode za detekciju temeljene na interpolaciji u obliku kratera;
- 9.3.3. Vrednovanje metode za detekciju temeljene na strojnom učenju;
- 9.3.4. Međusobna usporedba relativnih doprinosa metoda za detekciju.

9.3.1. Vrednovanje temeljne metode za detekciju

Temeljna metoda za detekciju kratera, opisana u poglavlju 4, vrednuje se u ovom poglavlju korištenjem: 1/64° i 1/128° MOLA podataka; i temeljnog i naprednog algoritma za uparivanje kratera CDA-ovog kataloga i referentnog kataloga, koji kratere uparuju do f_m<0.5, odnosno do f_m<3; koristeći referentne kataloge (MA17582GT, MA57633GT i MA130301GT); te F-ROC krivulje odnosno površine ispod iste.

Cannyjev i Shen-Castanov detektor ruba daju značajno bolje rezultate od detektora ruba koji su im prethodili, stoga se u prvom koraku pokazuje koliko su CDA-ovi koji koriste ta dva detektora ruba bolji od onih koji koriste prethodne jednostavnije i po svojstvima lošije detektore ruba. Pokazuje se i koliko su CDA-ovi koji koriste metode razvijene u ovome radu bolji od CDA-ova koji ih ne koriste. Slika 69 prikazuje rezultate F-ROC vrednovanja temeljnog CDA-a (odnosno nekoliko varijacija istog, koristeći različite parametrizacije i detektore ruba) te se isti uspoređuju sa Stepinskovim i Urbachovim (2008) CDA-om, odnosno njihovim MA75919T katalogom. Također se uspoređuju s radnom verzijom CDA-a temeljenog na Frei-Chenovom (1977) detektoru ruba i Houghovoj transformaciji (Salamunićcar i Lončarić, 2006b), koji se koristio prilikom razvoja okoline za razvoj CDA-ova (Salamunićcar i Lončarić, 2008d). Slika 17 (CDA-3) također prikazuje radnu verziju CDA-a temeljenog na Frei-Chenovom (1977) detektoru ruba i Houghovoj transformaciji (Salamunićcar i Lončarić, 2006b). Primjeri slikovnih elemenata na F-ROC krivulji su *A* i *B*. Slikovni element *B* pokazuje da je 14 283 kratera iz MA75919T pronađeno u MA17582GT katalogu, a 61 635 nije, s tim da je 1 krater obrisan kao duplikat prije F-ROC analize. Krateri između slikovnih elemenata *A* i *B* premali su za vrednovanje korištenjem MA17582GT. Isti krateri nalaze se u sljedećoj verziji potpunijeg referentnog kataloga, a ovdje nisu bitni za usporedbu jer su svi CDA-ovi ravnopravni u usporedbi. Kako iz slike proizlazi, temeljni CDA ovoga rada (1, 2) značajno je bolji od standardnih implementacija temeljenih na Shen-Castanovom (3) i Cannyjevom (4) detektoru ruba, otprilike isto toliko koliko su te dvije implementacije bolje od onih CDA-ova koji se temelje na prethodnim detektorima rubova (5). Rezultati za radnu verziju CDA-a (Salamunićcar i Lončarić, 2006b), kako je prikazano za *s=4%* (6) na slici 7 u prethodnom radu (Salamunićcar i Lončarić, 2008d) i rezultati Stepinskovog i Urbachovog (2008) CDA-a (T) dodani su radi usporedbe. Temeljni CDA i od njih je značajno bolji. Razlog različitog odziva CDA-a (6) od CDA-ova (5) su drugačije karakteristike radne verzije CDA-a. Ista je već imala bolja svojstva nego klasične implementacije, no u isto vrijeme i lošija od CDA-a opisanog u ovom poglavlju. U

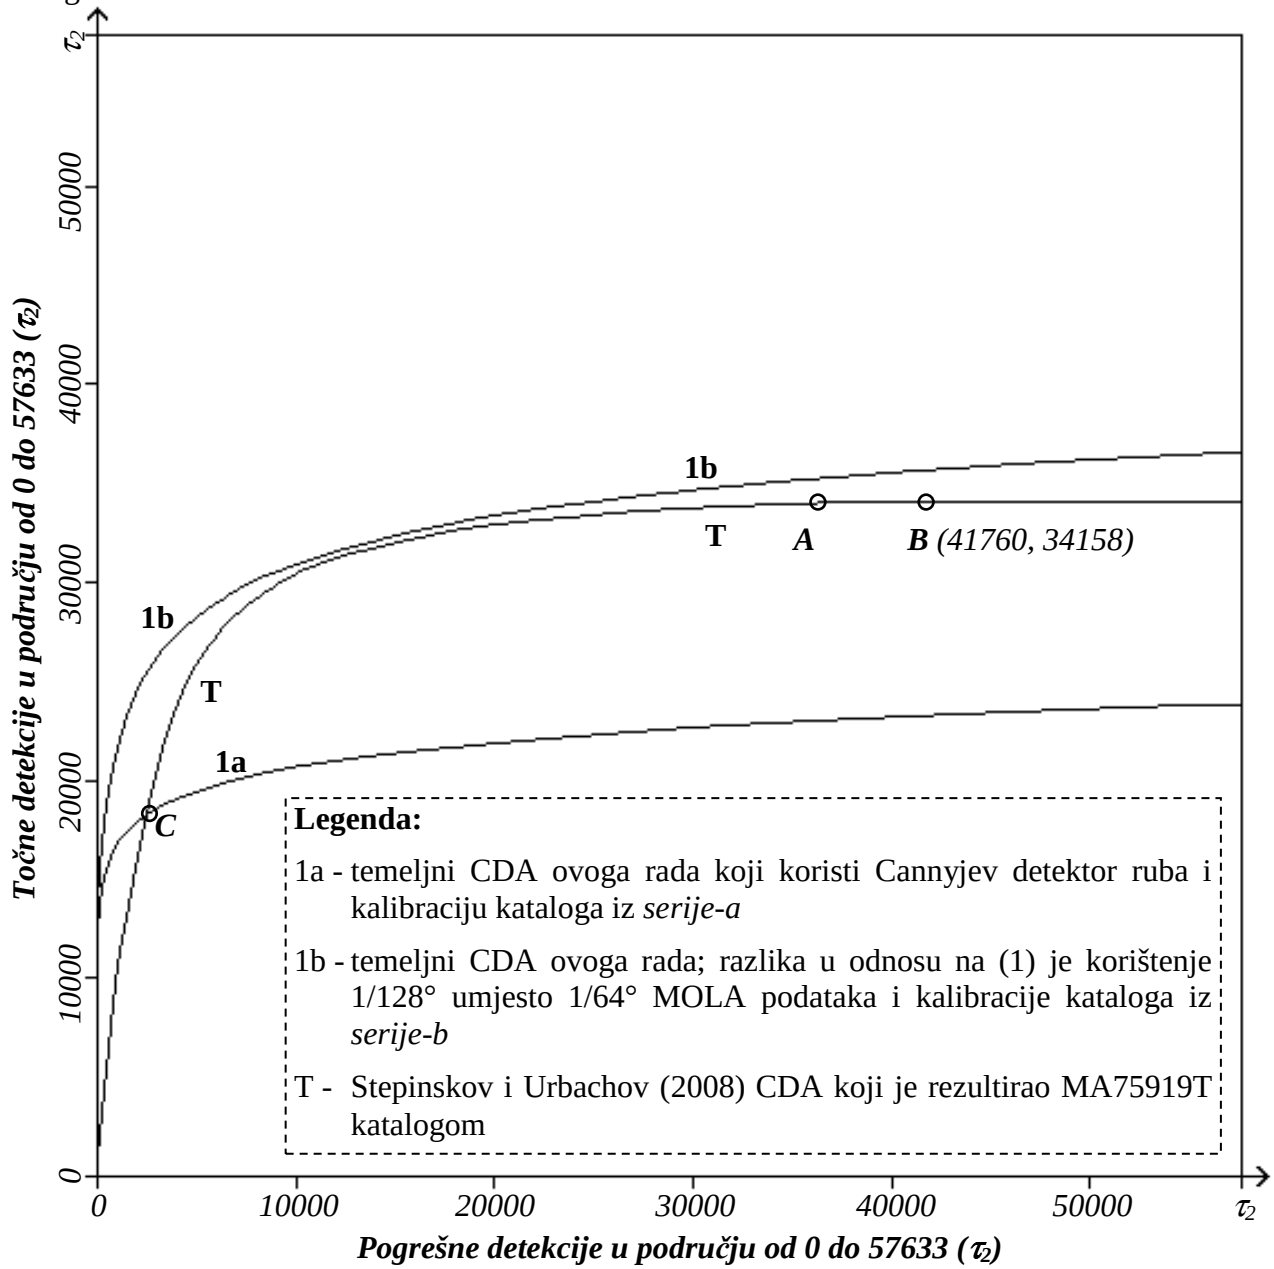
klasičnoj implementaciji CDA temeljen na Shen-Castanovom detektoru ruba bolji je od temeljenog na Cannyjevom detektoru ruba, dok je Cannyjev detektor ruba bolji u kombinaciji s temeljnim CDA-om ovoga rada. Razlog je učinkovitija zamjena izvornog Cannyjevog detektora ruba (4) s Cannyjevim detektorom ruba koji koristi gradijent (1) nego što je postignuto sa Shen-Castanovim detektorom ruba (3).



Slika 69. F-ROC vrednovanje temeljnog CDA-a korištenjem MA17582GT kataloga, 1/64° MOLA podataka, f_m<0.5, te njegova usporedba s radnim verzijama CDA-ova te Stepinskovim i Urbachovim (2008) CDA-om. © 2010 IEEE (Salamunićcar i Lončarić, 2010b).

Potpunost referentnog kataloga znatno utječe na rezultate vrednovanja i usporedbe različitih CDA-ova, stoga se u sljedećom koraku vrednovanja zamijenio referentni katalog MA17582GT s katalogom MA57633GT. Taj katalog je važan za usporedbu dva različita CDA-a zato što sadrži samo one kratere koji su prethodno ručno katalogizirani, stoga pruža najvišu moguću objektivnost u vrednovanju i usporedbi različitih CDA-ova. Također, s obzirom na to da i ulazni podaci utječu na rezultate vrednovanja, a da je Stepinskov i Urbachov (2008) CDA u svom radu koristio 1/128° podatke, isti su također korišteni. Slika 70 prikazuje rezultate F-ROC vrednovanja. CDA (1a) je bolji od Stepinskovog i Urbachovog (2008) CDA-a (T) koji je rezultirao MA75919T katalogom, ali

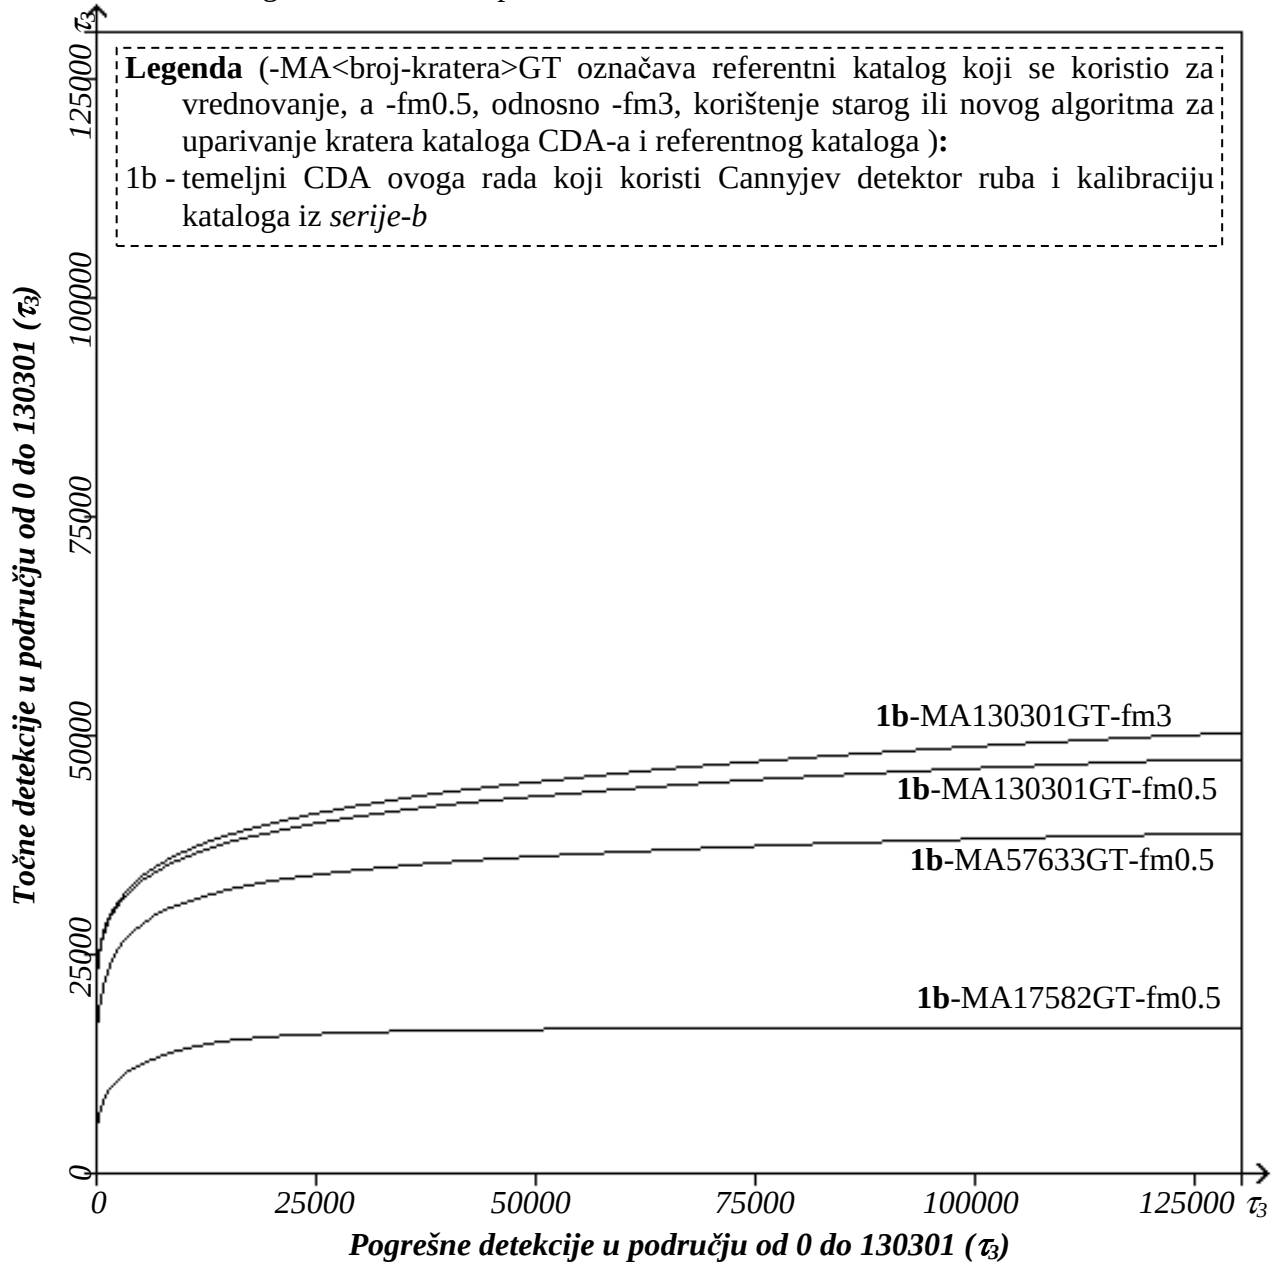
samo do slikovnog elementa *C*. CDA (1a) je naime konfiguriran tako da prije svega traži velike kratere, dok katalog MA75919T Stepinskovog i Urbachovog (2008) CDA-a (T) sadrži mnoge male kratere koji se nalaze u MA57633GT, ali ne i u MA17582GT katalogu. CDA (1b) daje bolje rezultate nego druga dva CDA-a u cijelom području, a jedina je razlika u odnosu na CDA (1a) korištenje vrijednosti *serije-b* za kalibraciju kataloga umjesto vrijednosti *serije-a*. Time je CDA konfiguriran za traženje ne samo velikih kratera, nego i onih manjih koji se nalaze i u MA75919T katalogu.



Slika 70. F-ROC vrednovanje temeljnog CDA-a korištenjem MA57633GT kataloga, 1/64° i 1/128° MOLA podataka, f_m<0.5, te njegova usporedba sa Stepinskovim i Urbachovim (2008) CDA-om. © 2010 IEEE (Salamunićcar i Lončarić, 2010b).

Kako bi se ispitao utjecaj potpunosti referentnog kataloga i metoda za uparivanje kratera CDA-ovog kataloga i referentnog kataloga na vrednovanje CDA-a i usporedbu s drugim CDA-ovima, napravljena je F-ROC analiza koja za isti CDA prikazuje odzive, ovisno o tome koji se referentni katalog i metoda za uparivanje kratera koriste. Slika 71 prikazuje rezultate ove usporedbe. Pritom se koristio CDA koji koristi kalibraciju kataloga iz *serije-b*, i to zato što je u

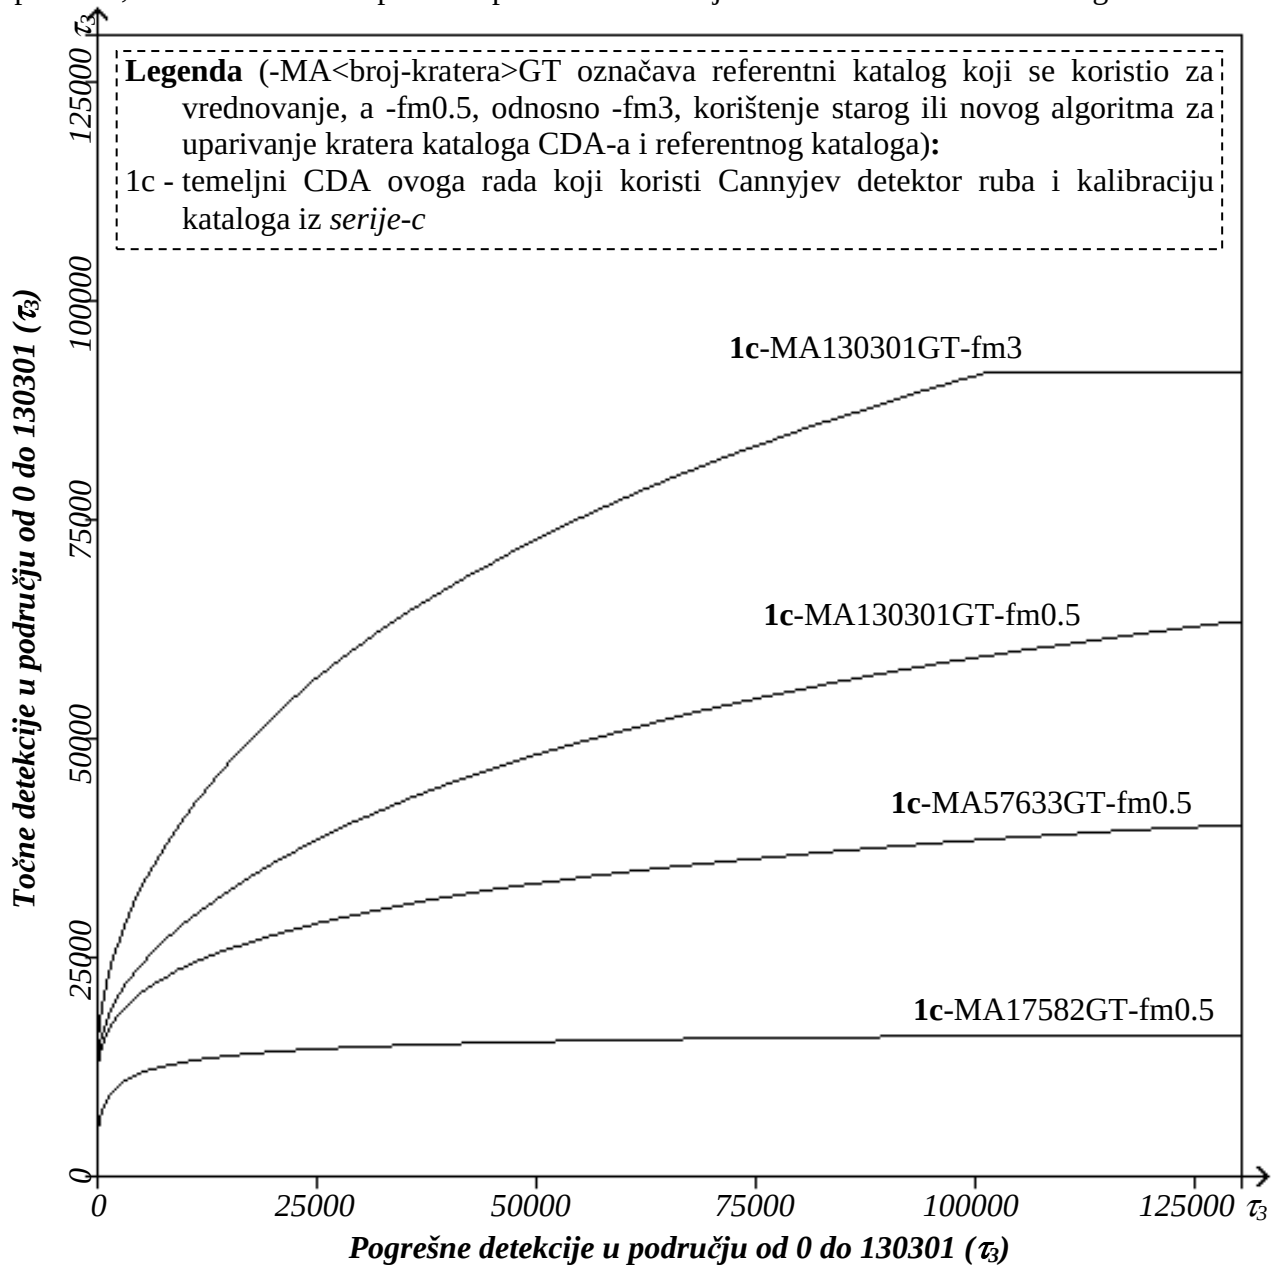
prethodno prikazanoj analizi dao najbolje rezultate. Ova slika prikazuje veliku ovisnost vrednovanja CDA-a koji detektira pretežno kratere veće od 4 km u dijametru o potpunosti referentnog kataloga, a samo manjim dijelom ovisnost o korištenju temeljne (do vrijednosti f_m<0.5), odnosno napredne (do vrijednosti f_m<3) metode za uparivanje kratera. Nova metoda za uparivanje u ovom slučaju daje naime neznatno bolje rezultate od stare metode. Izbor referentnog kataloga značajno utječe na rezultate vrednovanja, odnosno usporedbe dva CDA-a. Ako se u jednom radu za vrednovanje koristi MA17582GT, a u drugom MA57633GT katalog, ili u jednom MA57633GT, a u drugom MA130301GT katalog, rezultati nisu usporedivi.



Slika 71. Usporedba F-ROC odziva temeljnog CDA-a *serije-b* za MA17582GT, MA57633GT i MA130301GT, za f_m<0.5 i f_m<3, korištenjem 1/128° MOLA podataka. © 2008 Elsevier (Salamunićcar et al., 2011a).

Radi upotpunjavanja prethodne analize, temeljni CDA ovoga rada koji koristi vrijednosti kalibracije kataloga *serije-b* zamijenio se istim CDA-om, a jedina razlika je korištenje vrijednosti kalibracije kataloga *serije-c*. Time se detektira i znatan broj kratera manjih od 4 km u dijametru. Slika 72 prikazuje rezultate ove usporedbe. Ova slika prikazuje veliku ovisnost vrednovanja CDA-a

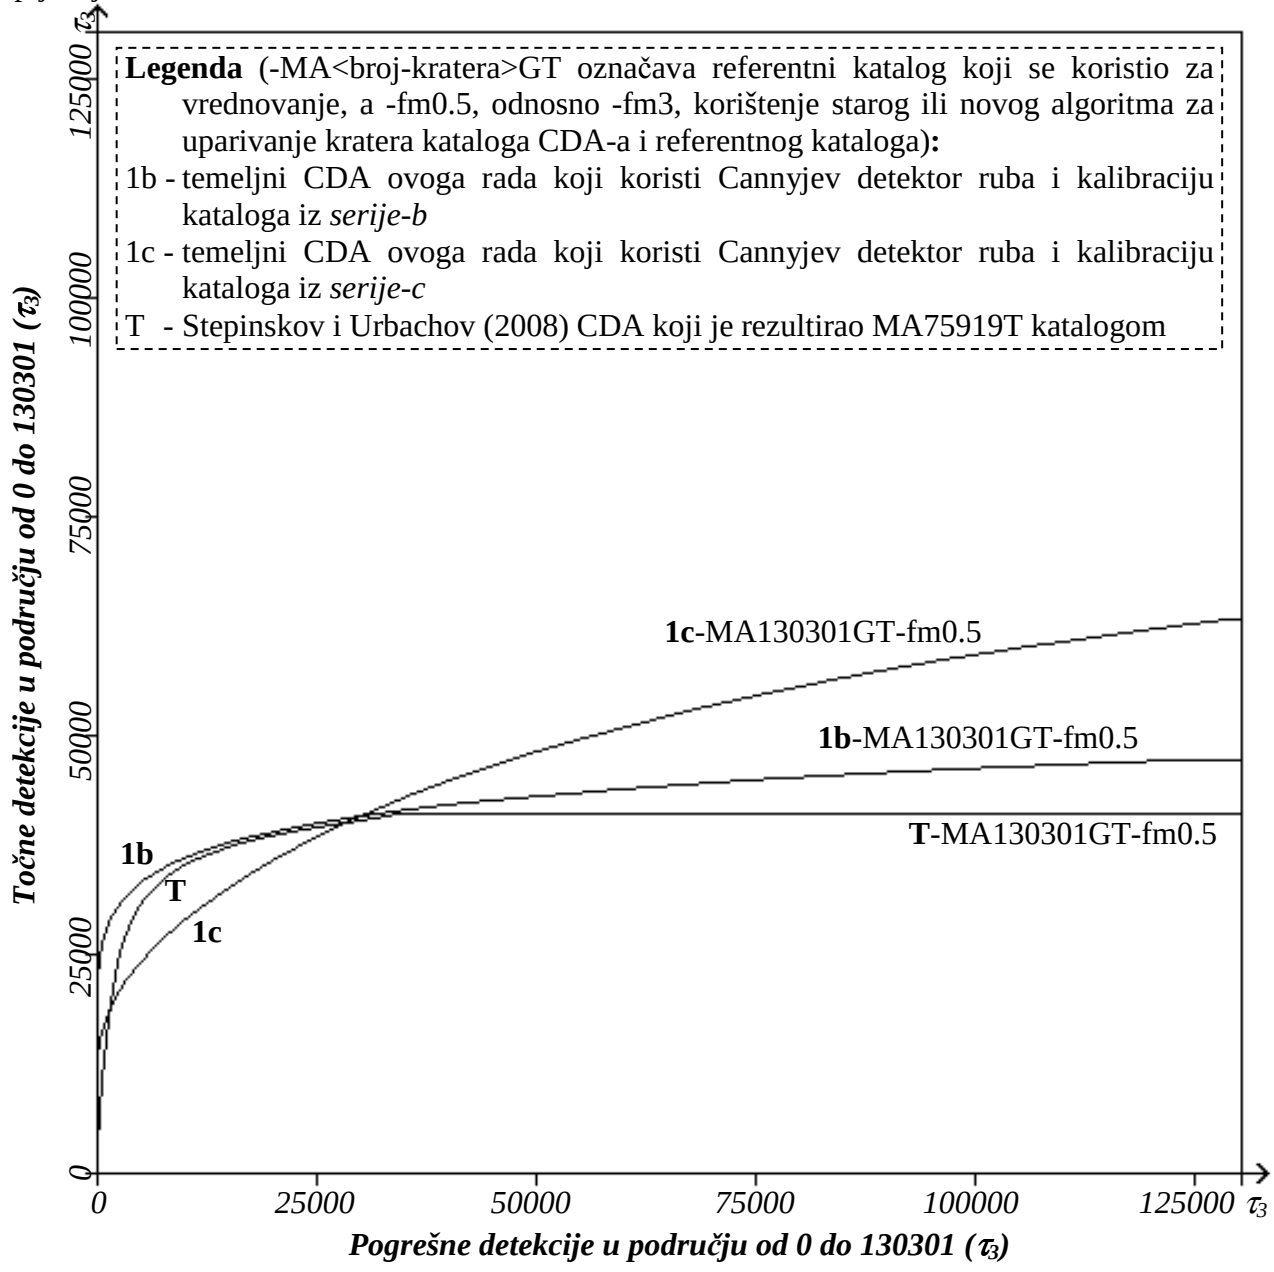
koji detektira i znatan broj kratera manjih od 4 km u dijametru i o potpunosti referentnog kataloga i o korištenju temeljne (do vrijednosti f_m<0.5), odnosno napredne (do vrijednosti f_m<3) metode za uparivanje kratera. Ovdje nova metoda za uparivanje daje puno bolje rezultate nego temeljna metode, upravo za male kratera. Izbor metode za uparivanje kratera CDA-ovog kataloga te referentnog kataloga stoga značajno utječe na rezultate vrednovanja, odnosno usporedbe dva CDA-a. Ako se u jednom radu za vrednovanje koristi f_m<0.5, a u drugom f_m<3, rezultati nisu usporedivi, kao što nisu bili usporedivi prilikom korištenja različitih referentnih kataloga.



Slika 72. Usporedba F-ROC odziva temeljnog CDA-a *serije-c* za MA17582GT, MA57633GT i MA130301GT katalog, za f_m<0.5 i f_m<3, korištenjem 1/128° MOLA podataka. © 2008 Elsevier (Salamunićcar et al., 2011a).

Kako bi se prethodna razmatranja uzela u obzir, u prvom koraku napravljena je F-ROC analiza, pri čemu se referentni katalog MA57633GT zamijenio referentnim katalogom MA130301GT. Ova usporedba ne bi bila objektivna za neki treći CDA, no prihvatljiva je za usporedbu temeljnog CDA-a ovoga rada i Stepinskovog i Urbachovog (2008) CDA-a koji je rezultirao MA75919T katalogom. Referentni katalog MA130301GT sadrži naime i one točne

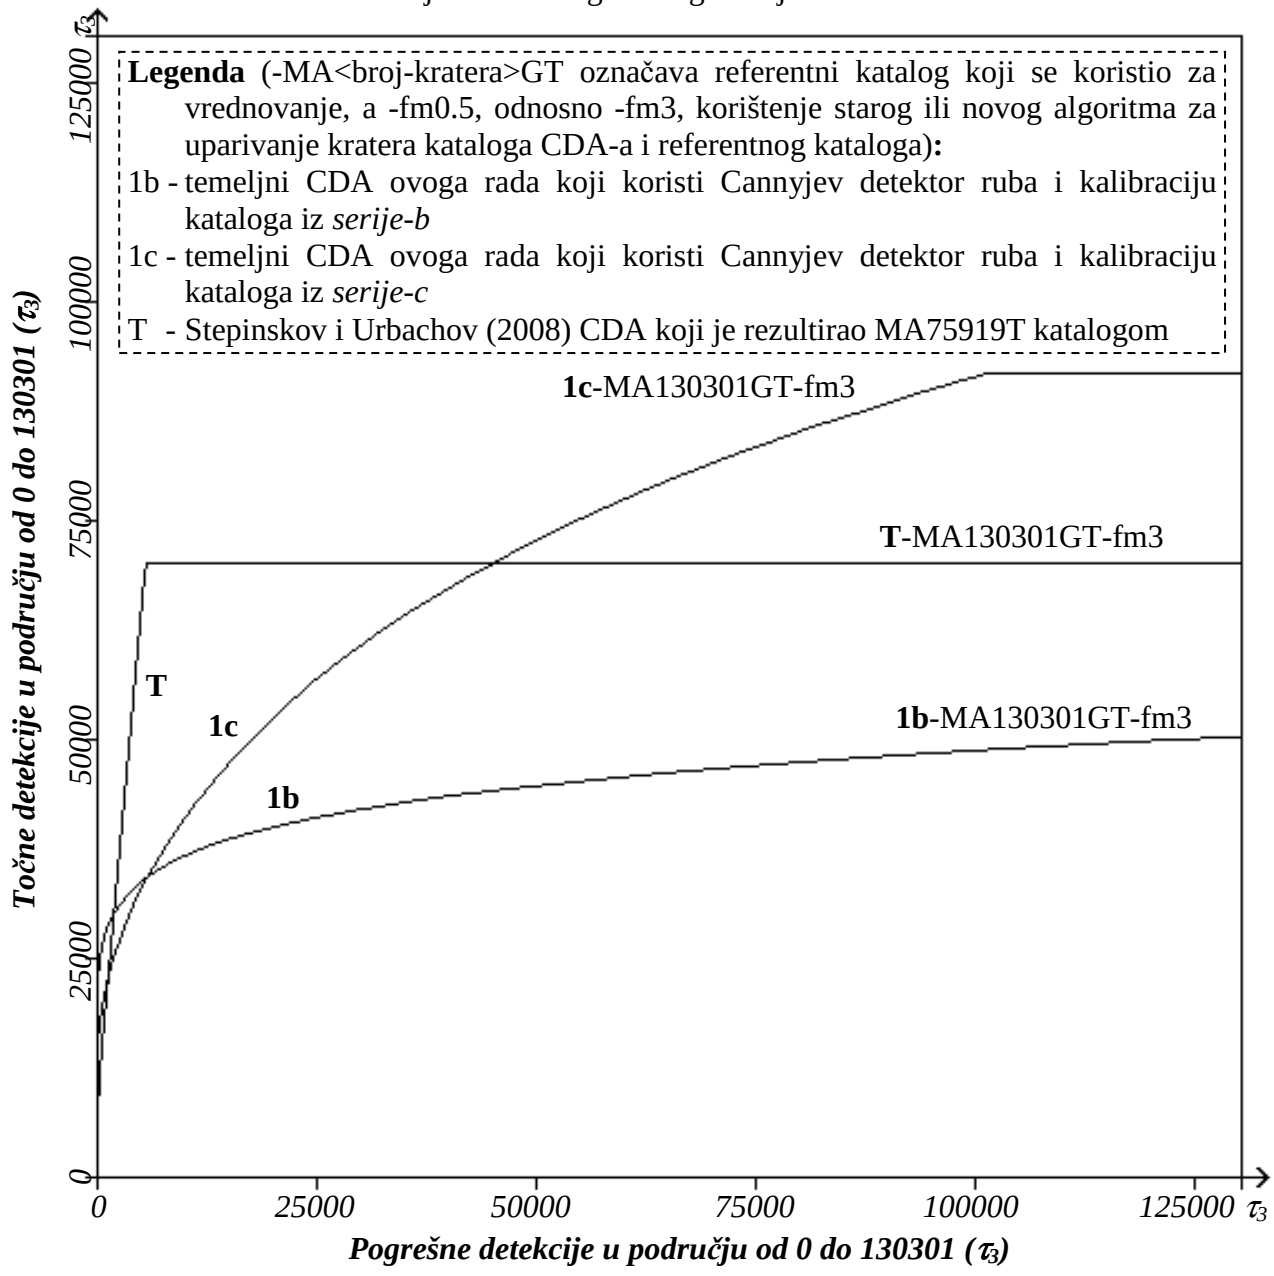
detekcije koje je pronašao temeljni CDA ovoga rada i one točne detekcije koje je pronašao Stepinskov i Urbachov (2008) CDA (koje se nalaze u MA75919T katalogu). Slika 73 prikazuje rezultate F-ROC analize. Temeljni CDA koji detektira pretežno kratere veće od 4 km u dijametru (1b) bolji je u cijelom području od Stepinskovog i Urbachovog (2008) CDA-a (T). Ujedno je CDA koji detektira i znatan broj kratera manjih od 4 km u dijametru (1c) u jednom dijelu lošiji od ostala dva CDA-a, a u drugom dijelu bolji. Zaključuje se da temeljni CDA (1c) detektira znatan broj malih objekata koji su pogrešne detekcije, ali i znatan broj malih kratera koje ostala dva CDA-a ne uspijevaju detektirati.



Slika 73. F-ROC vrednovanje temeljnog CDA-a korištenjem MA130301GT kataloga, 1/128° MOLA podataka, f_m<0.5, te njegova usporedba sa Stepinskovim i Urbachovim (2008) CDA-om. © 2008 Elsevier (Salamunićcar et al., 2011a).

Vrednovanje može znatno ovisiti i o metodi koja uparuje kratere iz CDA-ovog kataloga s referentnim katalogom. Stoga je u sljedećom koraku napravljena F-ROC analiza, pri čemu se uz referentni katalog MA130301GT koristila i napredna metoda za uparivanje do f_m<3. Slika 74 prikazuje rezultate F-ROC analize. Temeljni CDA koji detektira pretežno kratere veće od 4 km u

dijametru (1b) više nije bolji u cijelom području od Stepinskovog i Urbachovog (2008) CDA-a (T). Ujedno je CDA koji detektira i znatan broj kratera manjih od 4 km u dijametru (1c) i dalje u jednom dijelu lošiji od ostala dva CDA-a, a u drugom dijelu bolji od ostala dva CDA-a. Stepinskov i Urbachov (2008) CDA (T) u jednom je dijelu stoga bolji od temeljnog CDA-a koji je rezultat ovoga rada, ako se uzmu u obzir i oni krateri koji su detektirani s neprecizno određenim koordinatama ili dijametrom. S druge strane, temeljni CDA ovoga rada, koji koristi vrijednosti kalibracije kataloga *serije-c* (1c), znatno je bolji od Stepinskovog i Urbachovog (2008) CDA-a (T), u smislu da može detektirati znatno više kratera. To je važno zbog katalogiziranja što više kratera.

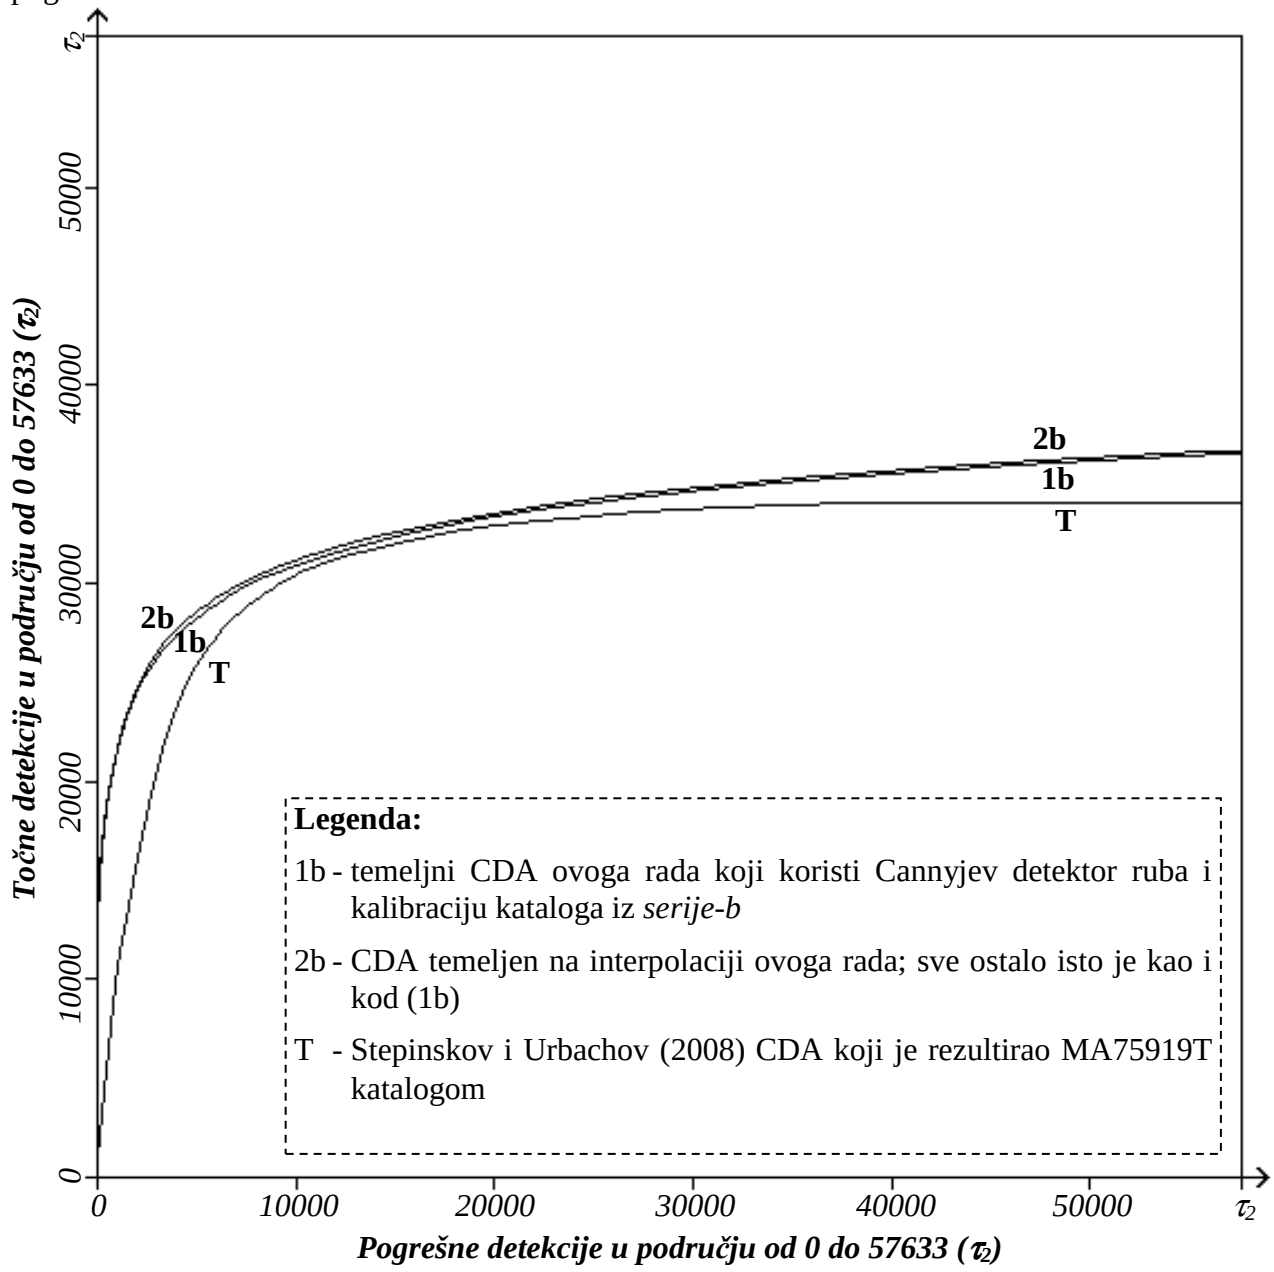


Slika 74. F-ROC vrednovanje temeljnog CDA-a korištenjem MA130301GT kataloga, 1/128° MOLA podataka, f_m<3, te njegova usporedba sa Stepinskovim i Urbachovim (2008) CDA-om. © 2008 Elsevier (Salamunićcar et al., 2011a).

9.3.2. Vrednovanje metode za detekciju temeljene na interpolaciji u obliku kratera

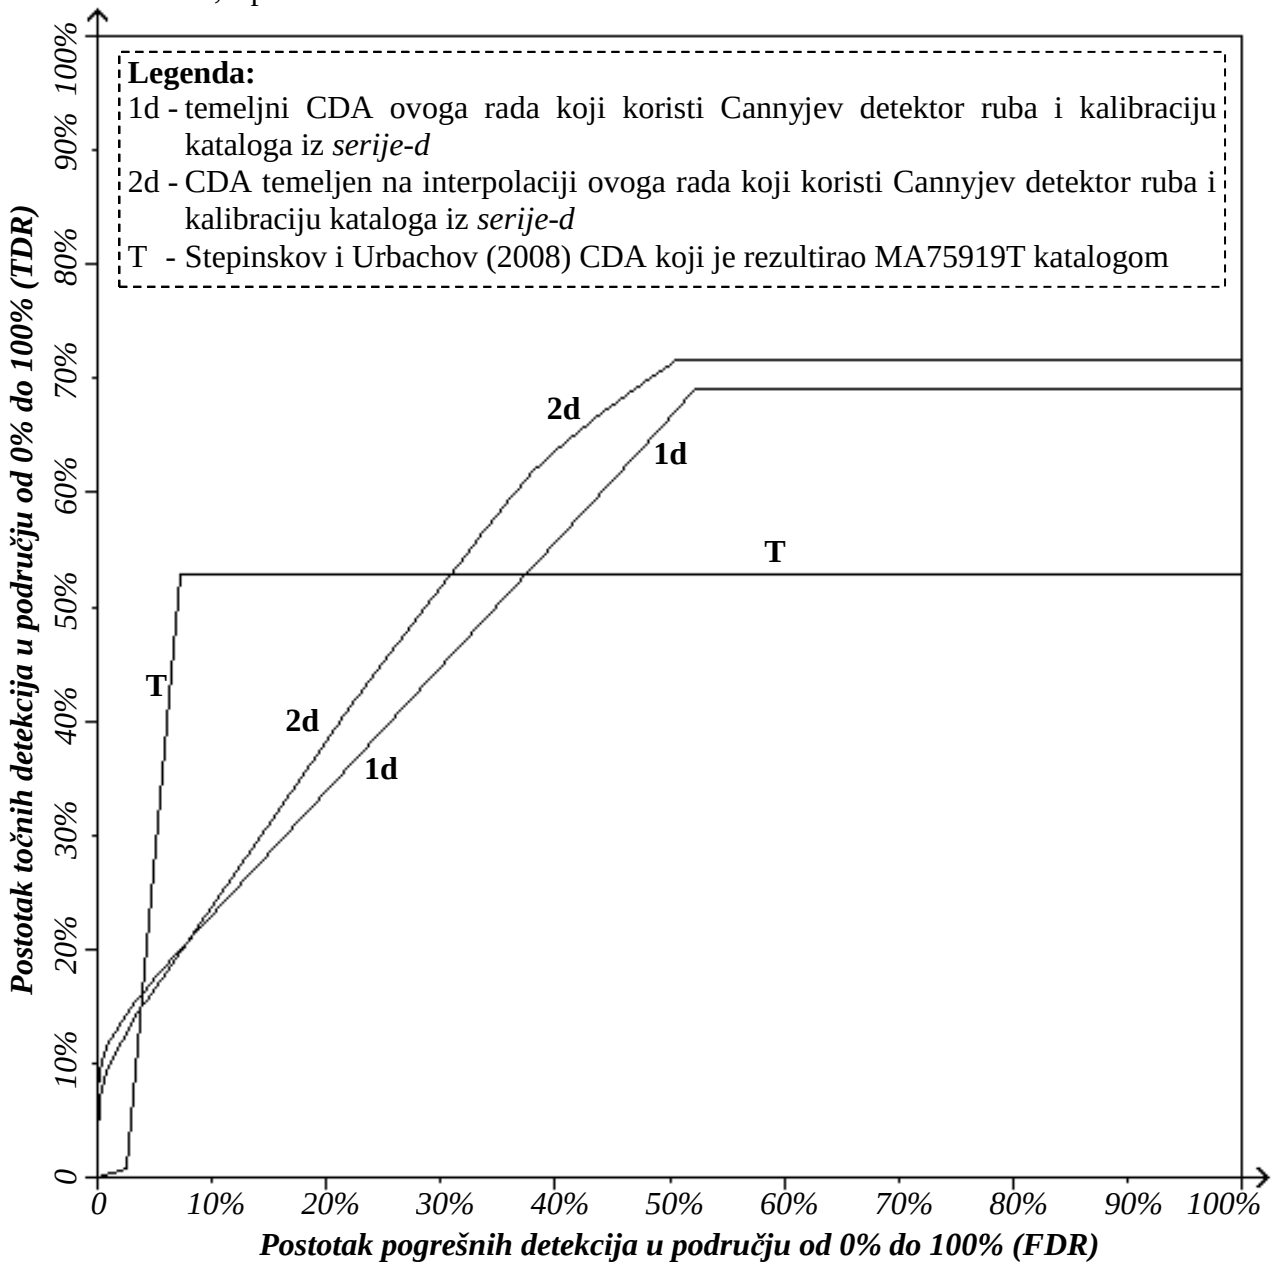
Koristeći zaključke iz vrednovanja temeljnog CDA-a ovoga rada, CDA temeljen na interpolaciji u obliku kratera vrednovan je i različitim načinima uspoređivan sa Stepinskovim i Urbachovim (2008) CDA-om.

U prvom koraku cilj je bio analiza poboljšanja CDA-a interpolacijom u odnosu na temeljni CDA-a ovoga rada. Slika 75 prikazuje rezultate F-ROC analize. Temeljni CDA (1b) je bolji od Stepinskovog i Urbachovog (2008) CDA-a (T) u cijelom području, kao što je također u cijelom području CDA temeljen na interpolaciji (2b) bolji od temeljnog CDA-a (1b). No poboljšanje postignuto interpolacijom u ovom slučaju nije značajno. Razlog je korištenje vrijednosti kalibracije kataloga iz *serije-b*, čime se detektiraju pretežno krateri veći od 4 km u dijametru. Tada se i bez interpolacije dobivaju dobri rezultati, zahvaljujući visokoj horizontalnoj rezoluciji korištene topografske slike.



Slika 75. F-ROC vrednovanje interpolacijskog CDA-a korištenjem MA57633GT kataloga, 1/128° MOLA podataka, f_m<0.5, te njegova usporedba sa Stepinskovim i Urbachovim (2008) CDA-om. © 2011 Elsevier (Salamunićcar et al., 2011f).

Kako bismo uzeli u obzir važnost potpunosti referentnog kataloga, metode za uparivanje kratera, korištene analize, kao i detekcije znatnog broja kratera manjih od 4 km u dijametru, vrijednosti kalibracije *serije-b* zamijenjene su *serijom-d* te se koristilo prikladnije vrednovanje za taj slučaj. Slika 76 prikazuje rezultate A-ROC analize. CDA temeljen na interpolaciji ovoga rada (2d) značajno je bolji od temeljnog CDA-a ovoga rada (1d), s obzirom na značajno veću površinu ispod A-ROC krivulje, kao i ukupnog ostvarenog postotka točnih detekcija. CDA temeljen na interpolaciji ovoga rada (2d) bolji je od Stepinskovog i Urbachovog (2008) CDA-a (T) jer je ukupan postignuti postotak točnih detekcija značajno veći. U jednom je međutim segmentu Stepinskov i Urbachov (2008) CDA (T) bolji od CDA-a temeljenog na interpolaciji (2d) jer za isti broj točnih detekcija ima manji broj pogrešnih. Ukoliko se kao kriterij koji CDA je bolji uzima površina ispod A-ROC krivulje, utoliko je temeljni CDA (1d) s površinom 53.977% bolji od Stepinskovog i Urbachovog (2008) CDA-a (T) s površinom 50.136%. CDA koji koristi interpolaciju (2d) bolji je od oba prethodna CDA-a, s površinom 57.433%.

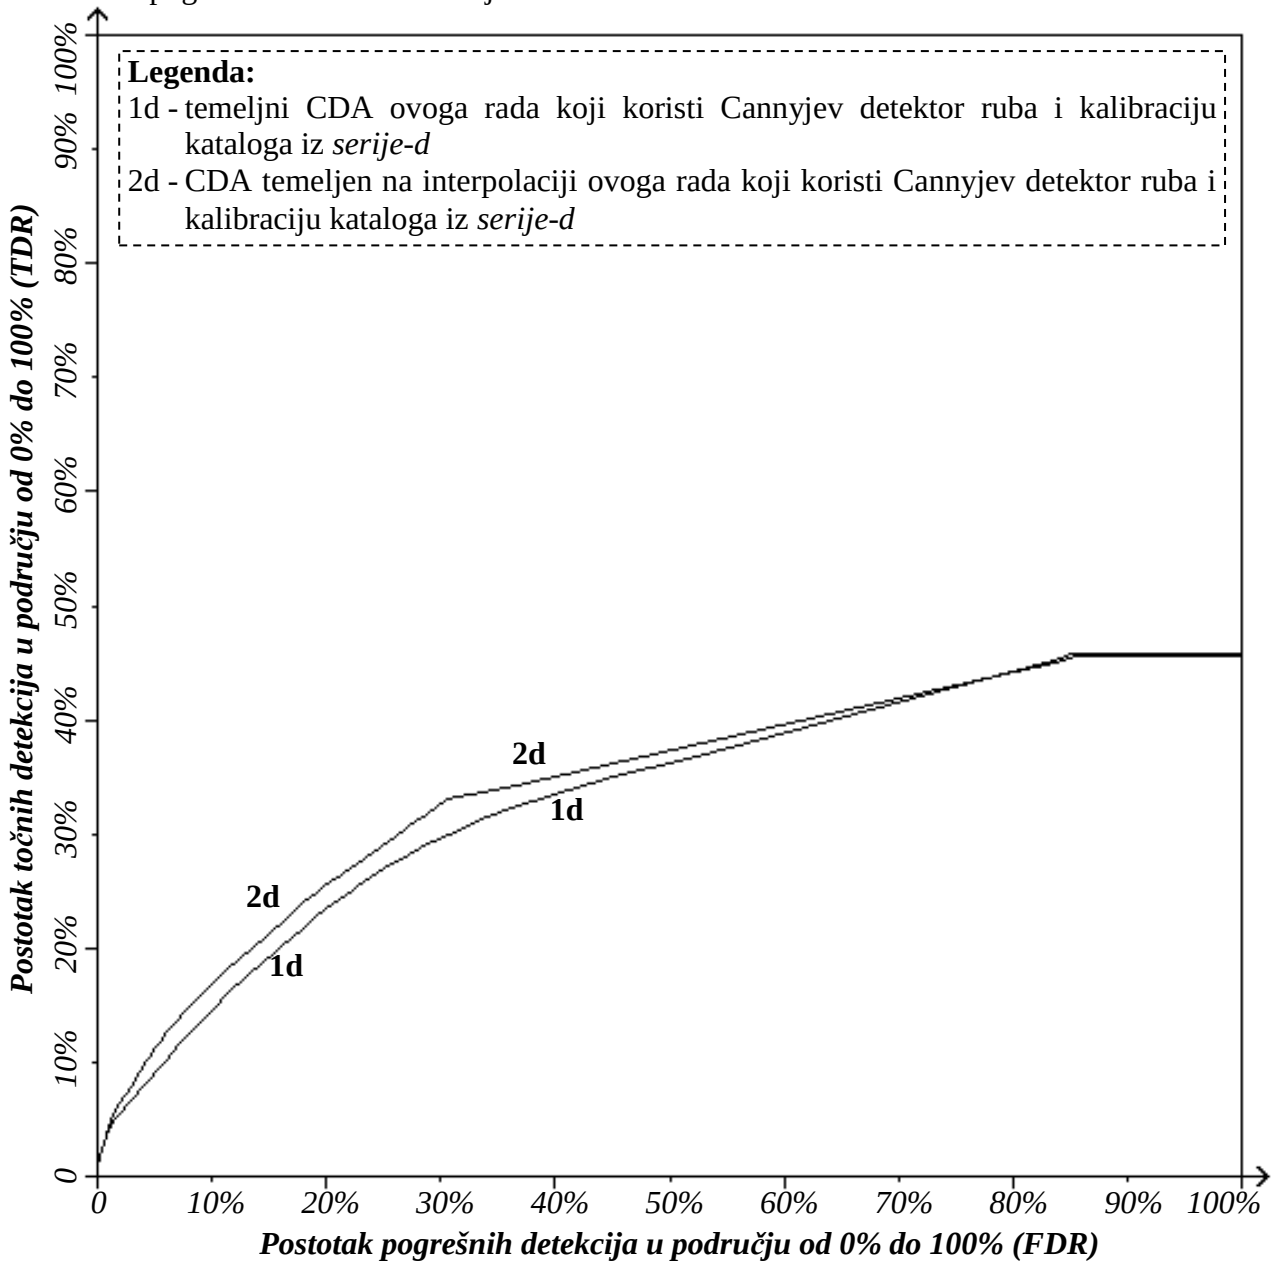


Slika 76. A-ROC vrednovanje interpolacijskog CDA-a korištenjem MA132843GT kataloga, 1/128° MOLA podataka, f_m<3, te njegova usporedba sa Stepinskovim i Urbachovim (2008) CDA-om. © 2011 Elsevier (Salamunićcar et al., 2011f).

Usporedba temeljnog CDA-a te interpolacijskog CDA-a napravljena je i korištenjem i dostupnih podataka za Mjesec. Time se uzima u obzir da CDA ne mora biti jednako učinkovit prilikom obrade topografskih slika Marsa i Mjeseca.

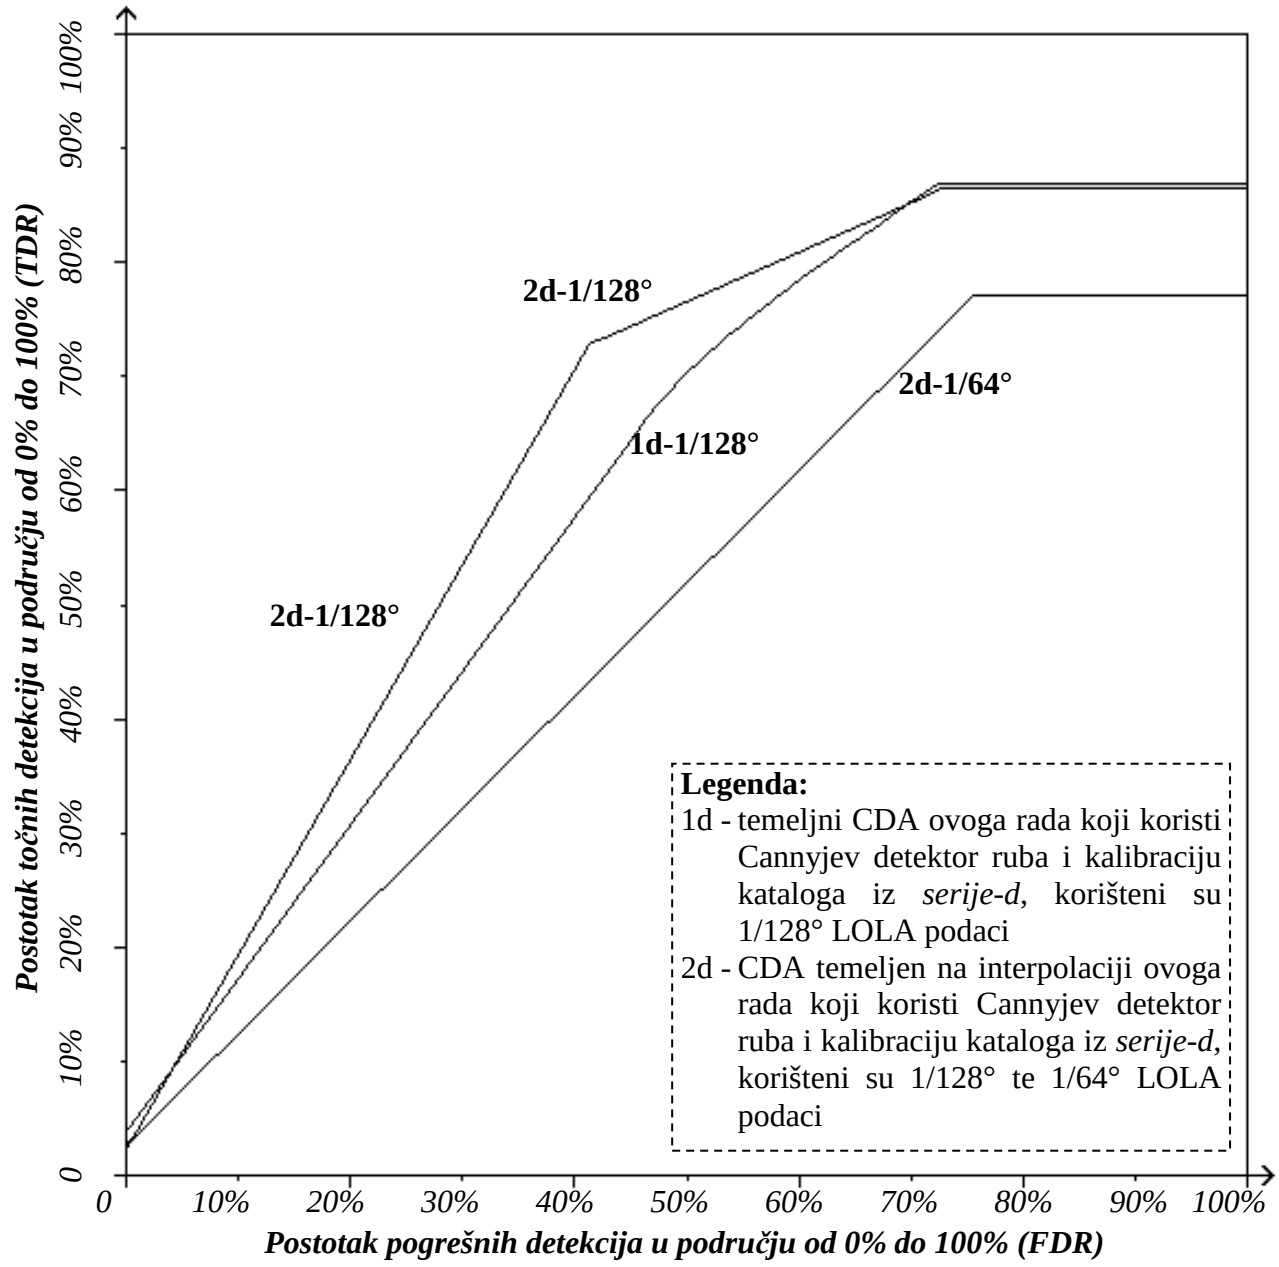
Pritom se nažalost nije mogla napraviti usporedba sa Stepinskovim i Urbachovim (2008) CDA-om, kako je to napravljeno prilikom vrednovanja korištenjem topografskih slika Marsa. Za njega naime nije dostupan rezultirajući katalog za Mjesec.

U prvom koraku napravljena je usporedba temeljnog CDA-a (1d) i interpolacijskog CDA-a (2d), korištenjem 1/16° LALT podataka te LU60645GT referentnog kataloga i uparivanja kratera do f_m<3. Slika 77 prikazuje rezultate A-ROC analize. CDA temeljen na interpolaciji ovoga rada (2d) značajno je bolji od temeljnog CDA-a ovoga rada (1d), s obzirom na to da je površina ispod A-ROC krivulje značajno veća. Primjena interpolacije u obliku kratera stoga daje bolje rezultate od temeljne metode za topografske slike Marsa i Mjeseca.



Slika 77. A-ROC vrednovanje interpolacijskog CDA-a korištenjem LU60645GT kataloga, 1/16° LALT podataka te f_m<3. © 2011 Elsevier (Salamunićcar et al., 2011f).

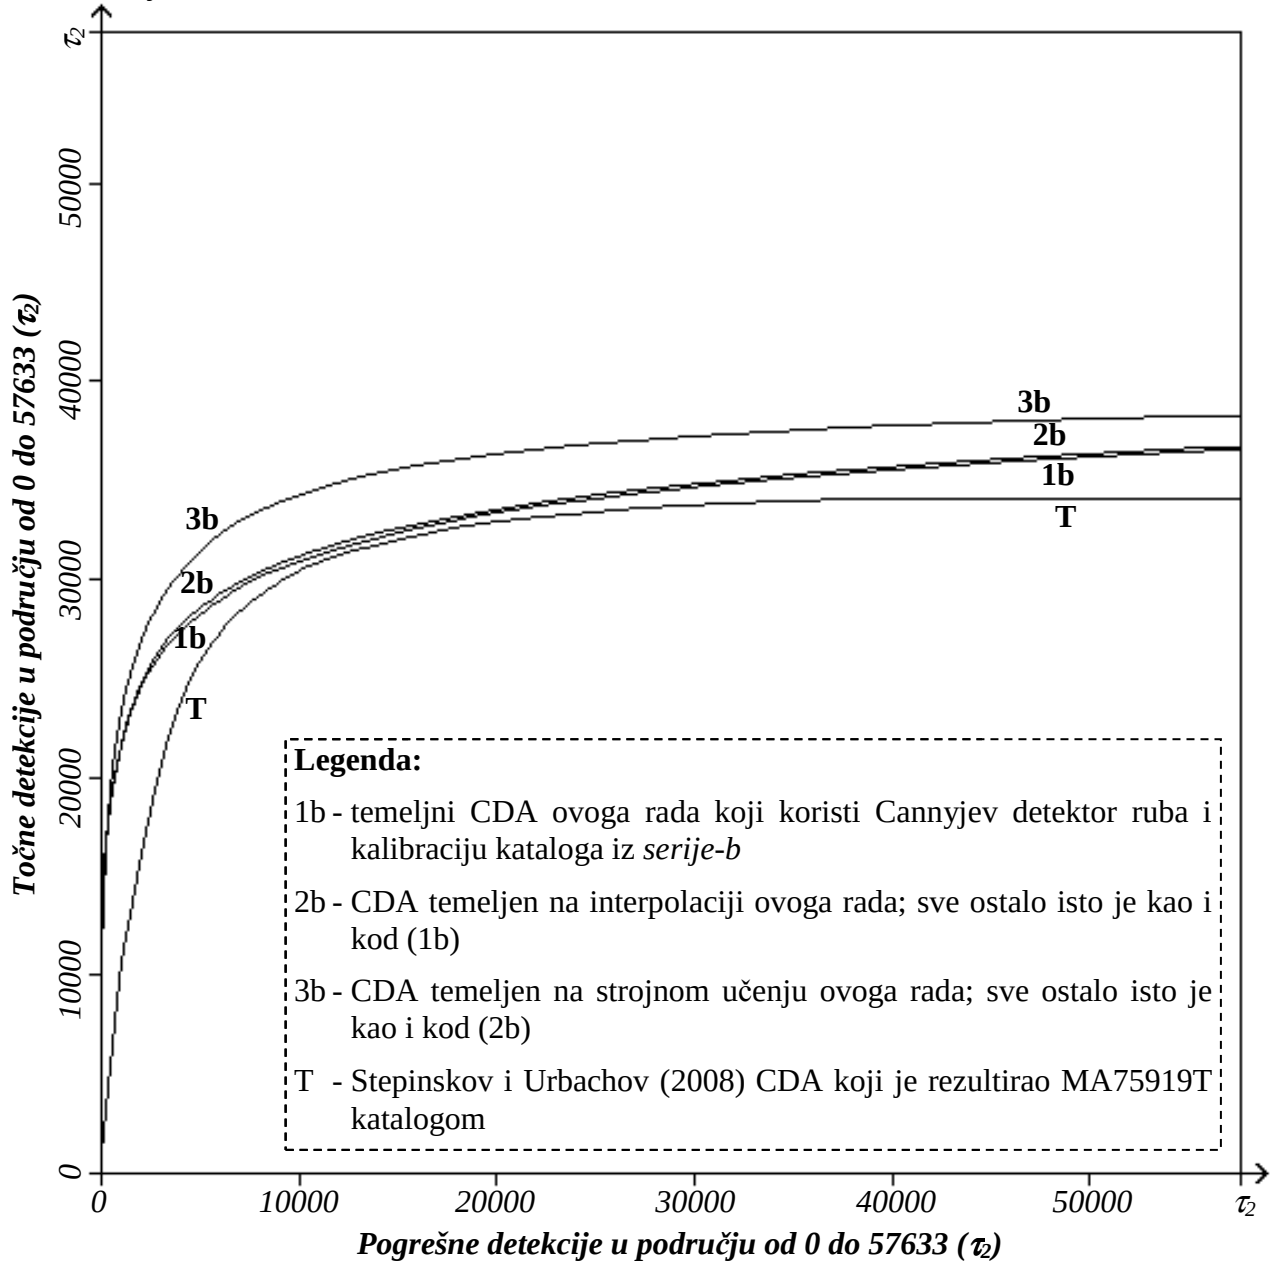
U drugom koraku napravljena je usporedba temeljnog CDA-a (1d) i interpolacijskog CDA-a (2d) korištenjem LOLA podataka dostupnih u višim horizontalnim rezolucijama, 1/64° i 1/128°, dok se ostali elementi vrednovanja nisu mijenjali. Slika 78 prikazuje rezultate A-ROC analize. CDA temeljen na interpolaciji ovoga rada (2d-1/128°) značajno je bolji od temeljnog CDA-a ovoga rada (1d-1/128°) s obzirom na to da je površina ispod A-ROC krivulje značajno veća. U svrhu usporedbe prikazan je odziv interpolacijskog CDA-a u slučaju korištenja 1/64° LOLA podataka (2d-1/64°), kako bi se pokazao utjecaj horizontalne rezolucije korištenih podataka na rezultat rada CDA-a. Iz istog se vidi kako su rezultati CDA-a (2d) značajno bolji za 1/128° LOLA podatke (2d-1/128°) nego što su za 1/64° LOLA podatke (2d-1/64°). Time je opravdano uzorkovanje podatka iz horizontalne rezolucije od ~1/91° u horizontalnu rezoluciju 1/128°. Da su uzorkovani u horizontalnu rezoluciju 1/64°, rezultati bi bili lošiji. Također ova analiza može biti korisna i za druga istraživanja, kojima je cilj odrediti optimalnu horizontalnu rezoluciju kojom će se prikazati dostupni podaci. Pritom je uvijek potreban određeni kompromis između podržane horizontalne rezolucije i veličine podataka.



Slika 78. A-ROC vrednovanje interpolacijskog CDA-a korištenjem LU60645GT kataloga, 1/128° i 1/64° LOLA podataka te f_m<3. © 2011 Elsevier (Salamunićcar et al., 2011f).

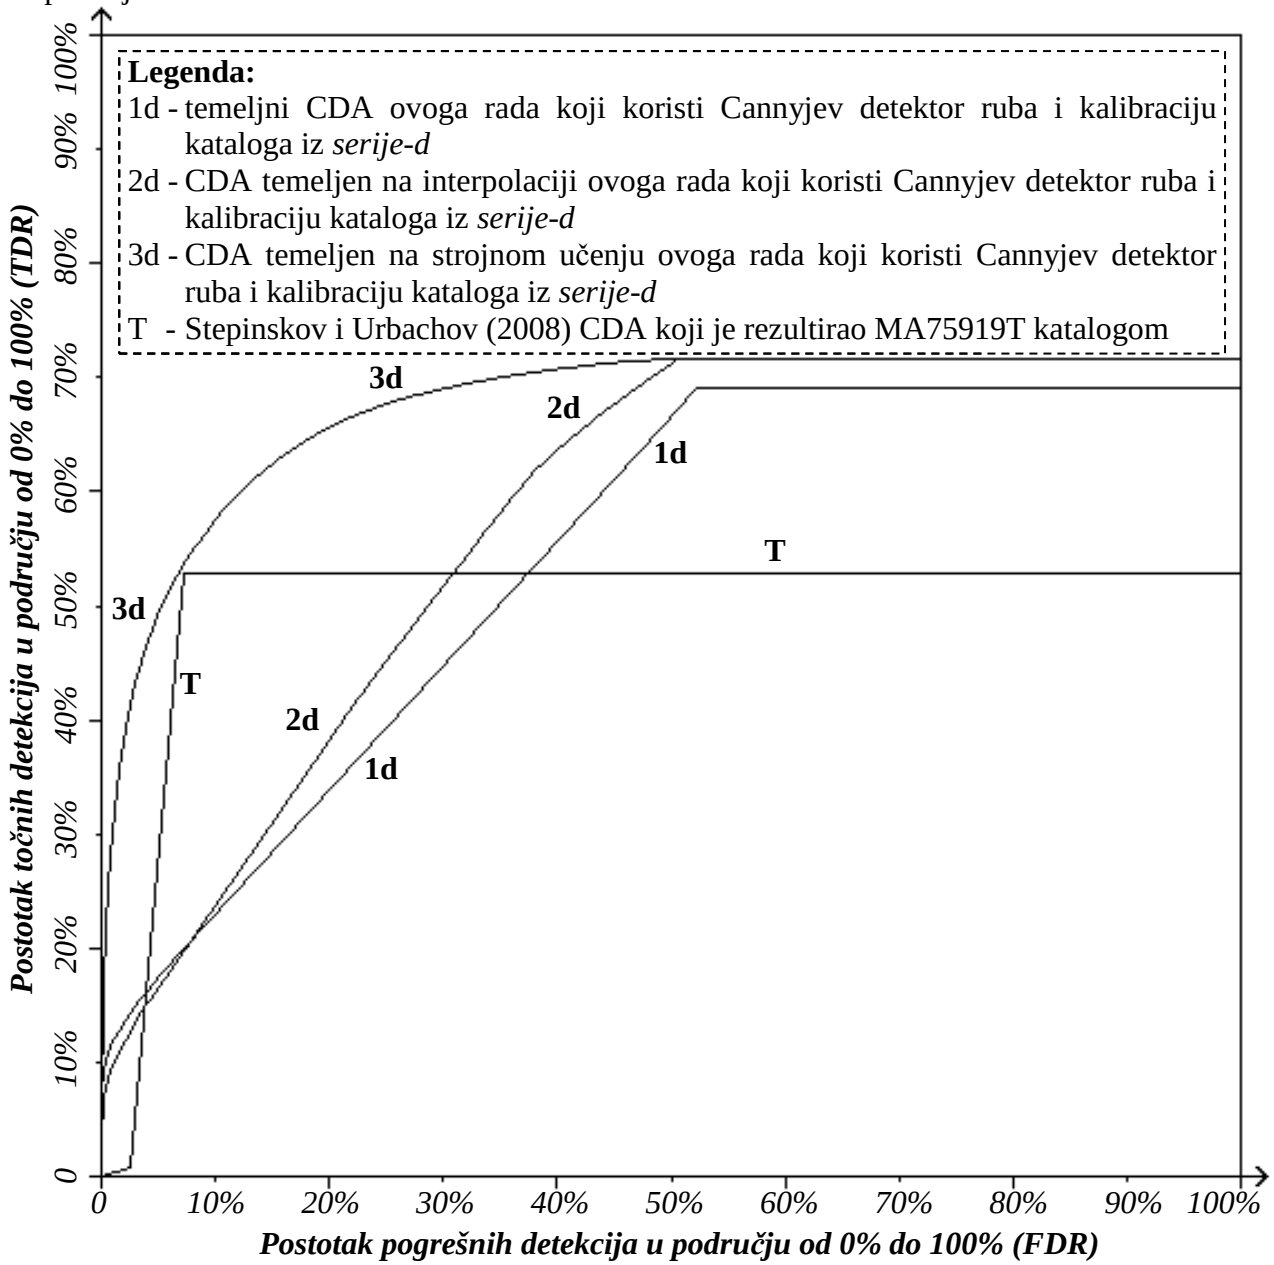
9.3.3. Vrednovanje metode za detekciju temeljene na strojnom učenju

Prva usporedba CDA-a temeljenog na strojnom učenju s prethodna dva CDA-a ovoga rada napravljena je korištenjem MA57633GT kataloga. Slika 79 prikazuje rezultate F-ROC analize. Temeljni CDA (1b) je bolji od Stepinskovog i Urbachovog CDA-a (T) u cijelom području. Također je u cijelom području CDA temeljen na interpolaciji (2b) bolji od temeljnog CDA-a (1b), kao što je i CDA temeljen na strojnom učenju (3b) bolji od CDA-a temeljenog na interpolaciji (2b). Dok razlika između temeljnog CDA-a i interpolacijskog CDA-a u ovom slučaju nije značajna, razlika između CDA-a koji koristi strojno učenje i CDA-a koji koristi interpolaciju je značajna. Time se istaknulo prvo važno svojstvo CDA-a temeljenog na strojnom učenju. Postignuti su značajno bolji rezultati i u području gdje su prethodna dva CDA-a također davali vrlo dobre rezultate. To se odnosi na korištenje vrijednosti kalibracije kataloga iz *serije-b* za detekciju kratera pretežno većih od 4 km u dijametru.



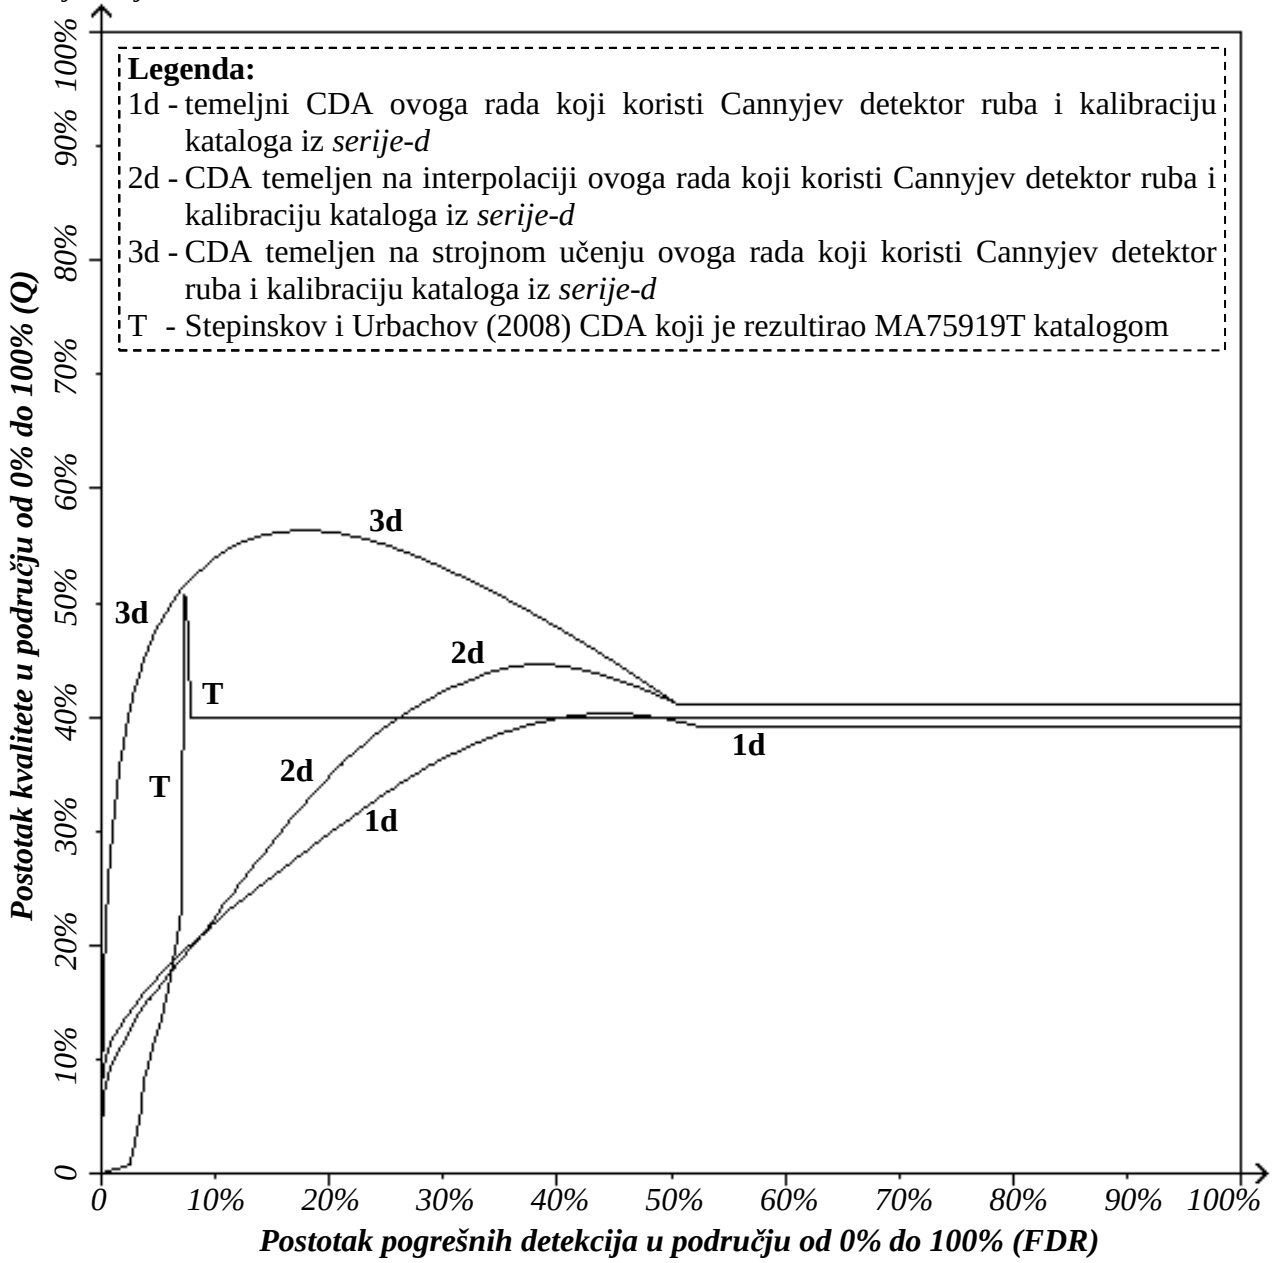
Slika 79. F-ROC vrednovanje CDA-a strojnog učenja korištenjem MA57633GT kataloga, 1/128° MOLA podataka, f_m<0.5, te njegova usporedba sa Stepinskovim i Urbachovim (2008) CDA-om.

U drugom koraku prikazani su rezultati za vrijednosti kalibracije kataloga *serije-d*, kako bi se uzele u obzir i brojne detekcije kratera manjih od 4 km u dijametru. Pritom su se koristili najpotpuniji referentni katalog i uparivanje kratera do f_m<3. Time se obuhvaćaju i oni krateri koje CDA-ovi detektiraju s manje točnim koordinatama i dijametrima. Slika 80 prikazuje rezultate A-ROC analize. CDA temeljen na strojnom učenju ovoga rada (3d) ne samo da je bolji od svih ostalih temeljem kriterija veće površine ispod A-ROC krivulje, nego je i bolji tijekom cijele A-ROC krivulje. Rezultat je manji broj pogrešnih detekcija od svih ostalih CDA-ova za bilo koji iznos točnih detekcija. Time je pokazano da ni u jednom segmentu Stepinskov i Urbachov (2008) CDA (T) više nije bolji od CDA-a temeljenog na strojnom učenju (3d), koji uz strojno učenje koristi i interpolaciju i sve otale module koji su sastavni dio temeljnog CDA-a ovoga rada. Ovom analizom potvrđeno je znatno veće poboljšanje koje je uvelo strojno učenje od poboljšanja koje je uvela interpolacija u obliku kratera.



Slika 80. A-ROC vrednovanje CDA-a strojnog učenja korištenjem MA132843GT kataloga, 1/128° MOLA podataka, f_m<3, te njegova usporedba sa Stepinskovim i Urbachovim (2008) CDA-om.

U sljedećem koraku napravljeno je dodatno vrednovanje CDA-ova Q krivuljom, koja je po definiciji omjer točnih detekcija i zbroja broja kratera u referentnom katalogu s brojem pogrešnih detekcija. Samim time za početni dio A-ROC odziva raste dio Q krivulje jer broj točnih detekcija raste značajnije od broja pogrešnih detekcija. Kako u nastavku A-ROC krivulje broj točnih detekcija raste sve manje, a broj pogrešnih detekcija sve više, Q krivulja ulazi u dio u kojem prestaje rasti i počinje padati. Stoga je pronalazak maksimuma Q krivulje jedan način određivanja optimalnog korištenja nekog CDA-a. Uzima se vjerojatnost pridružena upravo onom krateru koji se u grafu nalazi na maksimumu Q krivulje kao prag vjerojatnosti. Nakon toga se uzimaju u obzir samo oni kandidati za kratere koji imaju višu pridijeljenu vjerojatnost od praga. Na temelju ovog vrednovanja bolji je onaj CDA koji ima veći maksimum Q krivulje. Slika 81 prikazuje rezultate Q analize. CDA temeljen na strojnom učenju ovoga rada (3d) i po ovom kriteriju bolji je od svih ostalih. Bolji nije samo stoga što mu je maksimum Q krivulje veći, nego i zato što je njegova Q krivulja uvijek iznad ostalih.

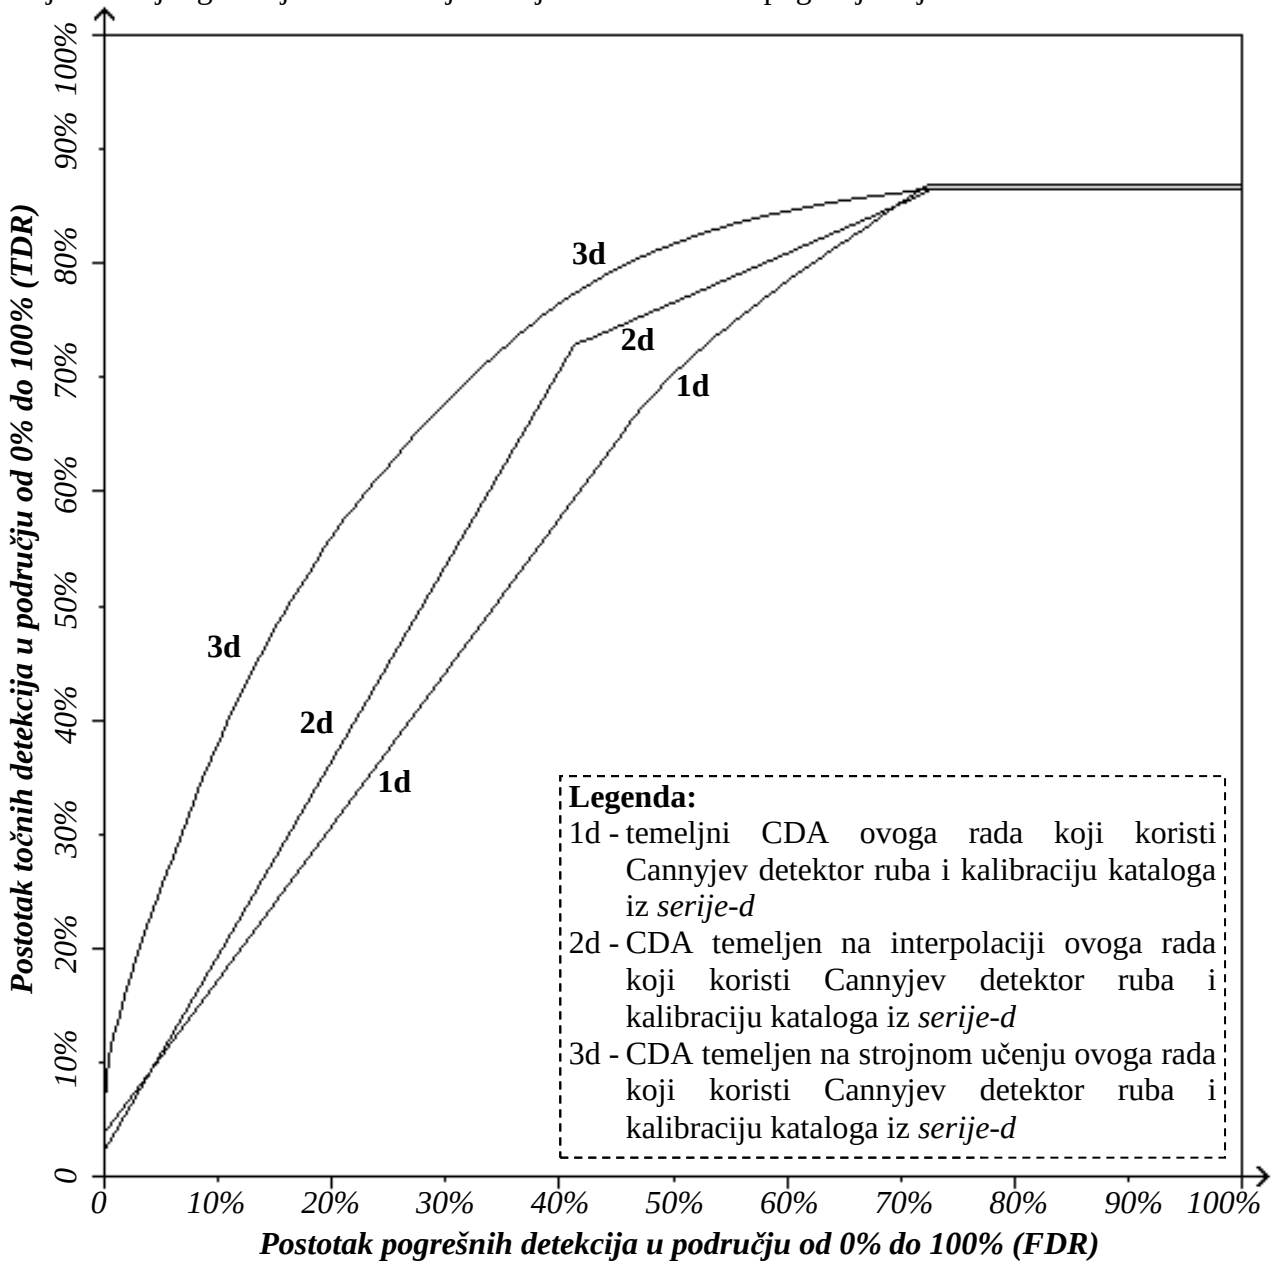


Slika 81. Q vrednovanje CDA-a strojnog učenja korištenjem MA132843GT kataloga, 1/128° MOLA podataka, f_m<3, te njegova usporedba sa Stepinskovim i Urbachovim (2008) CDA-om.

Kao i u prethodnom slučaju, usporedba CDA-a koji koristi strojno učenje s CDA-om koji koristi interpolaciju i temeljnim CDA-om, napravljena je i korištenjem dostupnih podataka za Mjesec, kako bi se uzelo u obzir da CDA ne mora biti jednako učinkovit prilikom obrade topografskih slika Marsa i Mjeseca.

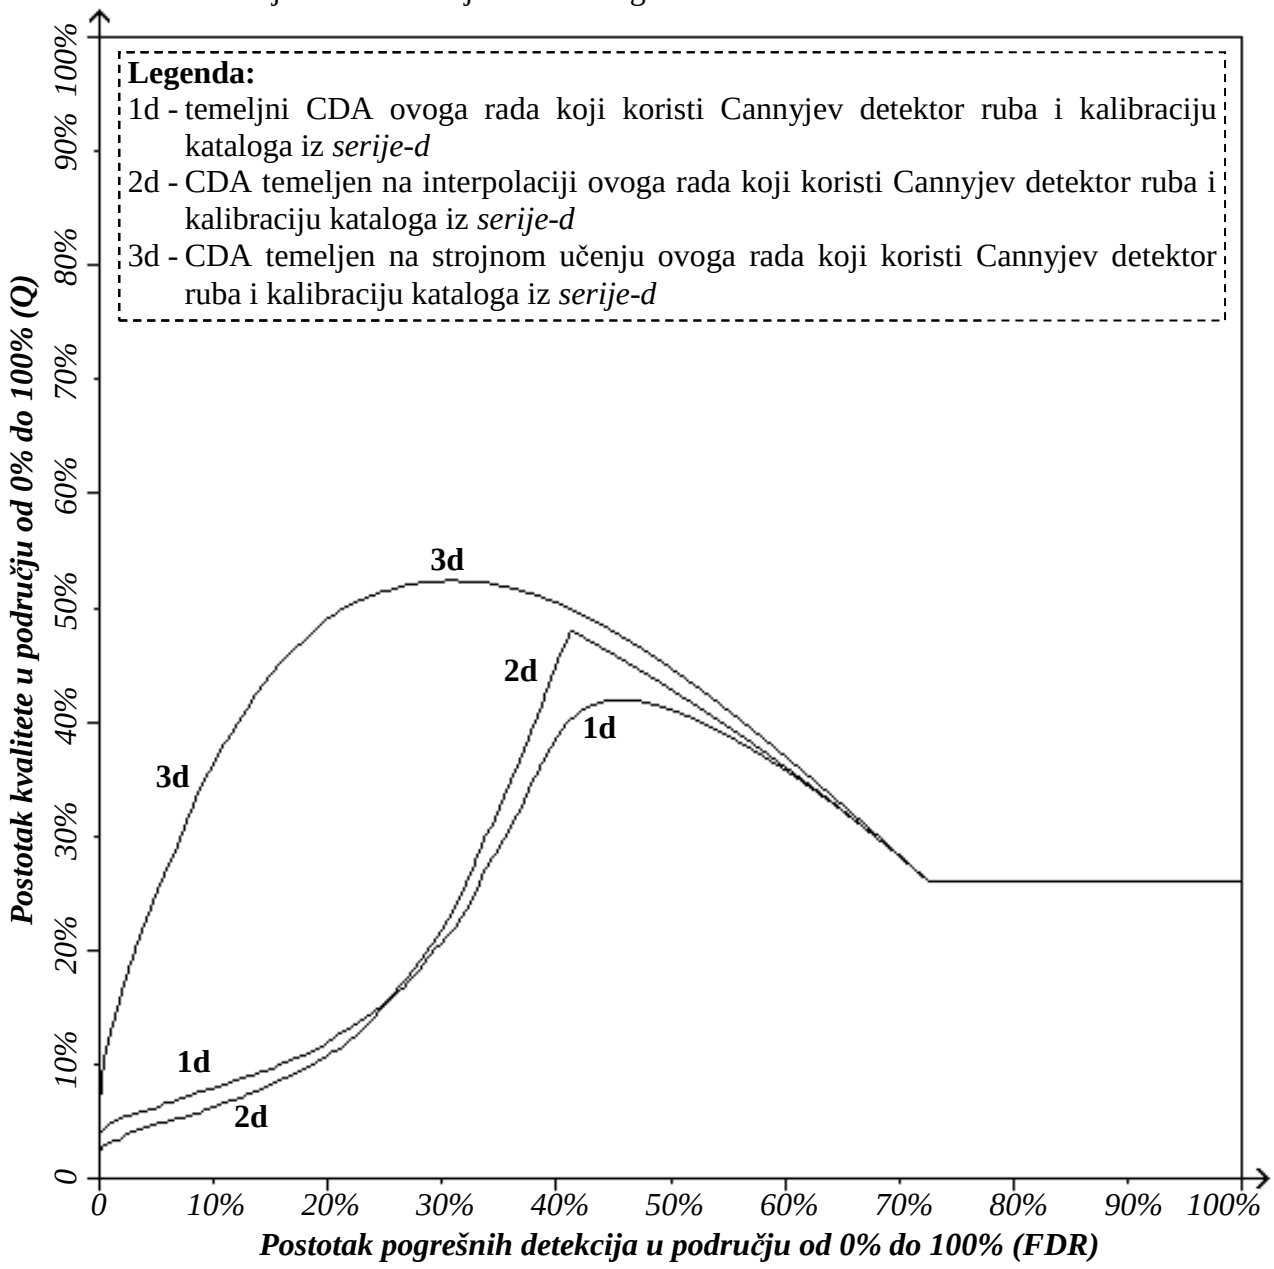
Pritom se nije mogla raditi usporedba sa Stepinskovim i Urbachovim (2008) CDA-om, kako je to napravljeno u slučaju vrednovanja korištenjem topografske slike Marsa. Za taj CDA naime nije dostupan rezultirajući katalog za Mjesec.

U prvom koraku napravljena je A-ROC analiza. Slika 82 prikazuje njezine rezultate. CDA temeljen na strojnom učenju ovoga rada (3d) ne samo da je bolji od svih ostalih na temelju kriterija veće površine ispod A-ROC krivulje, nego i tijekom cijele A-ROC krivulje. Za bilo koji iznos točnih detekcija uvijek ima manji broj pogrešnih detekcija od svih ostalih CDA-ova, stoga je primjena strojnog učenja dala značajno bolje rezultate i za topografiju Mjeseca.



Slika 82. A-ROC vrednovanje CDA-a strojnog učenja korištenjem LU60645GT kataloga, 1/128° LOLA podataka te f_m<3.

U drugom koraku ponovo je napravljena Q analiza istih CDA-ova, kako bi se provjerilo imaju li Q krivulje CDA-ova ovoga rada iste značajke za globalne topografske slike Marsa kao i pri korištenju globalnih topografskih slika Mjeseca. Slika 83 prikazuje njezine rezultate. Q usporedba temeljnog CDA-a (1d), CDA-a temeljenog na interpolaciji (2d) i CDA-a temeljenog na strojnom učenju (3d), koristeći LU60645GT referentni katalog, novu metodu za uparivanje kratera koji zadovoljavaju f_m<3 i 1/128° LOLA podatke, pokazuje da je CDA temeljen na strojnom učenju ovoga rada (3d) i po ovom kriteriju bolji od svih ostalih. Također, CDA temeljen na strojnom učenju bolji je od ostalih CDA-ova s obzirom na to da je njegova Q krivulja uvijek iznad ostalih. Ovo je još jedna potvrda značajno boljih rezultata primjene strojnog učenja za topografije Marsa i Mjeseca, s time da CDA koji koristi strojno učenje ujedno koristi interpolaciju u obliku kratera, kao i sve ostale module koje koristi temeljni CDA ovoga rada.



Slika 83. Q vrednovanje CDA-a strojnog učenja korištenjem LU60645GT kataloga, 1/128° LOLA podataka te f_m<3.

Prethodnom analizom pokazana su znatna poboljšanja postignuta interpolacijom i strojnim učenjem, bez obzira na to koriste li se topografske slike Marsa ili Mjeseca. Isto je potvrđeno bez

obzira na to koristi li se MA57633GT referentni katalog koji prije svega osigurava objektivnost u vrednovanju ili referentni katalozi MA132843GT i LU60645GT koji osiguravaju točnost u vrednovanju. Također isto je pokazano bez obzira na to koristi li se temeljna (do vrijednosti f_m<0.5), odnosno napredna (do vrijednosti f_m<3) metoda za uparivanje kratera. Na kraju, isto vrijedi bez obzira na to koristi li se F-ROC, A-ROC ili Q vrednovanje (usporedbe koje se najčešće koriste). Postignuta poboljšanja stoga nisu rezultat odabira metodologije za vrednovanje, nego postignutih značajki CDA-ova. Na temelju tih analiza CDA koji koristi i strojno učenje i interpolaciju bolji je i od prethodnih CDA-ova ovoga rada i od Stepinskovog i Urbachovog (2008) CDA-a.

9.3.4. Međusobna usporedba relativnih doprinosa metoda za detekciju

Pretpostavimo da su CDA-A, CDA-B i CDA-C postigli svojstva detekcije *A*, *B* i *C*, te da: (1) je svaka od vrijednosti u normaliziranom području između 0 i 100%; (2) veća vrijednost znači bolja svojstva detekcije; i (3) $A < B$ i $B < C$. U tom slučaju, za CDA-B moguće poboljšanje svojstava detekcije je (1-*A*), dok je postignuto poboljšanje (*B*-*A*), a za CDA-C moguće poboljšanje je (1-*B*), a postignuto poboljšanje (*C*-*B*). Koristeći navedeno, odnos između postignutog i teoretski najvećeg mogućeg poboljšanja svojstava detekcije je $R_B=(B-A)/(1-A)$ za CDA-B i $R_C=(C-B)/(1-B)$ za CDA-C. Na kraju te dvije vrijednosti možemo usporediti te time dobivamo $I_B=R_B\cdot 100/(R_B+R_C)$ i $I_C=R_C\cdot 100/(R_B+R_C)$. Koristeći navedeni postupak možemo usporediti i više CDA-ova. Kako se neki krateri iz MA132843GT kataloga ne mogu detektirati nijednim CDA-om zbog ograničene rezolucije korištene globalne topografske slike, kreiran je dodatni referentni katalog koji ne sadrži 19 883 kratera, koje nijedan CDA nije detektirao. Slika 84 prikazuje rezultate za površine ispod F-ROC i A-ROC krivulja, gdje se kod F-ROC krivulje površina računa samo do udaljenosti $1\cdot\tau$, jer je na većim udaljenostima postotak pogrešnih detekcija uvijek veći od postotka točnih. Kako je na slici prikazano, relativni doprinos CDA-a temeljenog na interpolaciji veći je od relativnog doprinosa temeljnog CDA-a, dok je relativni doprinos CDA-a temeljenog na strojnom učenju veći od ukupnog relativnog doprinosa prethodnih dvaju CDA-ova.

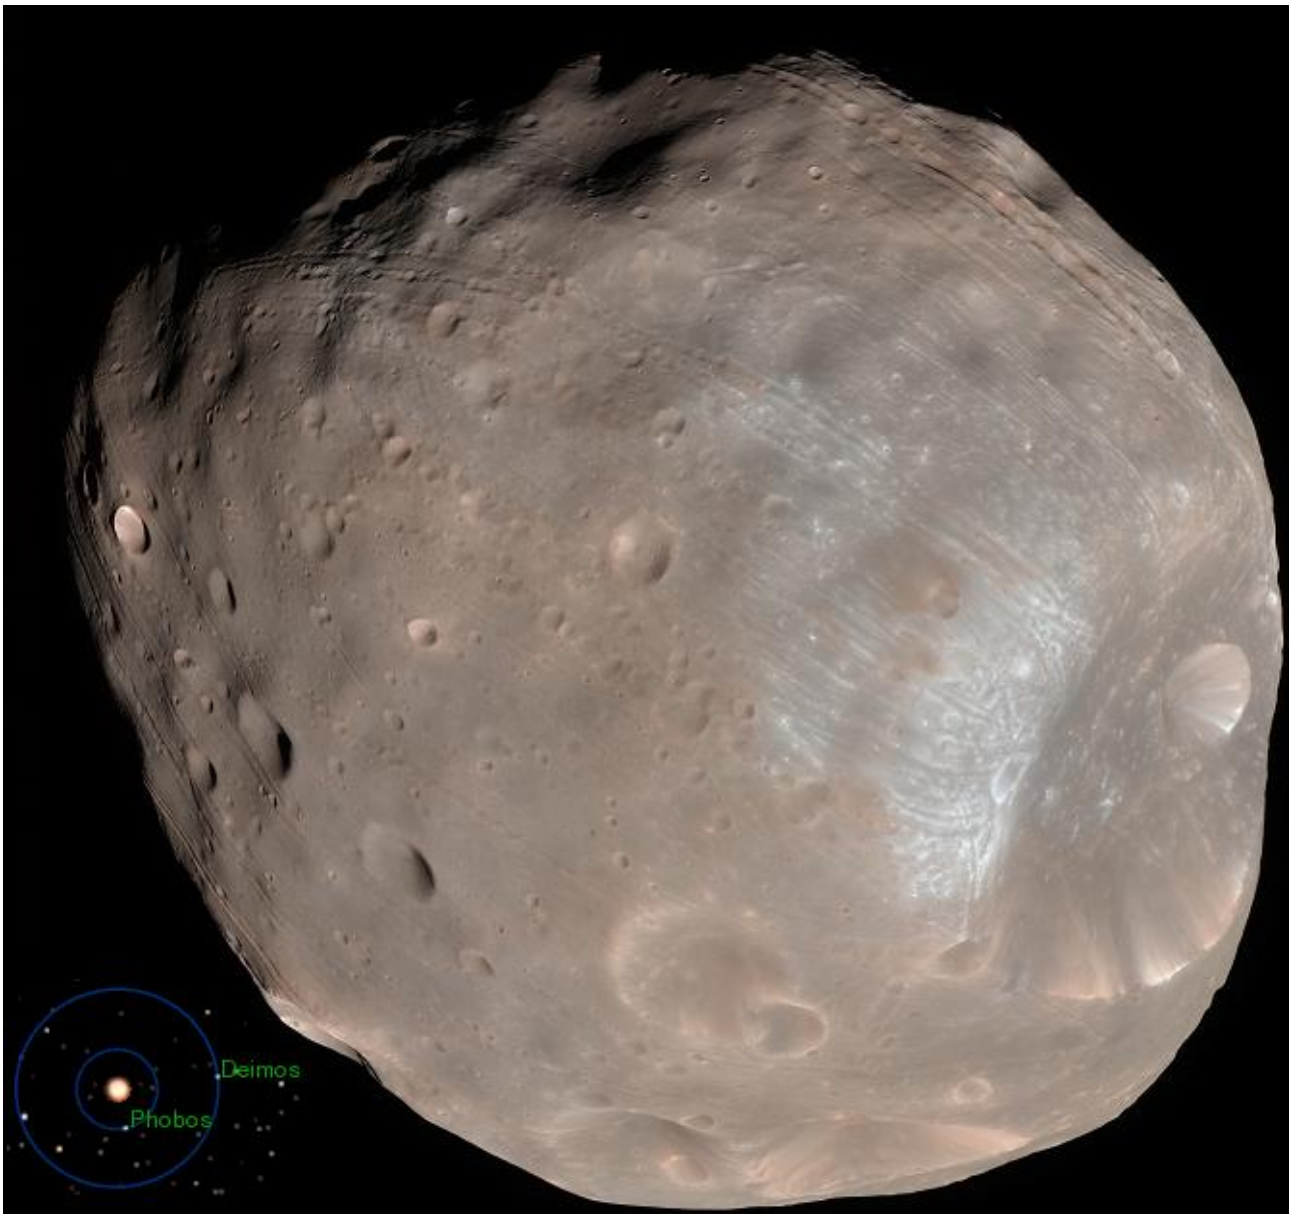
	AUFROC$_{1\tau}$	AUAROC	prosjek
MA132843GT	 23.3% 24.7% 52.0%	 20.1% 19.6% 60.4%	 21.7% 22.1% 56.2%
MA132843GT reduciran na 112960 kratera	 12.4% 25.4% 62.2%	 19.8% 18.6% 61.6%	 16.1% 22.0% 61.9%
prosjek	 17.9% 25.1% 57.1%	 19.9% 19.1% 61.0%	 18.9%22.1%59.0%

Slika 84. Međusobna usporedba relativnih doprinosa metoda za detekciju korištenjem površine ispod F-ROC krivulje do udaljenosti $1\cdot\tau$ i površine ispod A-ROC krivulje: (1) temeljnog CDA-a u odnosu na Stepinskov i Urbachov (2008) CDA (plava); (2) CDA-a temeljenog na interpolaciji u odnosu na temeljni CDA (žuta); i (3) CDA-a temeljenog na strojnom učenju u odnosu na CDA temeljen na interpolaciji (zelena).

9.4. Strojna detekcija i globalni katalog kratera Fobosa s 1102 kratera

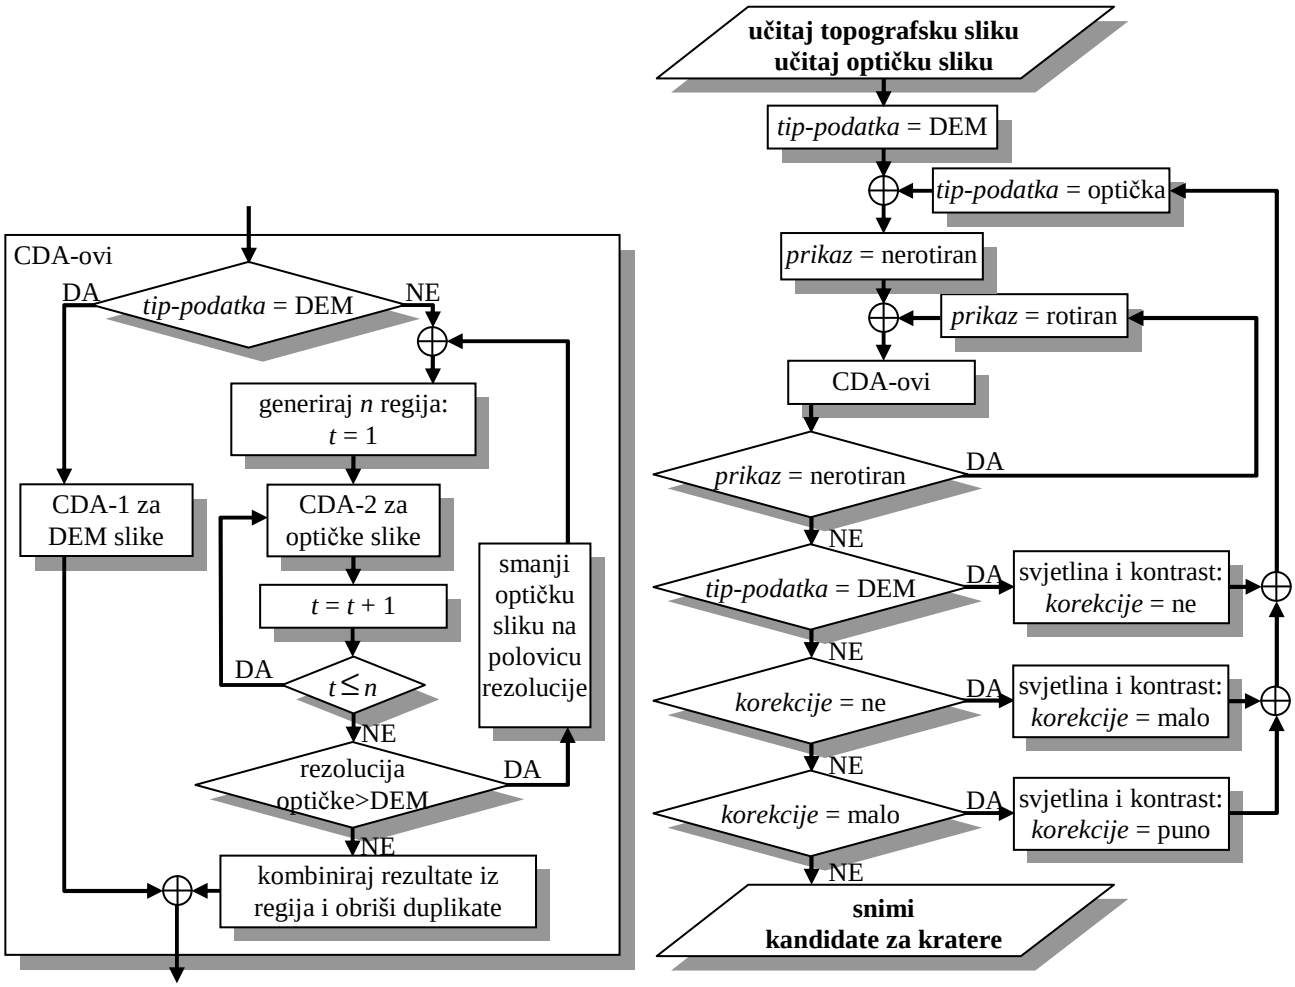
Ovaj dio rada napravljen je u suradnji s Pedrom Pinom, Lourençom Bandeirom i Joséom Saraivom (Salamunićcar et al., 2011c; Salamunićcar et al., 2011d), čiji doprinos je detekcija kratera iz optičkih slika njihovim CDA-om (Bandeira et al., 2007b).

Fobos je mjesec Marsa, čiji su topografski podaci (Wählisch et al., 2010) tek nedavno postali dostupni. Stoga se eksperimentalno provjerilo može li se CDA razvijen u ovome radu koristiti i za detekciju njegovih kratera. Slika 85 prikazuje Fobos i njegovu orbitu oko Marsa. Za razliku od Marsa (radijus mu je 3390 km) i Mjeseca (radijus mu je 1737.4 km), Fobos je puno manji (radijus mu je svega 11.1 km). Stoga je zbog puno manje gravitacije znatno nepravilnijeg oblika te time i izazov CDA-ovima. Jedini autori koji su pokazali da njihov CDA može detektirati kratere iz slika planetarnih tijela asteroidnog oblika su Leroy et al. (2001), Clerc et al. (2010) i Maass et al. (2011).



Slika 85. Fobos te orbite Fobosa i Deimosa oko Marsa (NASA, 2008a).

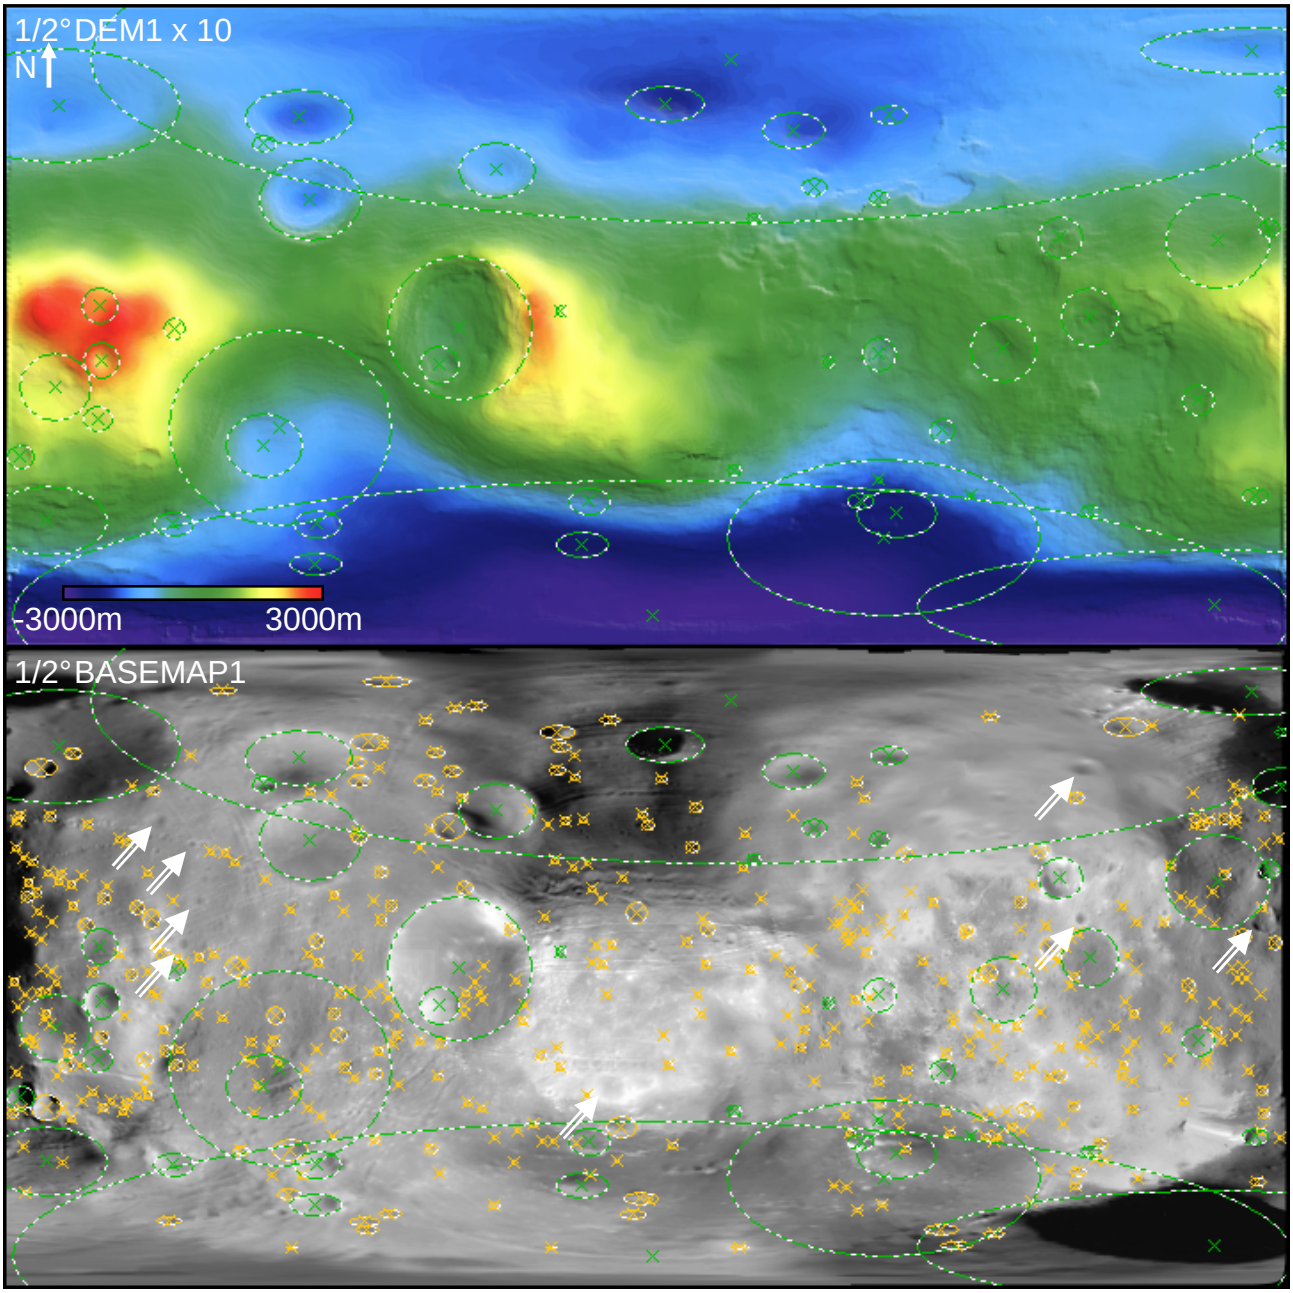
Osnovni cilj je integracija CDA-a za topografske i CDA-a za optičke slike, kako bi se krateri mogli detektirati i iz jednih i iz drugih. Slika 86 prikazuje dijagram toka predloženog integriranog CDA-a, njegov osnovni dio (lijevo) i proširenja (desno). Osnovni dio sadrži CDA za topografske slike i CDA za optičke slike. Sadrži i potrebnu obradu koja omogućuje CDA-ovima za optičke slike detekciju kratera i iz globalne optičke slike: (1) višestruko rezolucijsku piramidalnu obradu slika za detekciju kratera svih veličina; (2) automatsko generiranje slika veličine 512x512 slikovnih elemenata uz odgovarajuću promjenu projekcije, čime su krateri prikazani kao kružnice, a ne kao elipse; (3) automatsko integriranje rezultata pojedinih slika uz automatsko uklanjanje duplih detekcija istih kratera, koja su moguće zbog preklapanja pojedinih slika. Navedeno nije bilo potrebno i za CDA za topografske slike, s obzirom na to da već sadrži potrebne korake te može direktno detektirati kratere iz globalne topografske slike. Proširenja se sastoje od pretvorbe slika iz nerotiranog u rotirani prikaz (korištenjem metode opisane u potpoglavlju 5.5.) te korekciji svjetline i kontrasta optičkih slika (korištenjem metode opisane u potpoglavlju 8.2.).



Slika 86. Dijagram toka predloženog integriranog CDA-a (Salamunićcar et al., 2011d).

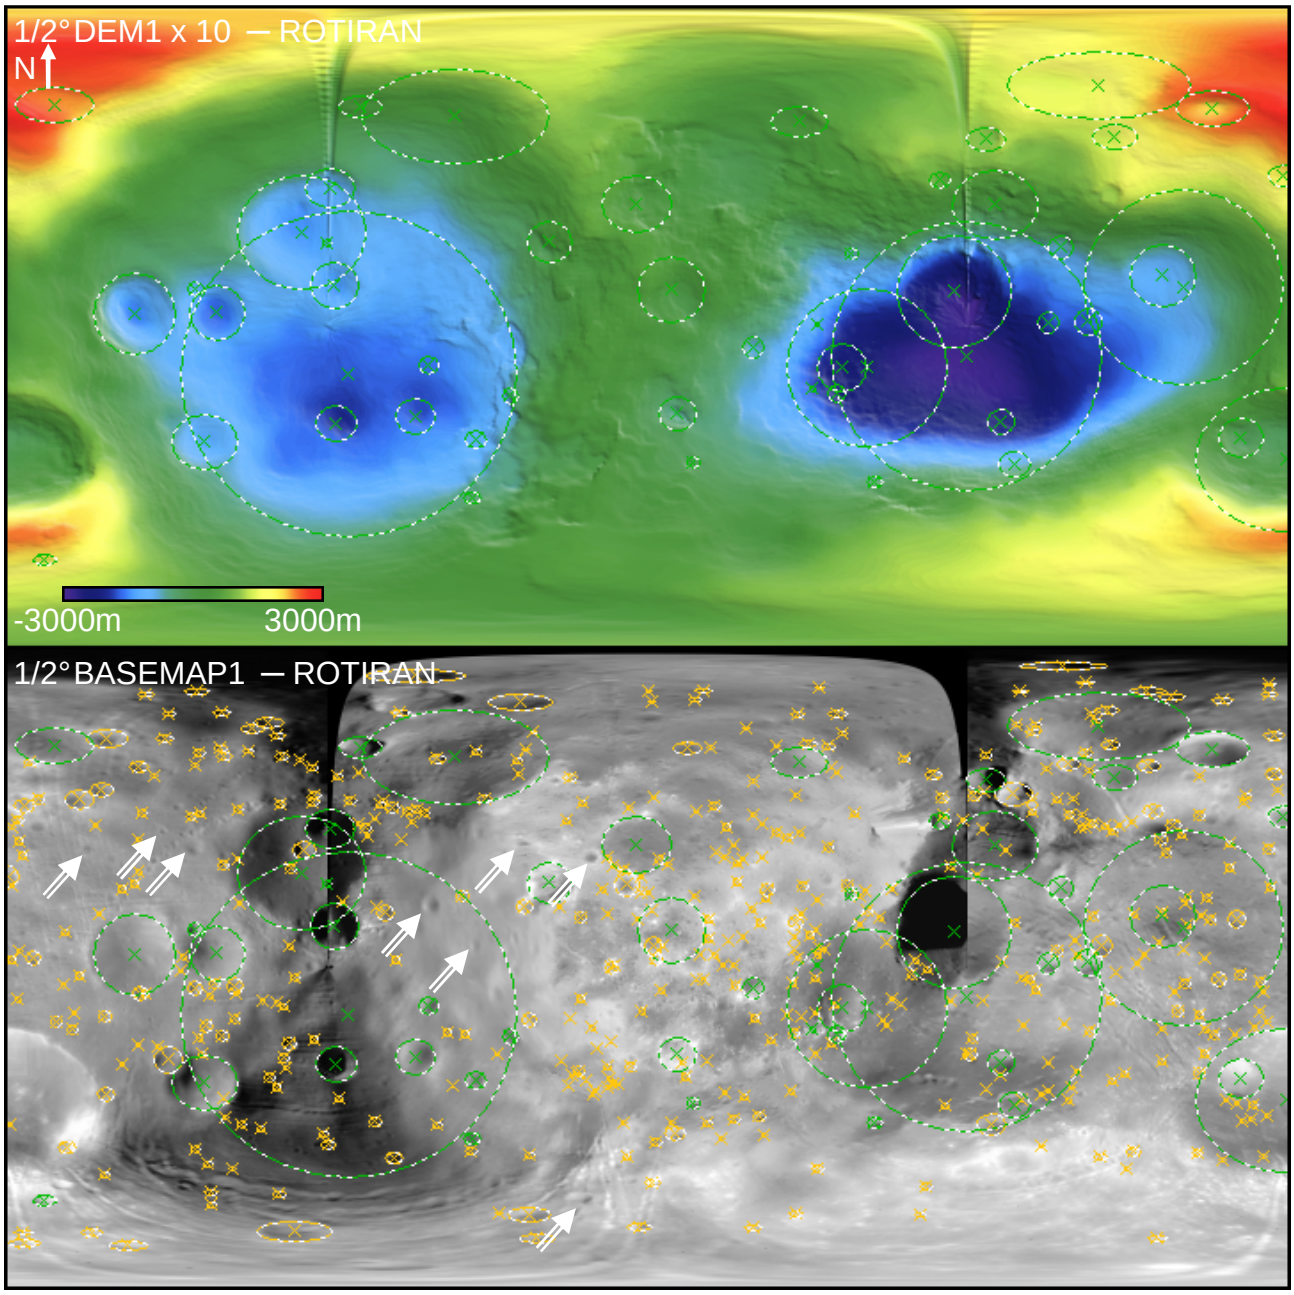
Koristio se CDA temeljen na interpolaciji, s obzirom na to da je pokazao bolje rezultate nego temeljni CDA, a CDA temeljen na učenju još nije bio razvijen tijekom ovog istraživanja. Dostupna topografska slika (Wählisch et al., 2010) uzorkovana je u sliku prve veće horizontalne rezolucije 1/4°. Dodatno su vrijednosti svih visina pomnožene s 10, kako bi CDA bolje detektirao rubove. Bilo je više pogrešnih detekcija u odnosu na rezultate za Mars i Mjesec, što je rezultat lošije kvalitete topografije rekonstruirane iz optičkih slika. Međutim Fobos je puno manji od Marsa i Mjeseca, pa nije bio problem ručno pregledati sve kandidate za kratere, obrisati pogrešne detekcije, a točne katalogizirati. Rezultat je bio početni katalog sa 47 kratera. Tom katalogu ručno su se

dodala 4 kratera koji imaju ime, pa stoga imaju dvostruku potvrđenost da su zaista krateri. U drugom koraku koristio se 1/16° globalni optički mozaik (Wählisch et al., 2010). Automatskom procedurom za njega su generirane slike 512x512 slikovnih elemenata, u područjima 64°N~63.75°S (za 1/4°), 56°N~55.875°S (za 1/8°) i 52°N~51.9375°S (za 1/16°), za CDA koji koristi optičke slike (Bandeira et al., 2007b). Kao i u prethodnom slučaju, ručno su se pregledali svi kandidati za kratere te se pritom referentni katalog proširio s 453 dodatna kratera. Slika 87 prikazuje PH504GT katalog.



Slika 87. Standardni prikaz Fobosa; 47 kratera koje je pronašao interpolacijski CDA i 4 dodana s imenom (gore); te 453 kratera koje je pronašao CDA koji obrađuje optičke slike (dolje).

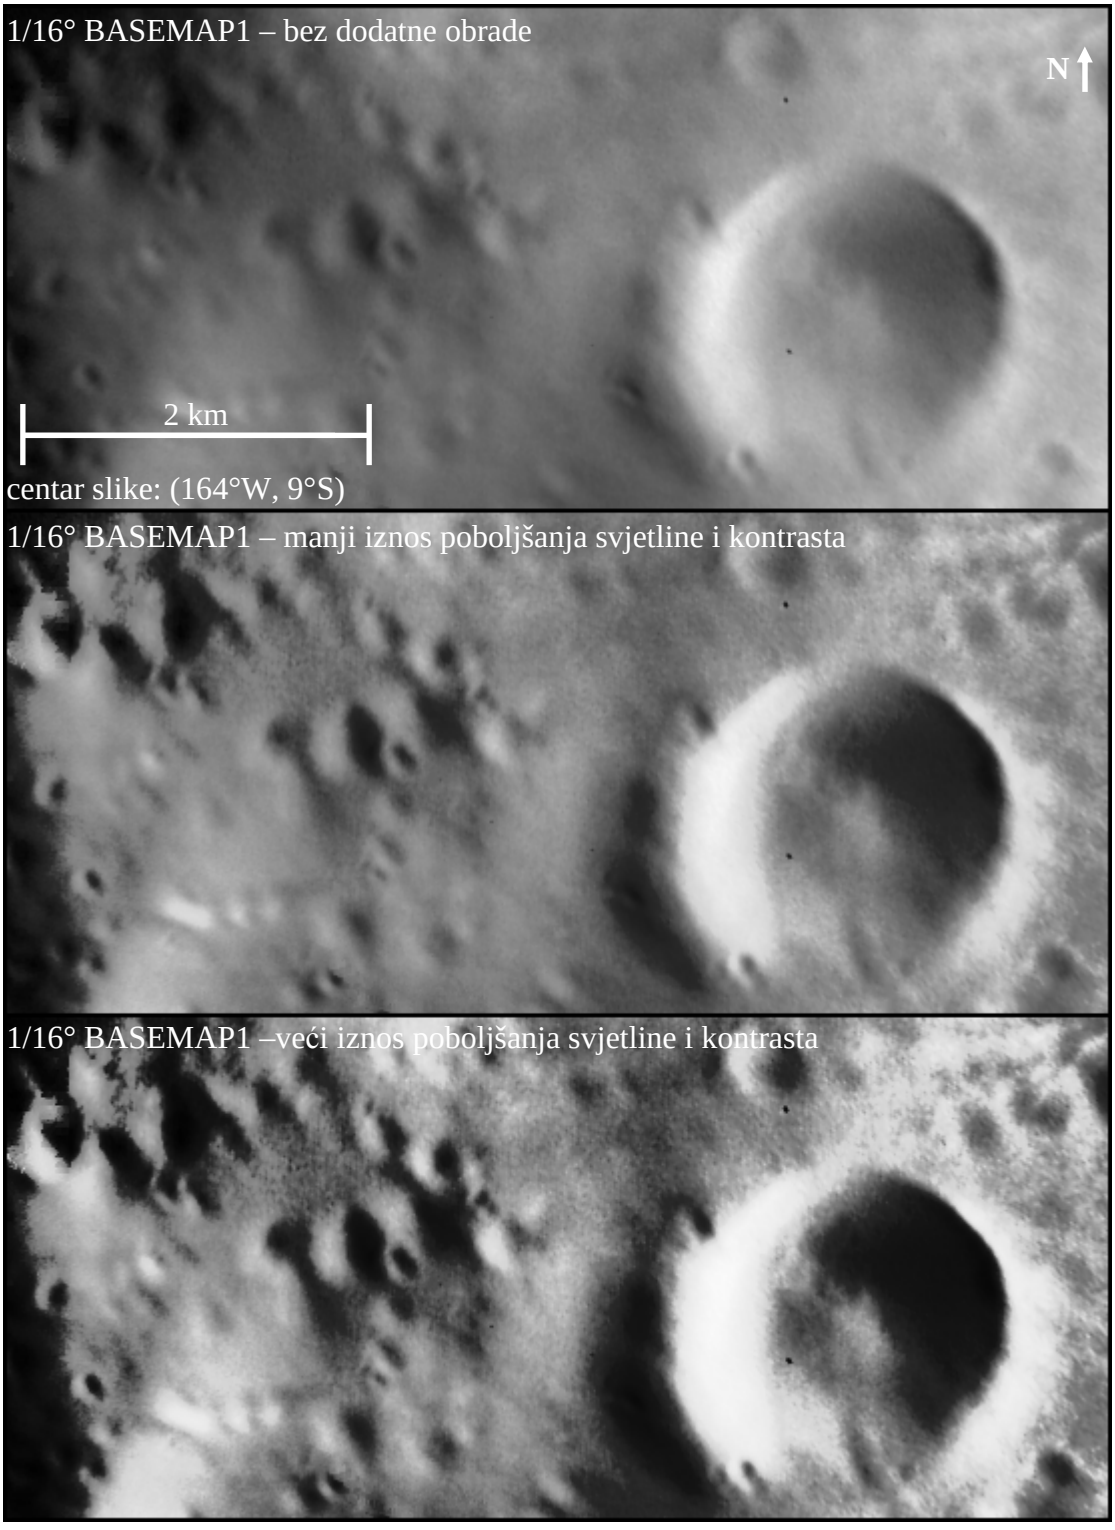
Rotirani prikaz korišten je u radu oba CDA-a kako bi se detektiralo što više kratera, posebno onih blizu Sjevernog i Južnog pola, koji su posebno izobličeni u jednostavnoj cilindričnoj projekciji. Slika 88 prikazuje katalog PH504GT, koristeći rotirani prikaz topografske i optičke slike. U oba slučaja mogu se primijetiti artefakti, no isti nisu posljedica algoritma koji rotira globalne slike i koordinate kratera, nego posljedica nesavršenosti korištenih globalnih slika. Sama bi se metoda za rotaciju globalnih slika stoga mogla koristiti i za provjeru njihove kvalitete.



Slika 88. Rotirani prikaz Fobosa; 47 kratera koje je pronašao interpolacijski CDA i 4 dodana s imenom (gore); te 453 kratera koje je pronašao CDA koji obrađuje optičke slike (dolje).

Uvidom u prethodne dvije slike može se primijetiti da svi vidljivi krateri nisu katalogizirani (primjerice oni označeni strelicama). Isti su naime premali da bi ih se moglo detektirati iz topografskih podataka, s obzirom na to da su isti dostupni samo u horizontalnoj rezoluciji 1/4°. Dodatni razlog je što ih CDA koji se koristio za obradu optičkih slika nije uspio detektirati, s obzirom na to da je i za njega bio svojevrstan izazov detekcija kratera s tijela asteroidnog oblika, gdje slike nisu visoke kvalitete. Stoga su se optičke slike dodatno obradile radi poboljšanja svjetline i kontrasta, te su se nakon toga ponovo koristile za CDA koji koristi optičke slike. Slika 89 prikazuje dio korištene optičke slike u izvornom neobrađenom formatu, te istu slika nakon poboljšanja svjetline i kontrasta, koristeći pritom manji i veći iznos poboljšanja. Poboljšavanjem svjetline (povećavanjem svjetline na mjestima gdje je globalna slika pretamna i smanjivanjem svjetline na mjestima gdje je presvijetla) i povećavanjem kontrasta do određene mjere poboljšavaju se svojstva detekcije, a nakon iste svojstva detekcije se ponovo počinju pogoršavati. Stoga se u

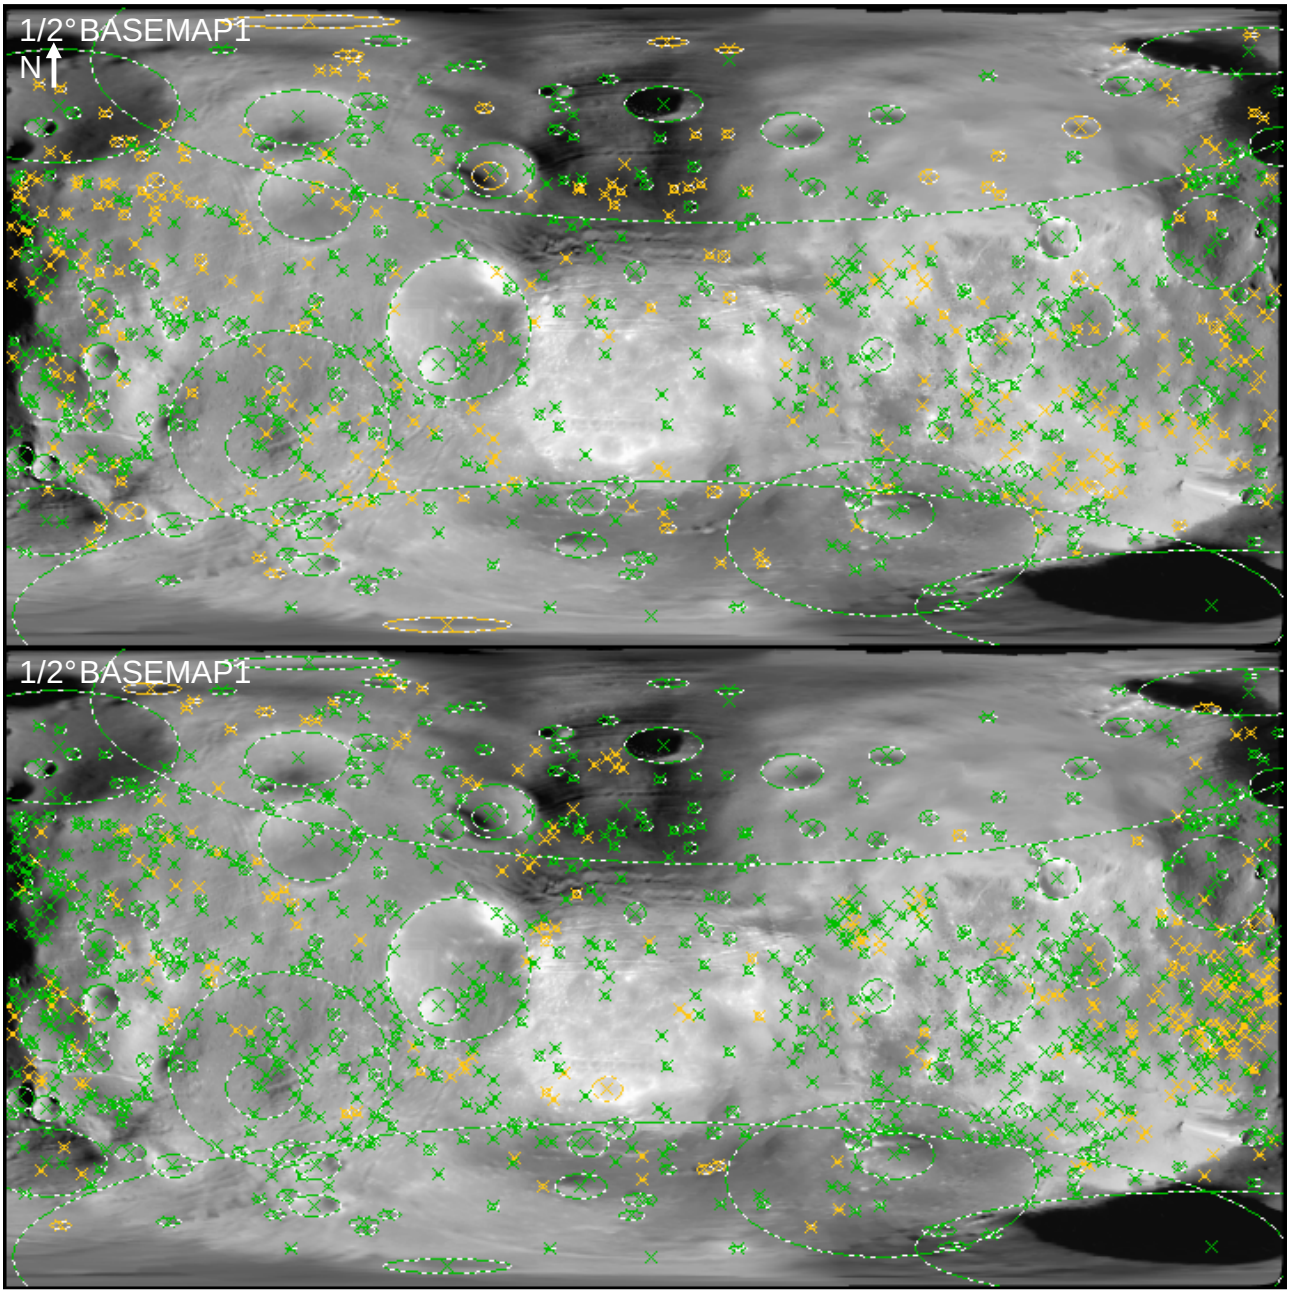
ovome radu, uz sliku u izvornom obliku, koriste i dvije dodatne slike s različitim iznosima poboljšanja svjetline i kontrasta.



Slika 89. Dio optičke slike korištene bez dodatne obrade (gore), te manji (sredina) i veći (dolje) iznos poboljšanja svjetline i kontrasta (Salamunićcar et al., 2011d).

Koristeći manji iznos poboljšanja svjetline i kontrasta dodatno se katalogiziralo još 167 kratera, a nakon toga koristeći veći iznos poboljšanja svjetline i kontrasta još 156 kratera. Slika 90 (gore) prikazuje 323 na ovaj način dodatno katalogizirana kratera u usporedbi s prethodno katalogiziranim. Kako bi se mogao procijeniti broj kratera koji se ni nakon ovog koraka nisu uspjeli

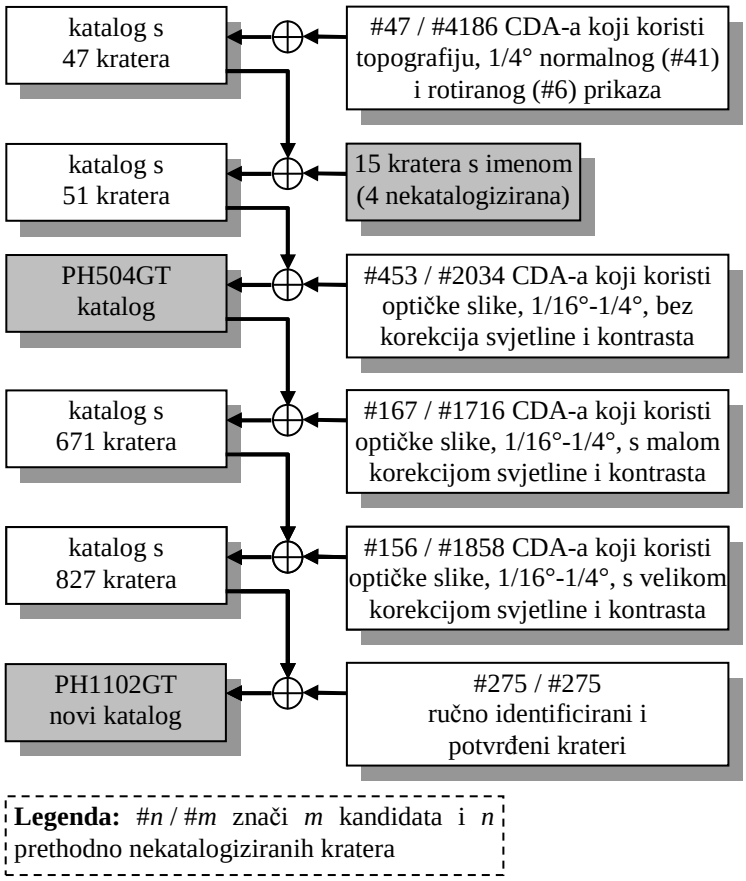
katalogizirati, isti su ručno pronađeni i dodani u katalog. Slika 90 (dolje) prikazuje 275 ručno pronađenih i katalogiziranih kratera u usporedbi s kraterima koji su katalogizirani korištenjem CDA-ova. Krateri koje integrirani CDA nije uspio detektirati prvenstveno su vrlo mali krateri s dijametrom ispod onog koji CDA može detektirati, te oni krateri koji se nalaze na dijelovima globalne optičke slike iznimno loše kvalitete (gdje je slika zamućena, gdje je posebno naglašen šum koji se manifestira kroz različite artefakte na slici, i slično).



Slika 90. Standardni prikaz Fobosa; 323 kratera dodatno pronađenih CDA-om koji obrađuje optičke slike, korištenjem manjeg (167 kratera) i većeg (156 kratera) poboljšanja iznosa svjetline i kontrasta (gore); te 275 ručno pronađenih i katalogiziranih kratera koje CDA nije uspio detektirati (dolje) (Salamunićcar et al., 2011d).

Rezultat ovog istraživanja je PH1102GT katalog kratera Fobosa. Slika 91 prikazuje korake katalogizacije koji pokazuju doprinos integriranog CDA-a. Kao i kod svih ostalih kataloga ovoga rada, za svaki krater postoje barem dvije nezavisne potvrde da je zaista krater. Zaključno s katalogom koji je sadržavao 827 kratera, prva nezavisna potvrda je detekcija kratera CDA-om, a

druga nezavisna potvrda ručna provjera detekcije. Za svega 275 zadnjih kratera, nezavisne potvrde dviju različitih osoba su katalogizacija i dodatna provjera. Sveukupno, prva osoba je oko 75% kratera samostalno katalogizirala, koristeći pritom CDA.



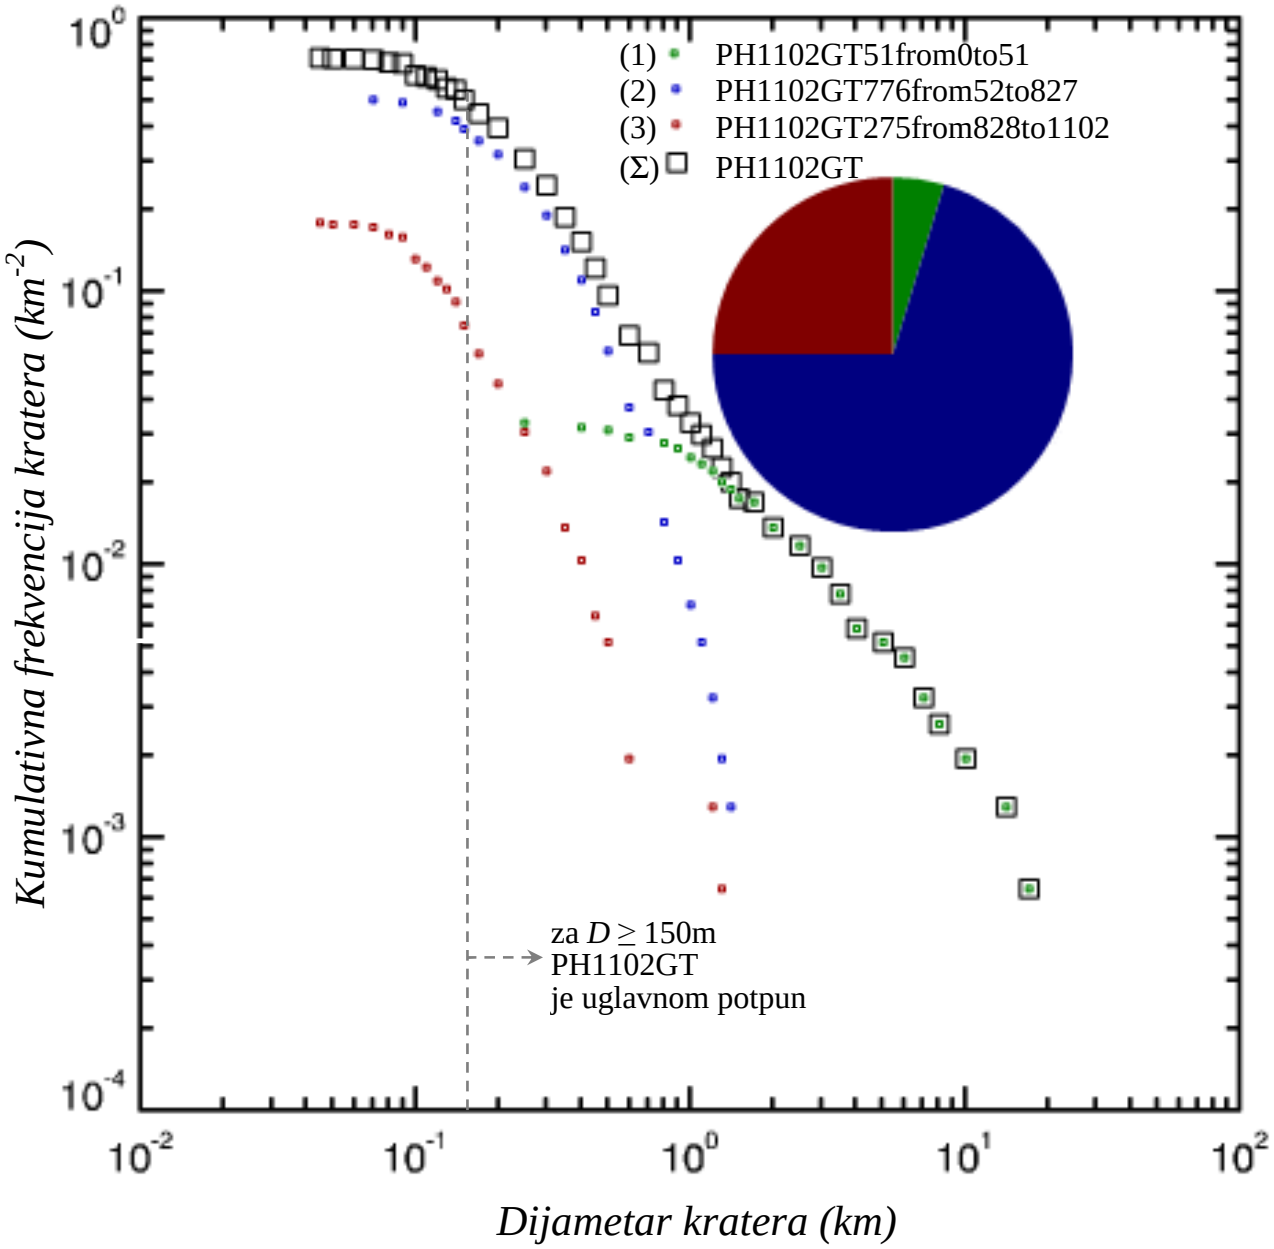
Slika 91. Doprinos integriranog CDA-a prilikom izrade najpotpunijeg javno dostupnog kataloga PH1102GT Fobosa (Salamunićcar et al., 2011d).

Kao i u prethodnim slučajevima Marsa i Mjeseca, i za Fobos je napravljena procjena potpunosti referentnog kataloga PH1102GT (Salamunićcar et al., 2011d). Slika 92 prikazuje rezultate generirane programom Craterstats (Michael, 2010). Na temelju analize se može primijetiti potpunost kataloga uglavnom za kratere veće od 150 m u dijametru.

Detekcija preostalih kratera planira se u budućem radu. Jedna mogućnost je iz optičkih slika generirati topografiju koja je u višoj horizontalnoj rezoluciji od sada dostupne (1/4°), kako bi se korištenjem tih podataka detektirali dodatni krateri s CDA-ovima ovoga rada (korištenjem CDA-a temeljenog samo na interpolaciji ili i na strojnom učenju). Druga mogućnost je korištenje novijeg, Stookeovog (2011) globalnog optičkog mozaika, koji prethodno nije bio dostupan, a kvalitetniji je i u višoj horizontalnoj rezoluciji. Može se koristiti u kombinaciji s CDA-om za optičke slike, a može poslužiti i za generiranje globalne topografske slike, kako bi se koristili CDA-ovi ovoga rada.

Rezultati za Fobos pokazali su kako CDA temeljen na interpolaciji može uspješno detektirati kratere i s tijela asteroidnog oblika (Salamunićcar et al., 2011c; Salamunićcar et al., 2011d). Također je pokazan i način korištenja CDA-a koji detektira kratere iz topografskih slika u kombinaciji s CDA-om koji ih detektira iz optičkih. Slika 92 prikazuje i kako se CDA-ovi međusobno nadopunjuju. Velike kratere je detektirao CDA koji koristi topografske slike, male kratere (koji se više ne mogu detektirati iz topografskih slika zbog premale horizontalne rezolucije) je detektirao CDA koji koristi optičke slike, a one srednje veličine oba CDA-a su podjednako detektirali. Ovo je i uobičajen primjer za Mars, Mjesec i ostala tijela, gdje bi se sukladno

pokazanom u ovom poglavlju također mogli zajedno koristiti CDA-ovi za topografske i optičke slike, kako bi zajedno detektirali što više kratera.



Slika 92. Procjena potpunosti PH1102GT kataloga (Salamunićcar et al., 2011d). Graf prikazuje njegovu potpunost za kratere veće od 150 m u dijametru te veću potpunost od kataloga pojedinih CDA-ova.

9.5. Testni poligon za vrednovanje laboratorijskih kratera

Ovaj dio rada napravljen je u suradnji s Dejanom Vinkovićem, Damirom Vučinom, Mladenom Gomerčićem, Igorom Pehnecom, Marinom Vojkovićem, Tomislavom Hercigonjom i Luči Karbonini (Vojković et al., 2010a, 2010b; Salamunićcar et al., 2010b; Vinković et al., 2011), čiji doprinos je izrada laboratorijskih kratera, njihovo 3D-skeniranje i priprema topografskih slika te interpretacija rezultata (nastanak kratera Marsa i laboratorijskih kratera te međusobna usporedba).

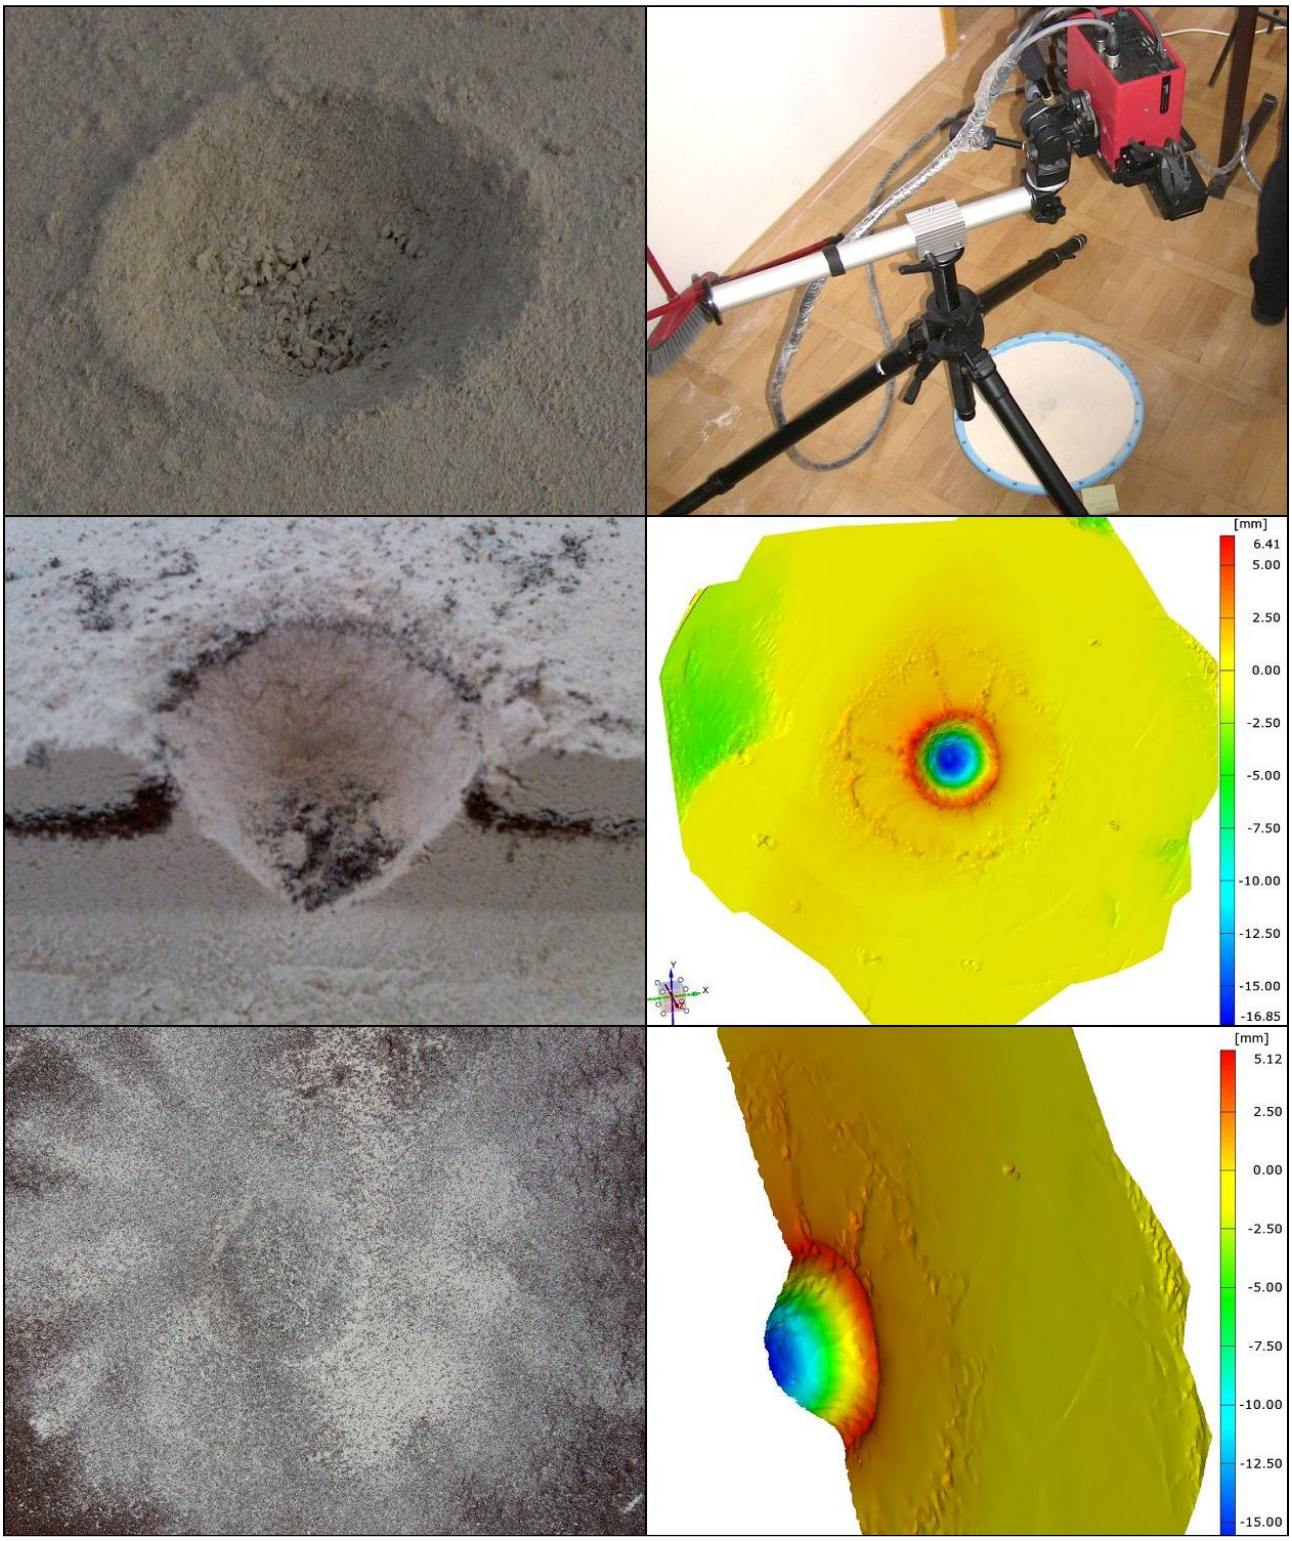
Osnovna svrha laboratorijskih kratera je bolje razumijevanje nastanka pravih kratera, kako bi se istraživanjem njihovih svojstava bolje mogli proučavati procesi na lunarnim i planetarnim tijelima, koji su bili aktivni ili su još uvijek aktivni.

Sami laboratorijski krateri kreiraju se eksplozivnim punjenjem u nabijenoj kamenoj prašini, kako bi po svom obliku što više odgovarali pravim kraterima, a kako bi ujedno i sam njihov postupak nastanka bio relativno jednostavan. Slika 93 prikazuje nekoliko primjera laboratorijskih kratera (lijevo), njihovo 3D-skeniranje (gore desno) te visokokvalitetne 3D-podatke, odnosno rezultate skeniranja (sredina desno i dolje desno).

Dosad su se laboratorijski krateri prvenstveno analizirali ručnim mjerenjima i usporedbom s pravim kraterima, no nije postojala formalna metoda koja bi izmjerila sličnost laboratorijskih i pravih kratera. Stoga se razvila metodologija koja koristi CDA-ove te 3D-oblike laboratorijskih i pravih kratera. Pritom se koristi princip Turingovog testa (Saygin et al., 2000): ako je laboratorijski krater toliko sličan pravom da ga CDA detektira, smatra se zadovoljavajućim modelom pravog kratera, a u protivnom se odbacuje kao nedovoljno sličan. Slika 94 prikazuje pripremu podataka gdje se laboratorijski krater integrira u 1/128° topografiju Marsa (gore lijevo), s ciljem postepenog prijelaza sa stvarne topografije na umetnuti laboratorijski krater. S obzirom na to da detekcije CDA-a ovise o veličini kratera, isti se integrira u tri različite veličine (gore desno). Potom se koriste temeljni CDA i interpolacijski CDA (CDA temeljen na strojnom učenju još nije bio razvijen), i to oba i s Cannyjevim i sa Shen-Castanovim detektorom ruba. Cilj je test sa četiri najrazličitija dostupna CDA-a. Kako je prikazano na istoj slici, u svim četirima slučajevima krater je uspješno detektiran u sve tri veličine, čime je po ovom testu dovoljno sličan pravim kraterima da bi se zadovoljio Turingov test.

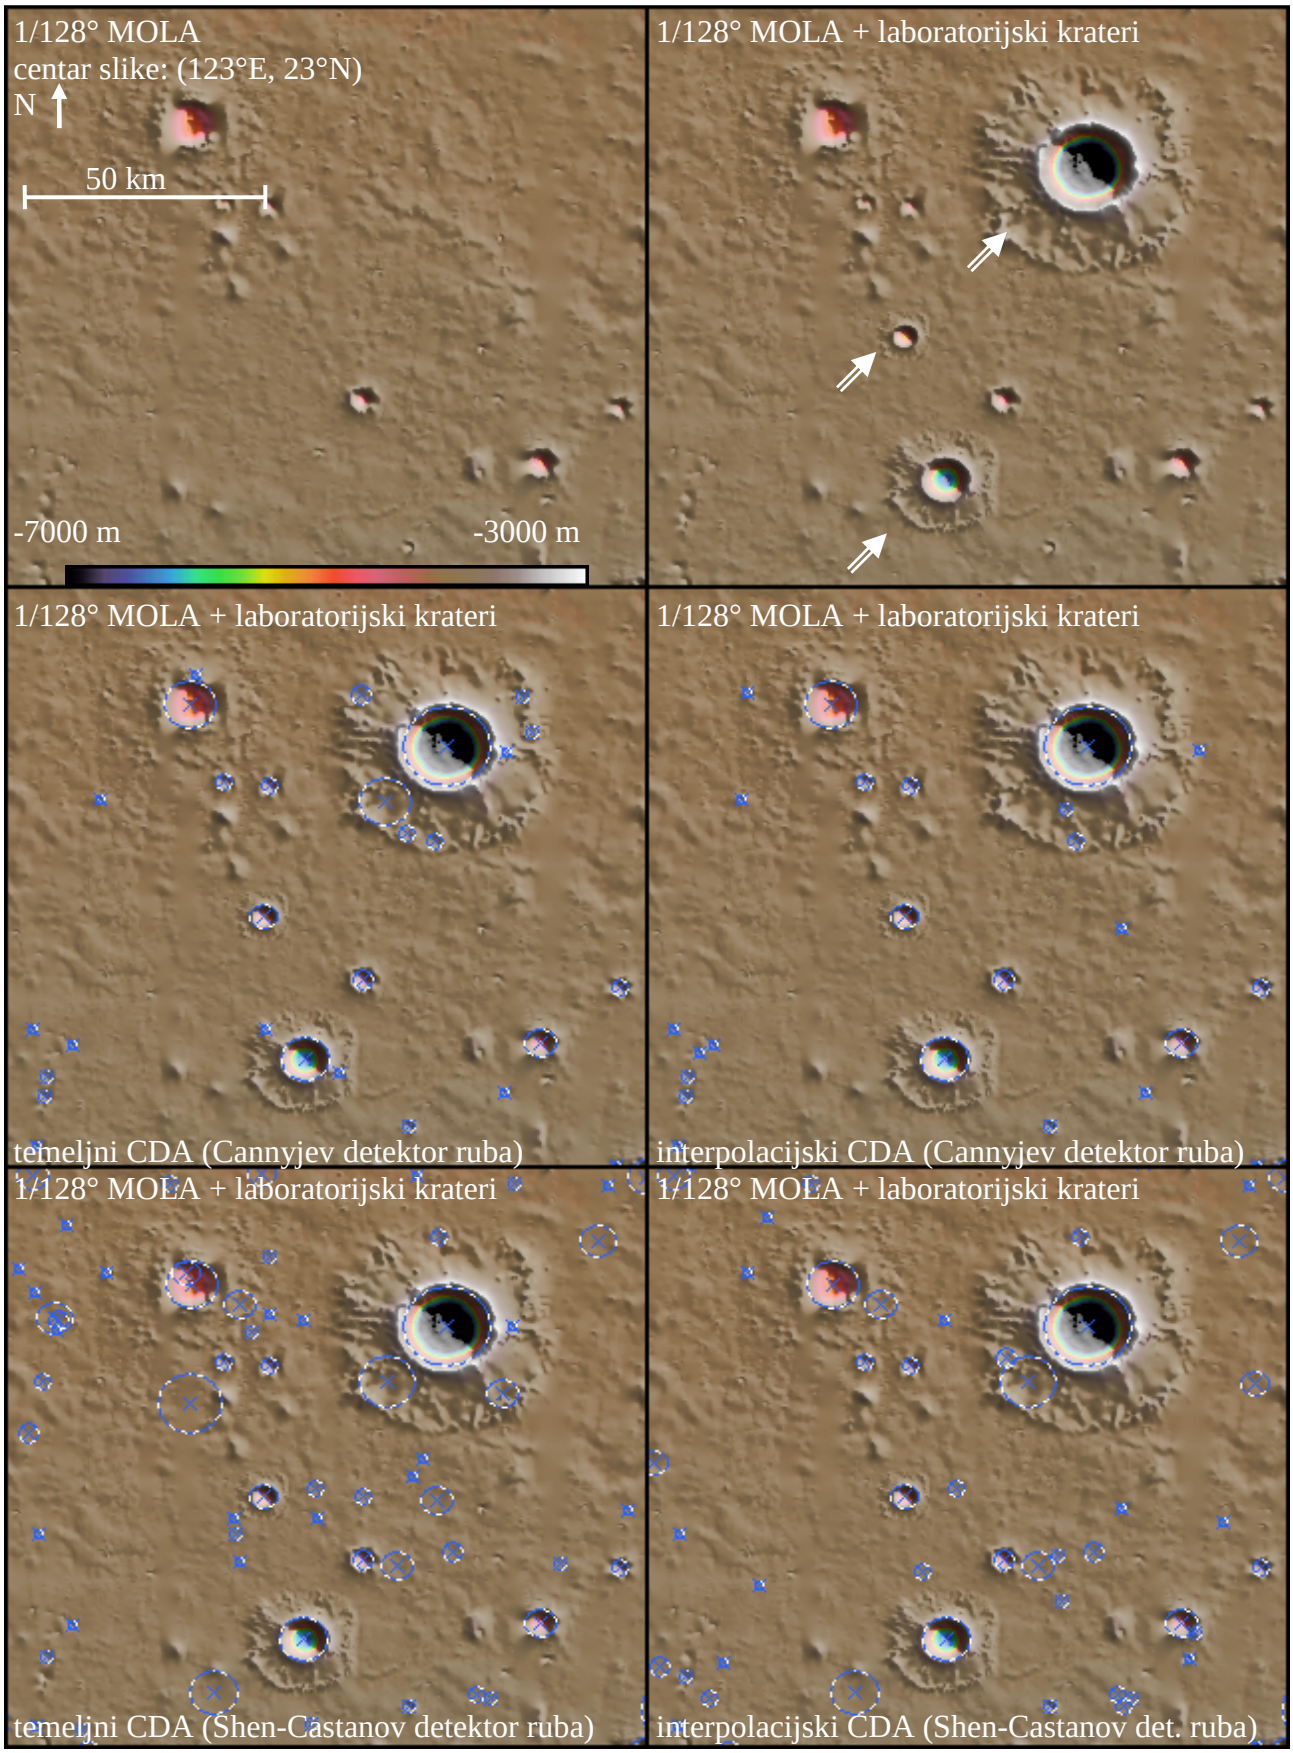
Uz prethodni test, čiji je rezultat ili zadovoljavajuća ili nezadovoljavajuća sličnost laboratorijskog i pravog kratera, može se napraviti i naprednije vrednovanje laboratorijskih kratera za dobivanje mjere sličnosti. U tu svrhu može se koristiti primjerice A-ROC vrednovanje CDA-a kako bi se odredio položaj laboratorijskih kratera na krivulji. Slika 95 prikazuje rezultat ove analize za slučaj CDA-a temeljenog na interpolaciji i Cannyjevom detektoru ruba, no ista analiza može se napraviti i za sve ostale slučajeve. Pritom imamo laboratorijski krater u tri veličine, no isto bi bilo i da imamo tri ili više različitih laboratorijskih kratera. Što je neki krater bliže ishodištu (donji lijevi ugao grafa), to je detektiran s višom pridruženom vjerojatnosti da je krater, pa je u tom smislu i 3D-oblikom sličniji pravom krateru. No sama pridružena vjerojatnost, za razliku od CDA-a koji je temeljen na učenju, kod ostalih CDA-ova ovoga rada nije broj u području od 0 do 100%, nego vrijednost koja je rezultat svih koraka CDA-a, gdje su vrijednosti samo međusobno usporedive. Postoji više načina normiranja pridijeljene vrijednosti vjerojatnosti. U ovom slučaju koristi se postotak udaljenosti od gornjeg desnog ruba grafa, kako definira formula (30). U našem slučaju najsličniji ispada najveći, a najmanje sličan najmanji, što je očekivajuće zbog utjecaja male horizontalne rezolucije na kvalitetu prikazanog 3D-oblika.

$$p_{\mathrm{lc}} = \sqrt{\frac{(1 - TDR)^2 + (1 - FDR)^2}{2}} \tag{30}$$

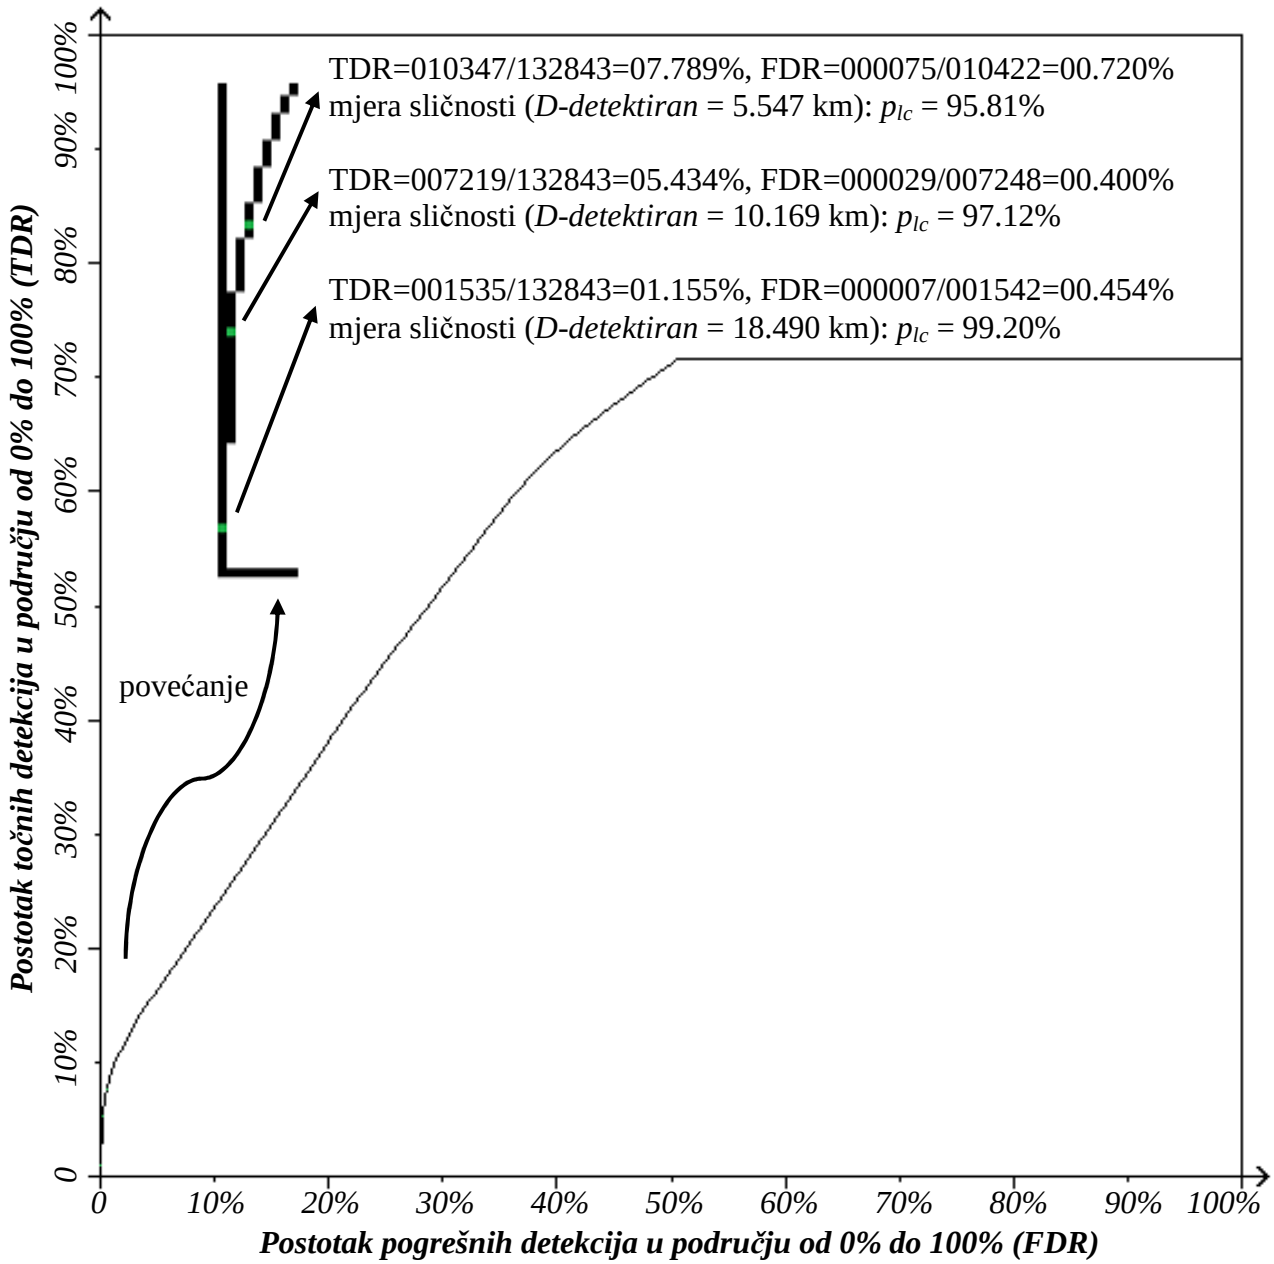


Slika 93. Primjeri (Vinković, 2009) laboratorijskih kratera (lijevo), skeniranje GOM-ATOS-I uređajem (desno gore) te rezultat skeniranja – 3D-modeli kratera (desno u sredini i desno dolje).

U sljedećom koraku, kako bi se pristup za vrednovanje laboratorijskih kratera CDA-ovima potvrdio kao robustan, skenirano je sedam različitih laboratorijskih kratera. Cilj je svaki od tih sedam kratera integrirati u topografske slike Marsa, kako bi se vidjelo hoće li ih korišteni CDA-ovi detektirati ili ne, te s kojom pripadnom vjerojatnosti. Kako bi se dodatno provjerila robusnost metode, cjelokupan eksperiment ponovljen je i korištenjem topografske slike Mjeseca.

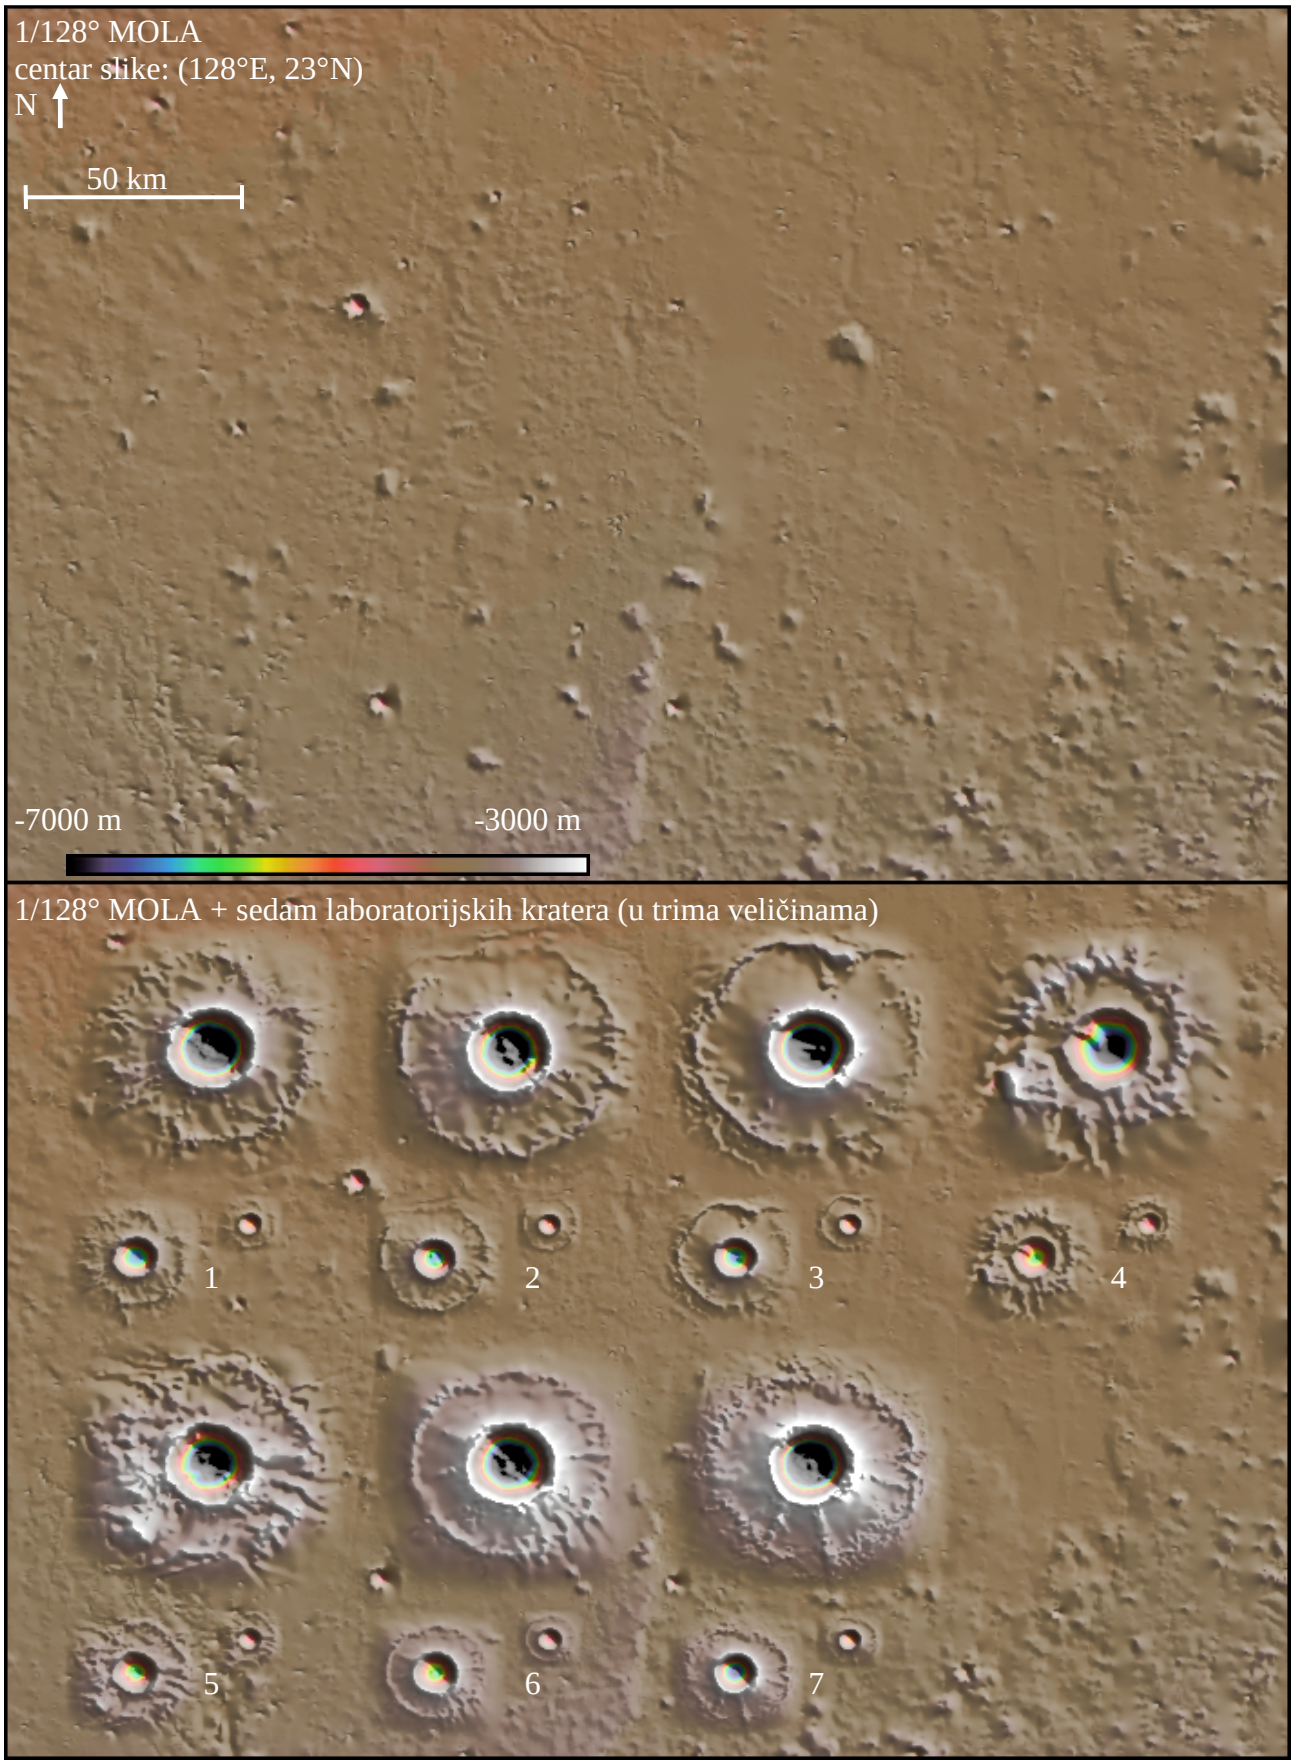


Slika 94. Topografija Marsa prije (gore lijevo) i nakon (gore desno) integracije laboratorijskog kratera u tri veličine (20, 10 i 5 km), te detekcije za CDA-ove ovoga rada bez (lijevo) i sa (desno) interpolacijom, korištenjem Cannyjevog (sredina) i Shen-Castanovog (dolje) detektora ruba.

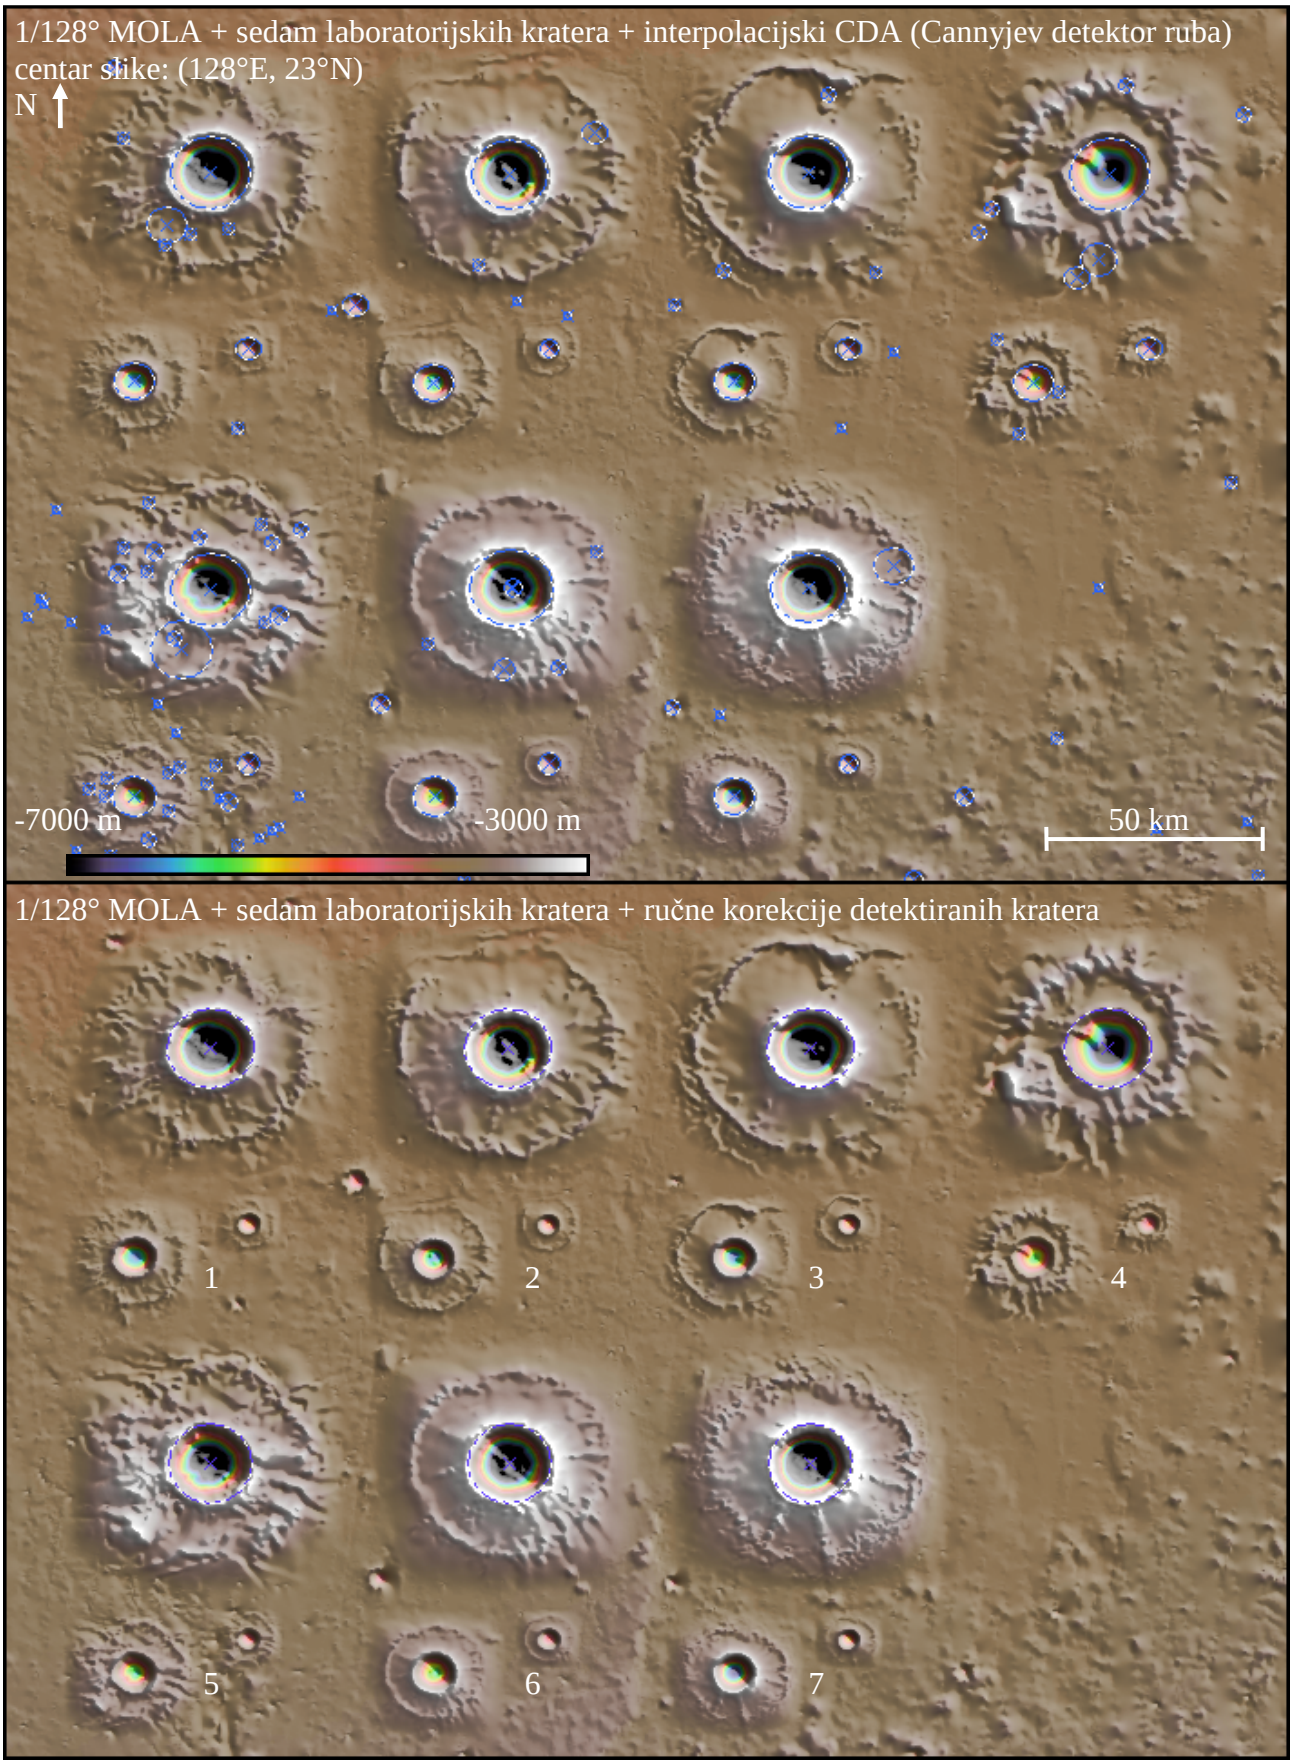


Slika 95. A-ROC vrednovanje interpolacijskog CDA-a koji koristi Cannyjev detektor ruba, korištenjem MA132843GT kataloga, 1/128° MOLA podatke i f_m<3.

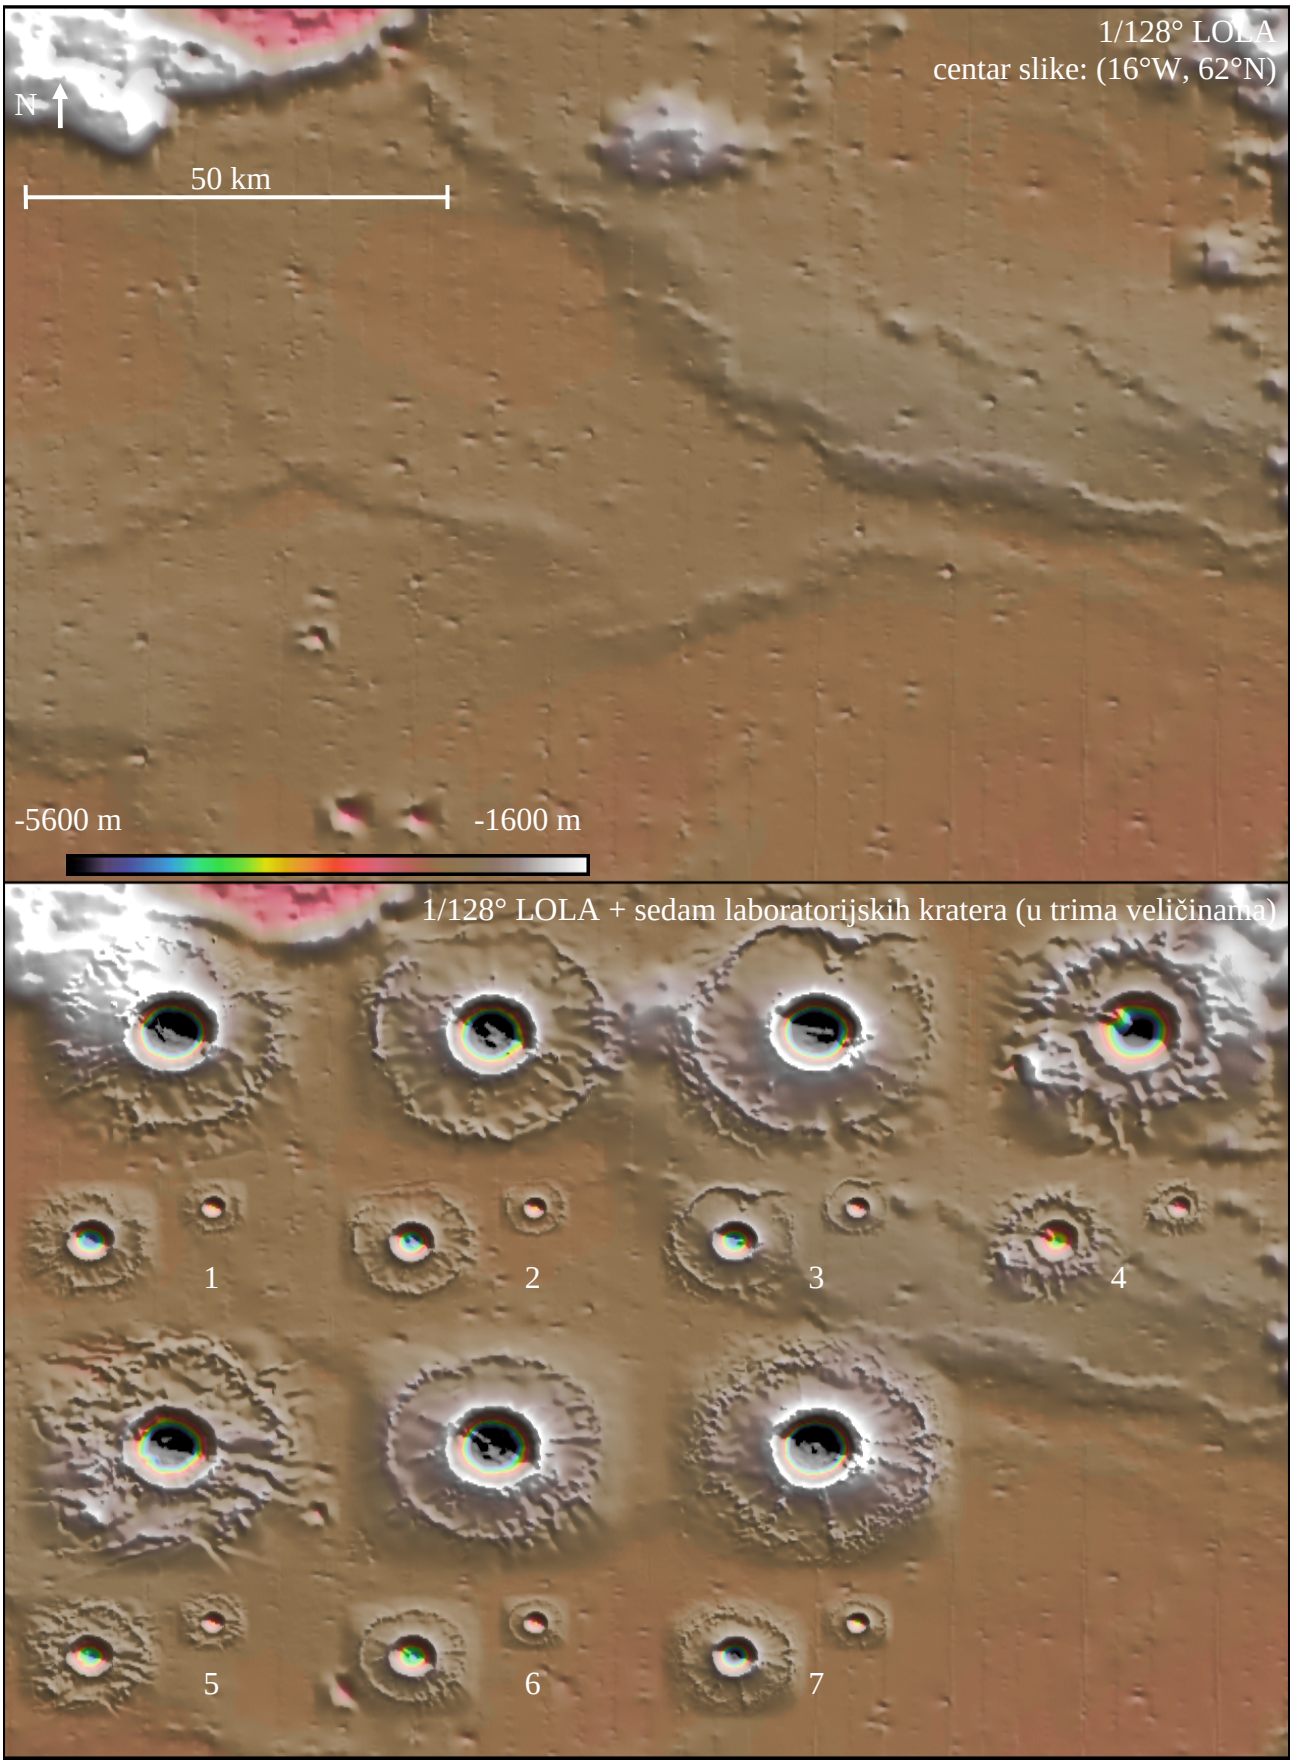
Za vrednovanje cjelokupnog pristupa odabran je dio površine koji je relativno ravan, ali ima i dovoljno neravnina. Slika 96 prikazuje topografiju površine Marsa prije i nakon integracije sedam laboratorijskih kratera, svakog u tri veličine. Iako prijelaz između okolne topografije i topografije laboratorijskih kratera nije onoliko dobar kao u slučaju samo jednog kratera kojem je odabrana optimalna pozicija, prijelaz je dovoljno dobar za potrebe eksperimenta. Slika 97 (gore) prikazuje rezultate detekcije CDA-a temeljenog na interpolaciji i Cannyjevom detektoru ruba. Eksperiment je ponovljen i sa Shen-Castanovim detektorom ruba, kao i s temeljnim CDA-om u kombinaciji s oba detektora ruba. Slika 98 prikazuje rezultate integracije laboratorijskih kratera u topografsku sliku Mjeseca, gdje su također svi zadovoljavajuće integrirani. Slika 99 (gore) prikazuje rezultate detekcije CDA-a temeljenog na interpolaciji i Cannyjevom detektoru ruba, za topografiju Mjeseca. Svi CDA-ovi su uspješno detektirali sve laboratorijske kratere u svim veličinama, i za primjer topografije Marsa i za primjer topografije Mjeseca, čime se pokazala robusnost predložene metodologije.



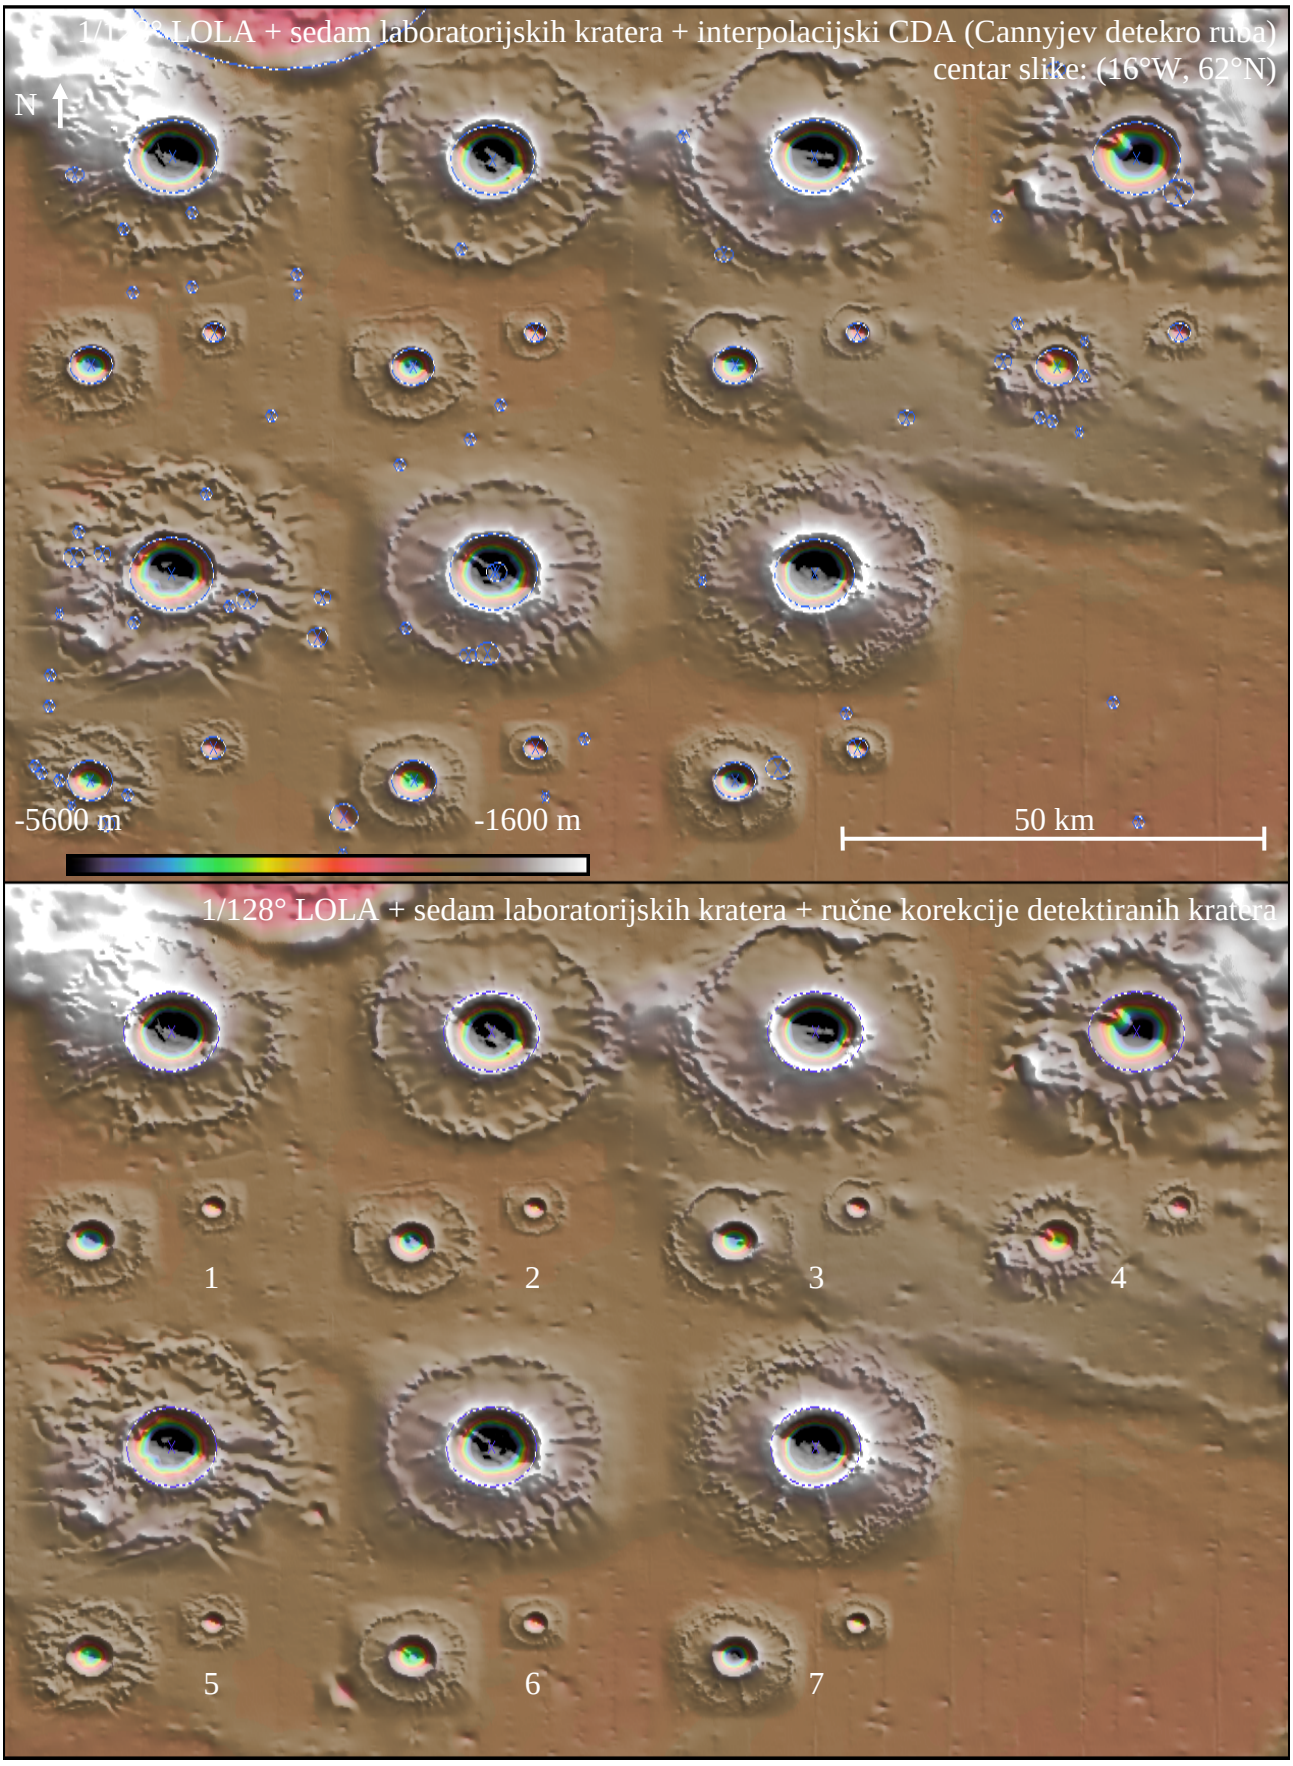
Slika 96. Topografija Marsa prije (gore) i nakon (dolje) integracije laboratorijskog kratera u tri veličine (20, 10 i 5 km). Svih sedam različitih laboratorijskih kratera uspješno je integrirano u pozadinsku topografiju s postepenim prijelazom između nje i integriranih kratera.



Slika 97. Detekcije CDA-a temeljenog na interpolaciji i Cannyjevom detektoru ruba (gore) i ručne korekcije detektiranih kratera (dolje), kako bi se za iste generirali topografski profili za daljnju analizu koja uključuje i usporedbu s topografskim profilima kratera Marsa.

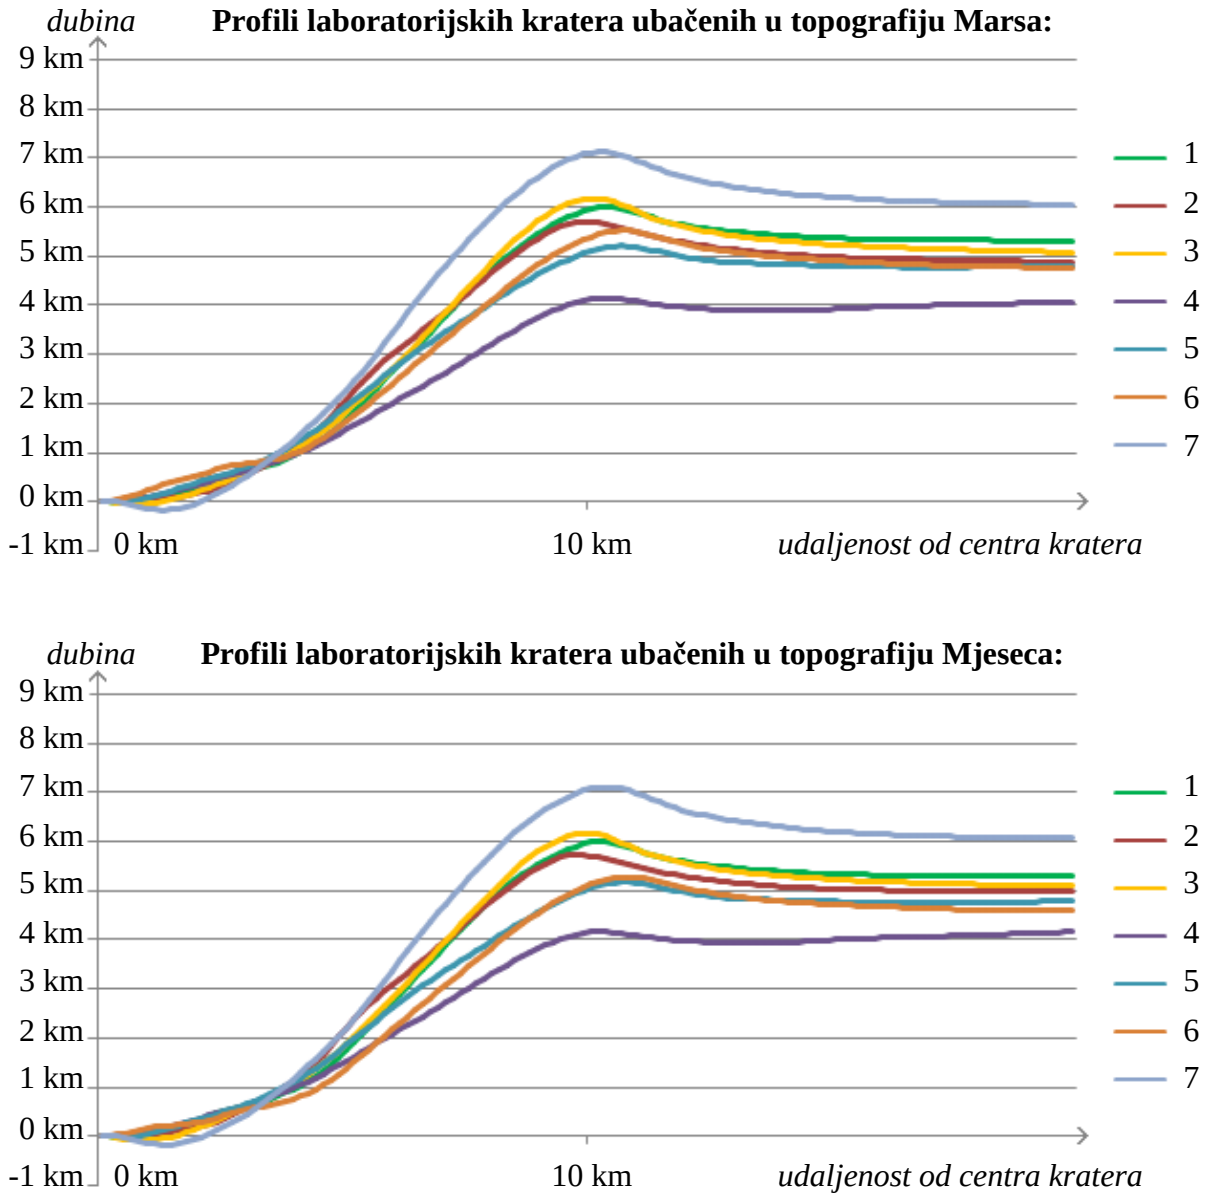


Slika 98. Topografija Mjeseca prije (gore) i nakon (dolje) integracije laboratorijskog kratera u tri veličine (kao i kod Marsa). Svih sedam različitih laboratorijskih kratera uspješno je integrirano u pozadinsku topografiju s postepenim prijelazom između nje i integriranih kratera.



Slika 99. Detekcije CDA-a temeljenog na interpolaciji i Cannyjevom detektoru ruba (gore) i ručne korekcije detektiranih kratera (dolje), kako bi se za iste generirali topografski profili za daljnju analizu koja uključuje i usporedbu s topografskim profilima kratera Mjeseca.

U završnoj fazi vrednovanja laboratorijskih kratera detekcije se po potrebi ručno korigiraju, slično kao što su se i registrirali pravi krateri. Cilj je što točnije mjerenje pripadnih topografskih profila. Slika 97 (dolje) prikazuje rezultate ručnog podešavanja detektiranih kratera za topografiju Marsa. Slika 99 (dolje) prikazuje pripadne rezultate ručnog podešavanja, ali za topografiju Mjeseca. Slika 100 prikazuje profile izmjerene interpolacijskim CDA-om. Rezultati su vrlo slični za topografije Marsa i Mjeseca, s obzirom na to da su isti krateri integrirani. Međutim, rezultati ipak nisu identični, s obzirom na to da postoje male razlike topografije u koju su integrirani. Razlike u rezultatima mogu se koristiti za procjenu točnosti mjerenja.



Slika 100. Profili laboratorijskih kratera integriranih u topografiju Marsa i Mjeseca, skalirani na dijametar od 20 km radi međusobne usporedbe, te usporedbe s profilima kratera Marsa i Mjeseca.

Slično se mogu generirati i profili pravih kratera na Marsu i Mjesecu, kako bi se usporedili s profilima laboratorijskih. Ovako se pruža sveobuhvatan pristup. Isti se temelji na autonomnosti CDA-a u vrednovanju laboratorijskih kratera, što je prva formalna i u potpunosti objektivna metoda razvijena s tom svrhom. Isti uključuje i ručnu analizu profila koja pruža mogućnost uobičajene analize, koja se može koristiti i za razmatranje dodatnog poboljšanja postupka za kreiranje laboratorijskih kratera.

9.6. Detekcija kratera Mjeseca iz topografije rekonstruirane iz optičkih slika

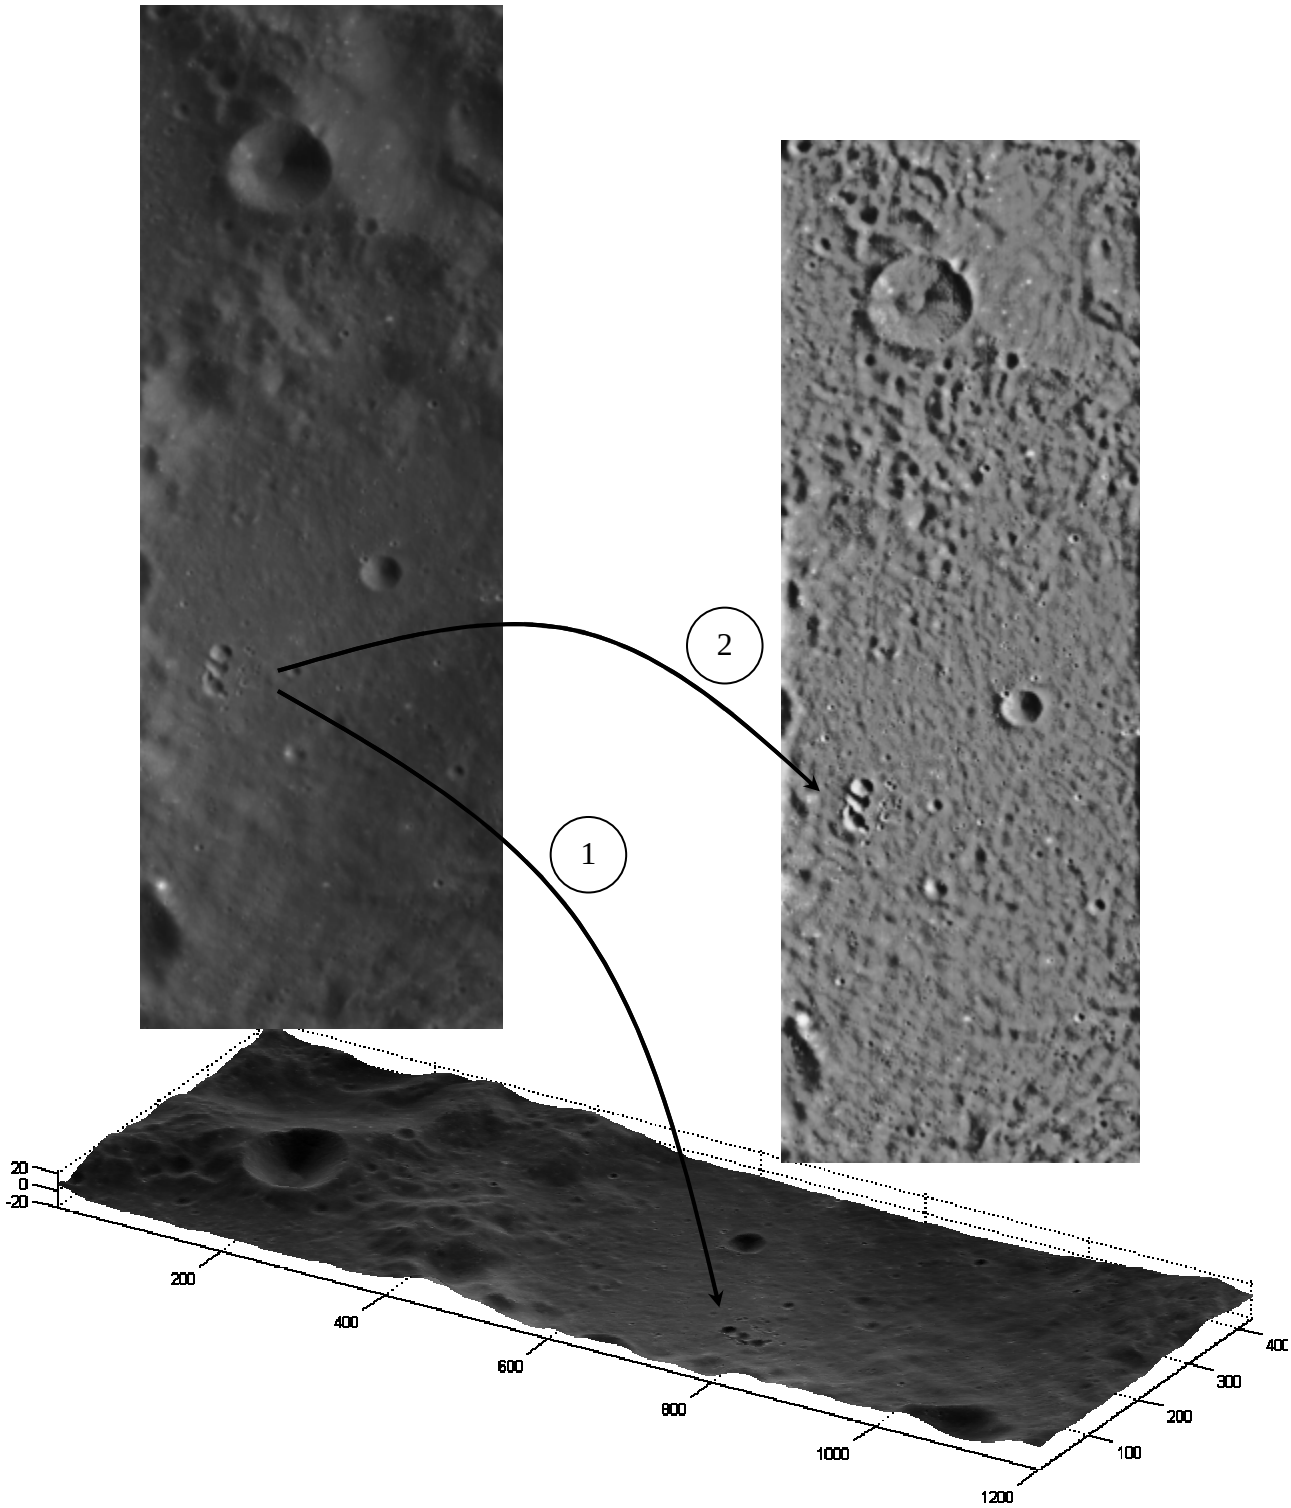
Ovaj dio rada napravljen je u suradnji s Christianom Wöhlerom i Arneom Grumpom (Lončarić et al., 2011; Salamunićcar et al., 2011e), čiji doprinos je rekonstrukcija topografskih iz optičkih slika (Grumpe i Wöhler, 2011). Sam princip rekonstrukcije topografskih slika iz optičkih, analizom sjena na slici, temelji se na radu Horna (1990).

Iz prethodnog zaključujemo da većina CDA-ova koji su postigli značajne rezultate koriste ili topografske ili optičke slike. Oba pristupa imaju svoje prednosti i nedostatke, a osnovni nedostatak CDA-ova koji koriste topografske slike je nemogućnost direktnog korištenja optičkih slika, iako su često u višoj horizontalnoj rezoluciji od topografskih. U tom smislu su od posebne važnosti postupci koji iz optičkih slika generiraju topografske, jer se time znatno proširuje moguća primjenjivost onih CDA-ova koji koriste topografske slike.

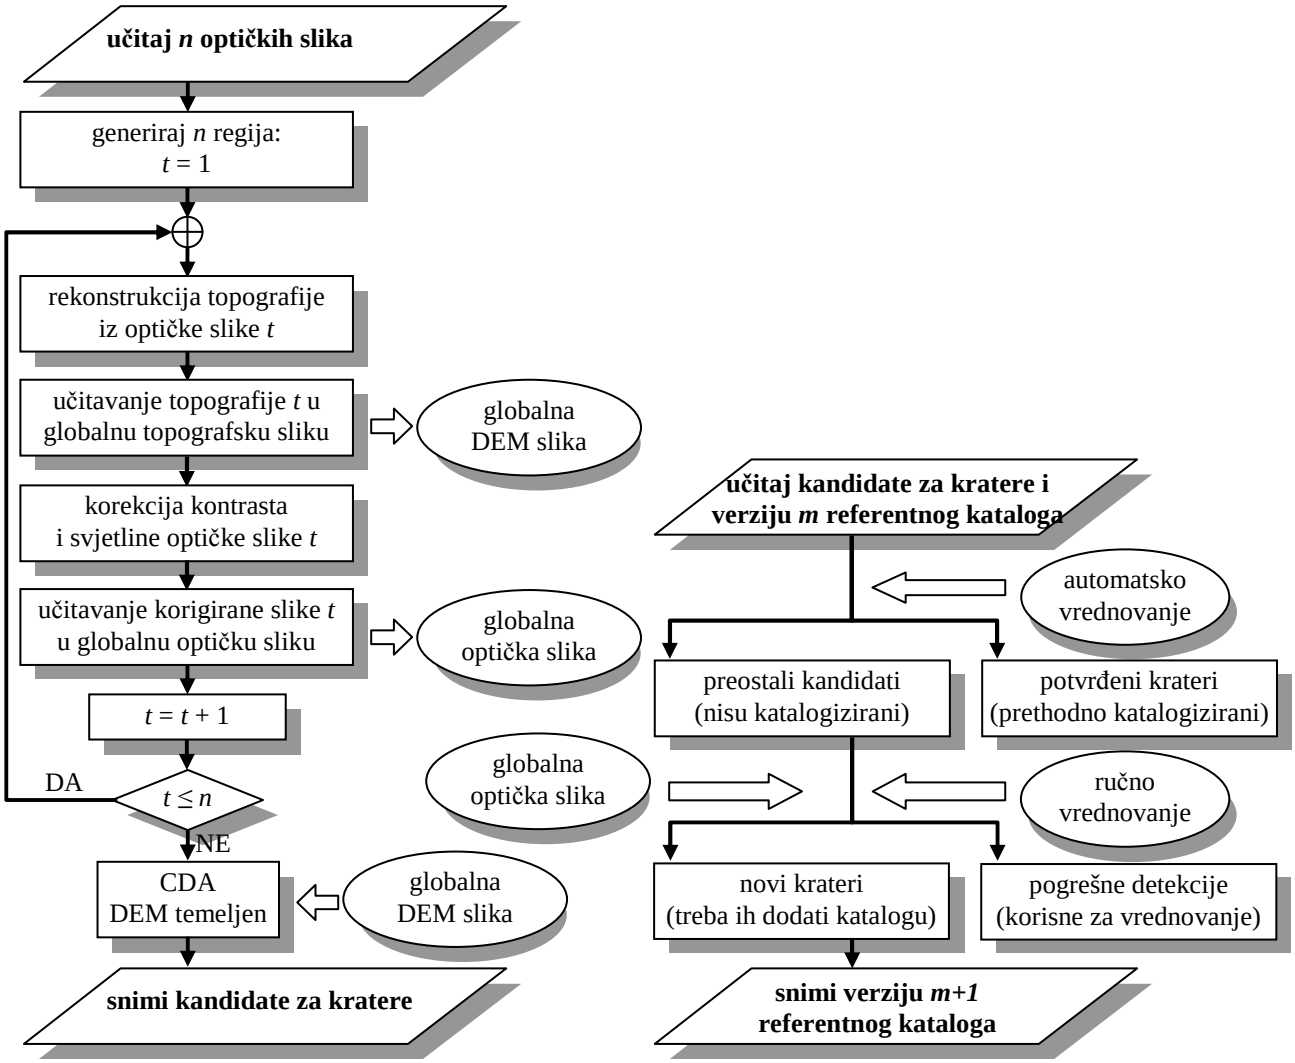
Jedna mogućnost generiranja topografskih slika iz optičkih je korištenje parova optičkih slika. Tada se razlike između slika koriste za rekonstrukciju topografije. Time se međutim metoda ograničava samo na one skupove podataka u kojima su dostupni parovi slika. Druga mogućnost je generiranje topografije iz samo jedne slike, korištenjem analize sjena za rekonstrukciju iznosa visina i gradijenata (Horn, 1990). Ovdje se druga mogućnost koristi za postizanja što veće primjenjivosti CDA-ova koji koriste topografske slike, kako bi isti mogli koristiti i optičke slike.

Slika 101 prikazuje osnovne korake obrade koji uključuju rekonstrukciju topografske slike iz optičke slike te poboljšavanje svjetline i kontrasta optičke slike kako bi se mogli lakše provjeravati kandidati za kratere. Slika 102 prikazuje dijagram toka predloženog hibridnog CDA-a. Za svaku od ulaznih optičkih slika definira se regija, odnosno koordinate rubova, koja definira gdje se navedena slika nalazi unutar globalne slike. Osnovni koraci obrade su rekonstrukcija topografske slike iz optičke slike te poboljšavanje svjetline i kontrasta. Rezultati obrade dodaju se pripadnoj izlaznoj globalnoj slici. U prvom slučaju to je globalna topografska slika, a u drugom globalna optička slika. Nakon obrade svih ulaznih optičkih slika, dobivena globalna topografska slika koristi se kao ulazna slika za CDA. Uz samu globalnu topografsku sliku CDA uzima u obzir regije u kojima je topografija rekonstruirana iz optičkih slika, kako bi kratere detektirao samo u tim regijama. Time se osigurava sveukupno brža obrada. Dobivena globalna optička slika koristi se prilikom ručne obrade kandidata za kratere koje je detektirao CDA. Na obrađenoj slici daleko se bolje vide detalji poput malih kratera i njihovih rubova, što olakšava provjeravanje kandidata za kratere. Osnovne značajke 3D-oblika kratera relativno su dobro rekonstruirane, kako je prikazano topografskom slikom, a što je posebno važno za rad CDA-ova.

Kako bi se vrednovali postignuti rezultati, koristio se interpolacijski CDA koji je pokazao bolje rezultate nego temeljni CDA (CDA temeljen na strojnom učenju još nije bio razvijen). Pritom su se koristili 1/512° LOLA podaci i topografski podaci rekonstruirani iz optičkih slika. Slika 103 prikazuje rezultate. CDA bolje detektira kratere korištenjem topografskih podataka rekonstruiranih iz optičkih slika, prvenstveno tamo gdje 1/512° LOLA podaci još nisu dostupni pa su stoga interpolirani vrijednostima najbližih slikovnih elemenata, koje su rezultat stvarnog mjerenja. Ovaj nedostatak slika se manifestira kao okomite pruge (bez stvarnih podataka) široke i više desetaka slikovnih elemenata. Kad znatan dio kratera nedostaje na topografskoj slici, onda je time i znatno otežana njegova detekcija, ili ovisno o dijelu koji nedostaje, ponekad i nije moguća. Rekonstruirane topografske slike nemaju dijelove bez stvarnih podataka jer slikovni elementi postoje za sve x i y vrijednosti korištene optičke slike, pa se tako i za svaki slikovni element može izračunati procjena pridijeljene visine.

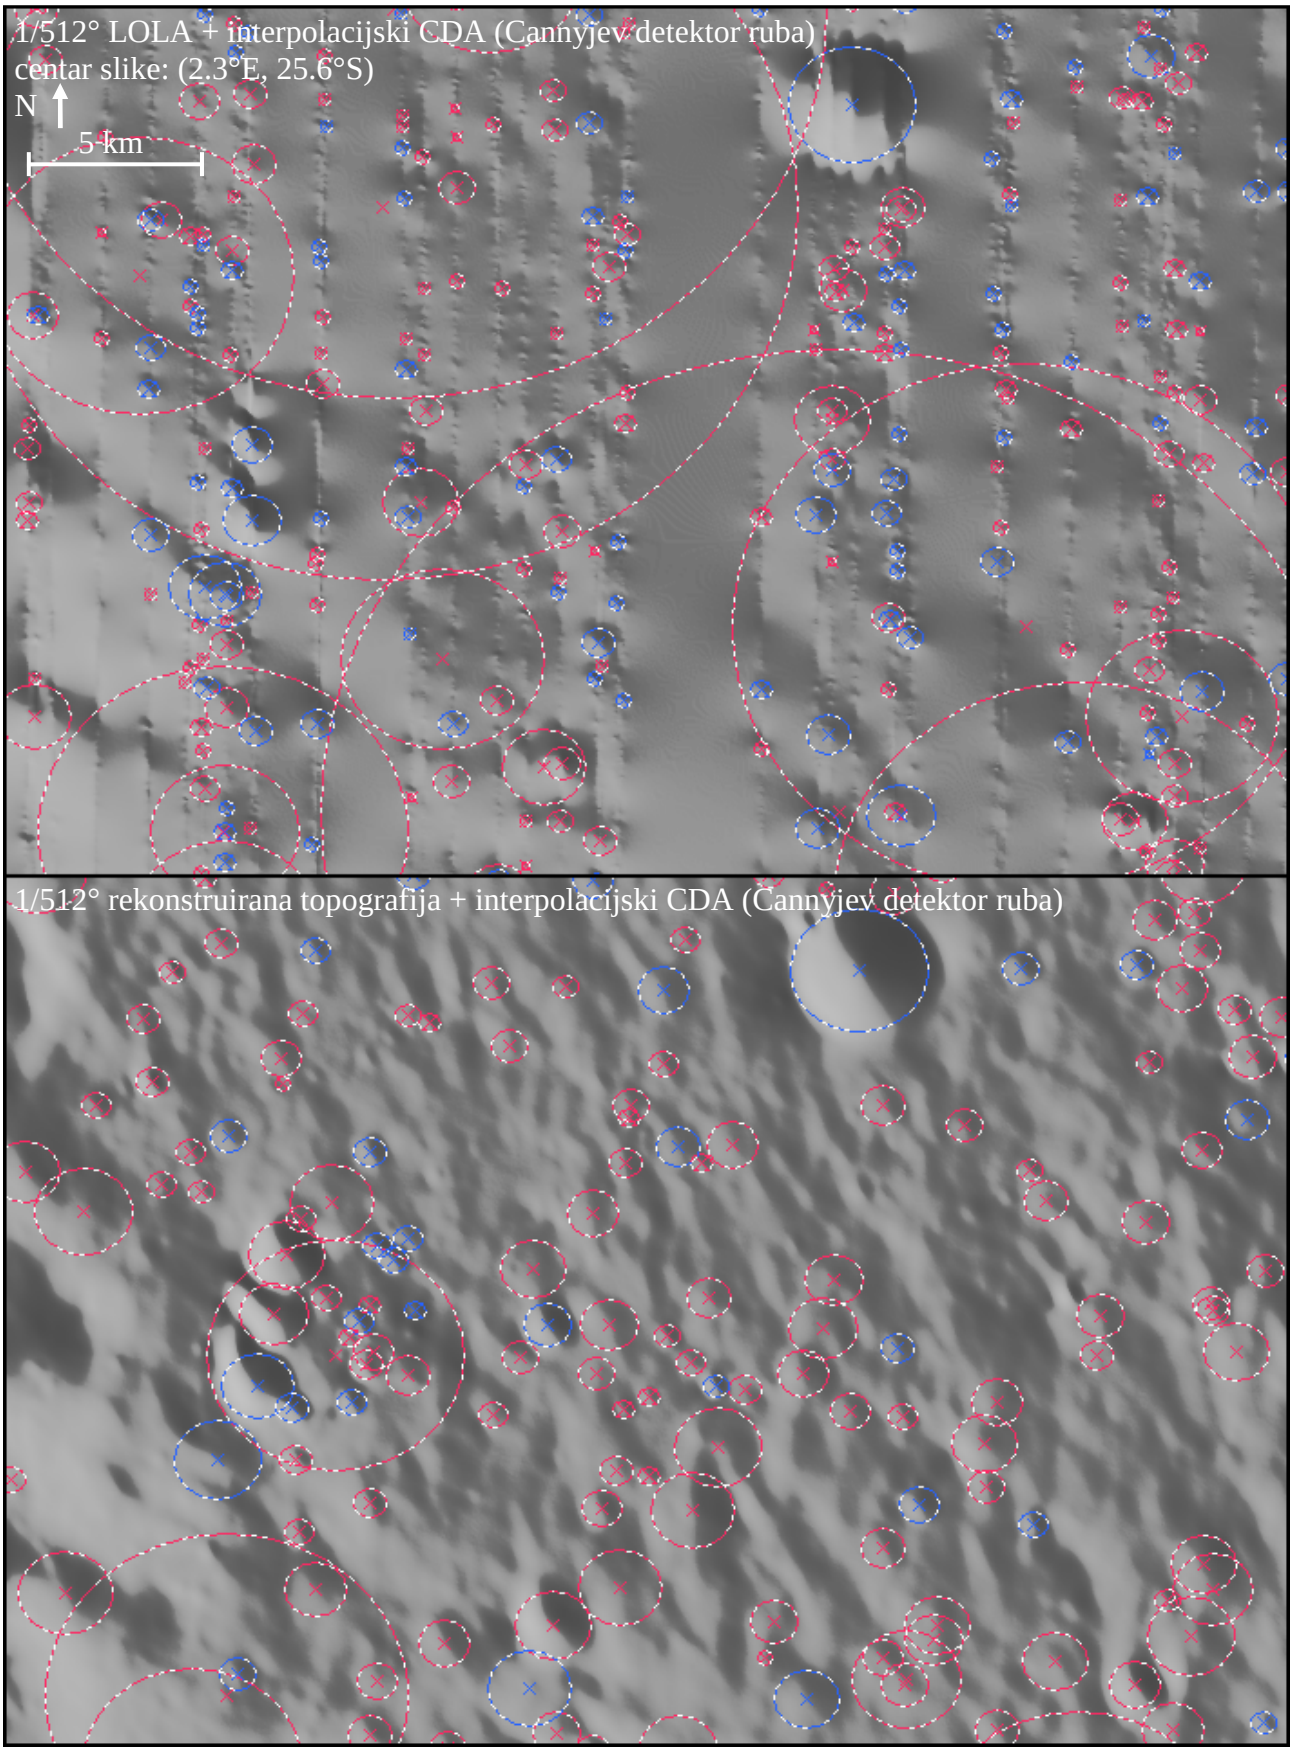


Slika 101. Osnovni koraci obrade (Lončarić et al., 2011): (1) rekonstrukcija topografske slike iz optičke; (2) poboljšavanje svjetline i kontrasta radi olakšavanja ručne provjere kratera te njihove katalogizacije.

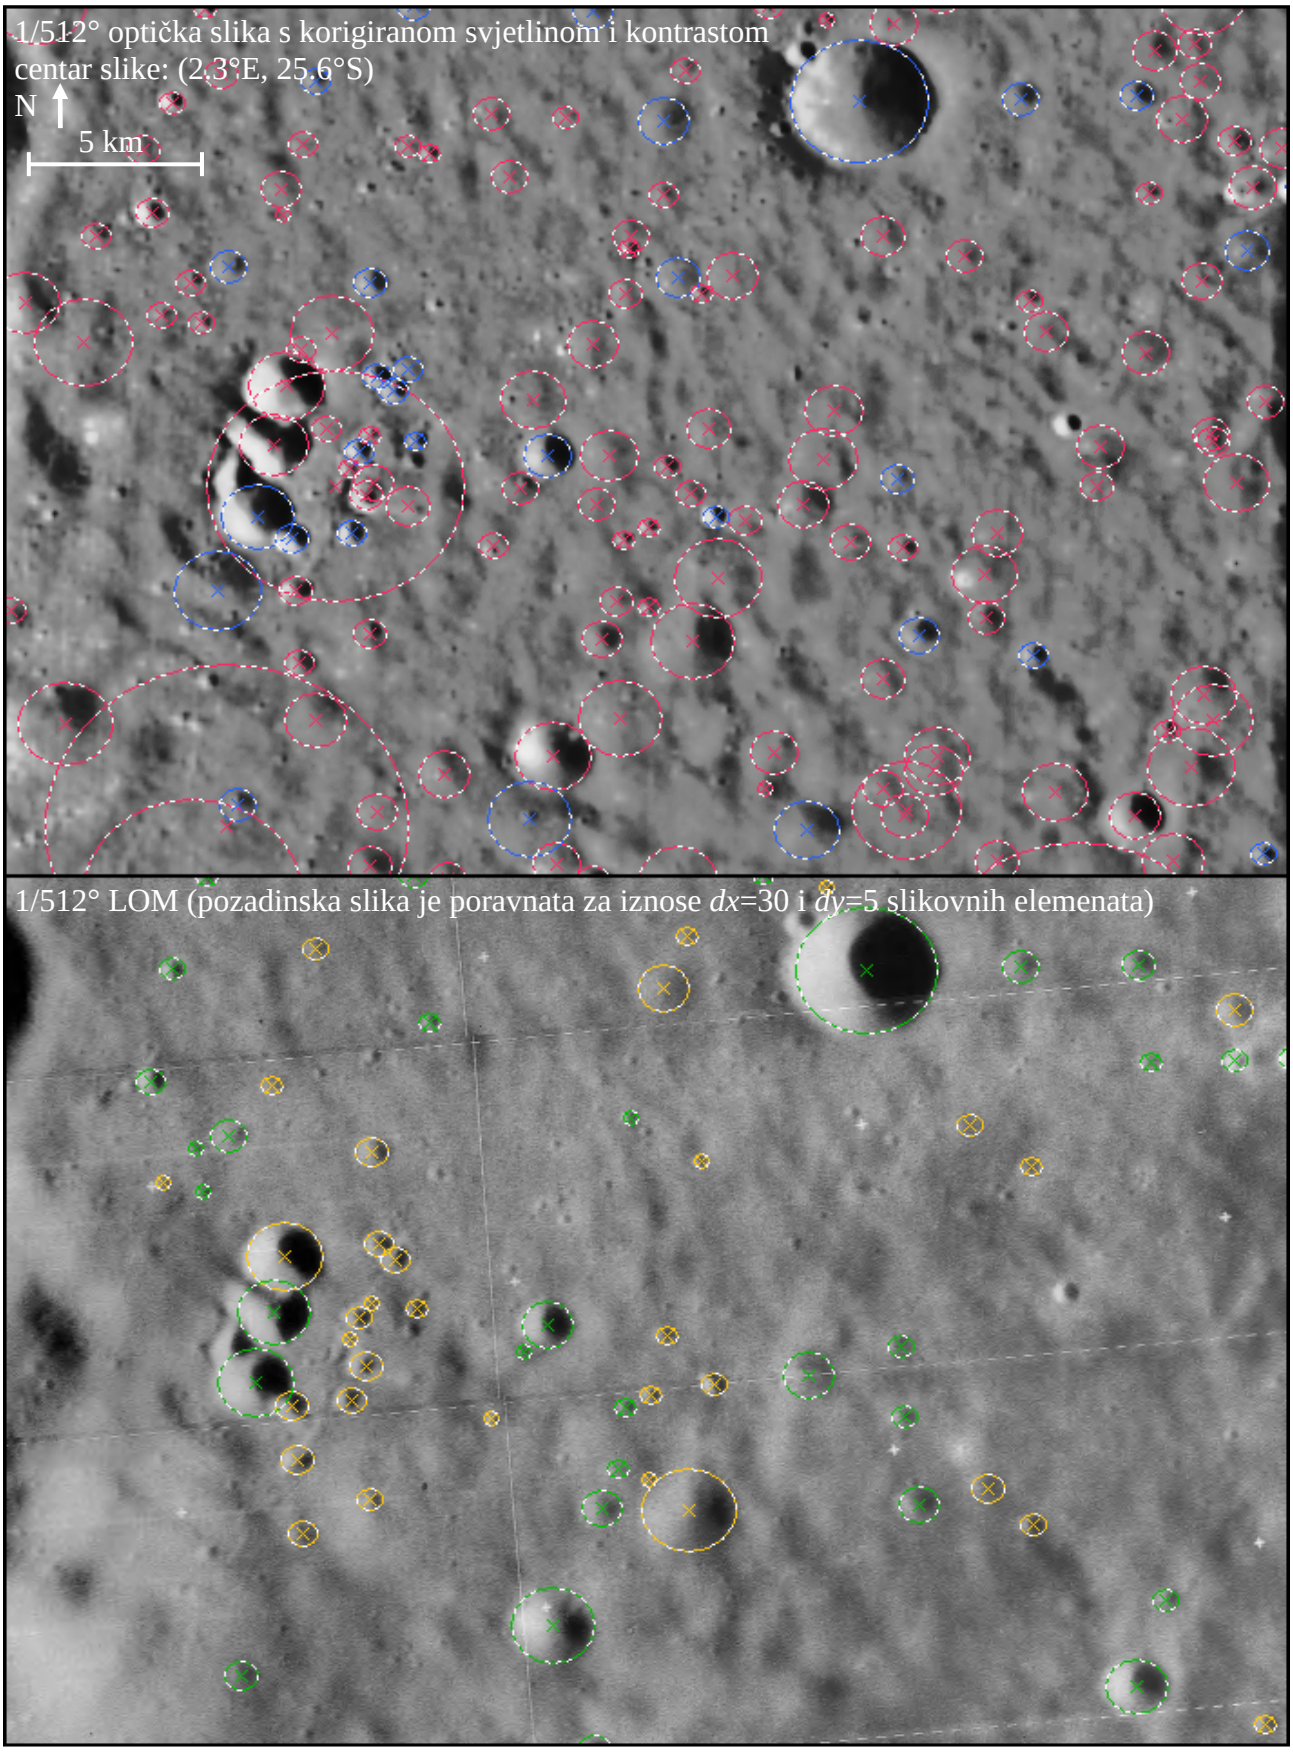


Slika 102. Dijagram toka (Salamunićcar et al., 2011e) predloženog hibridnog CDA-a (lijevo) i vrednovanja/katalogizacije kratera Mjeseca, a koje je detektirao hibridni CDA (desno).

U svrhu analize postignutih rezultata kandidati za kratere ručno su se katalogizirali isto kao i svi prethodni krateri Marsa, Mjeseca i Fobosa. Slika 104 prikazuje rezultate. Za odabranu sliku (1.64°E–3.06°E, 23°S–27°S) broj kandidata za kratere detektirane iz rekonstruirane topografije je 387 (60 sa $0.24 \leq p$, 327 sa $0.12 \leq p < 0.24$, gdje je p pridružena vjerojatnost), a broj točnih detekcija je 125 (43 i 82, za ta dva područja pridijeljenih vjerojatnosti). Od tih 125 kratera, 54 nisu bili detektirani s 1/512° LOLA podacima korištenjem istog praga vjerojatnosti, a ostalima su uglavnom preciznije detektirane koordinate i dijametri. Ovim se pristupom pokazala ne samo mogućnost detekcije i katalogizacije više kratera, nego i veća točnost njihovih početno pridijeljenih koordinata i dijametara, pa je sveukupna kasnija katalogizacija brža.

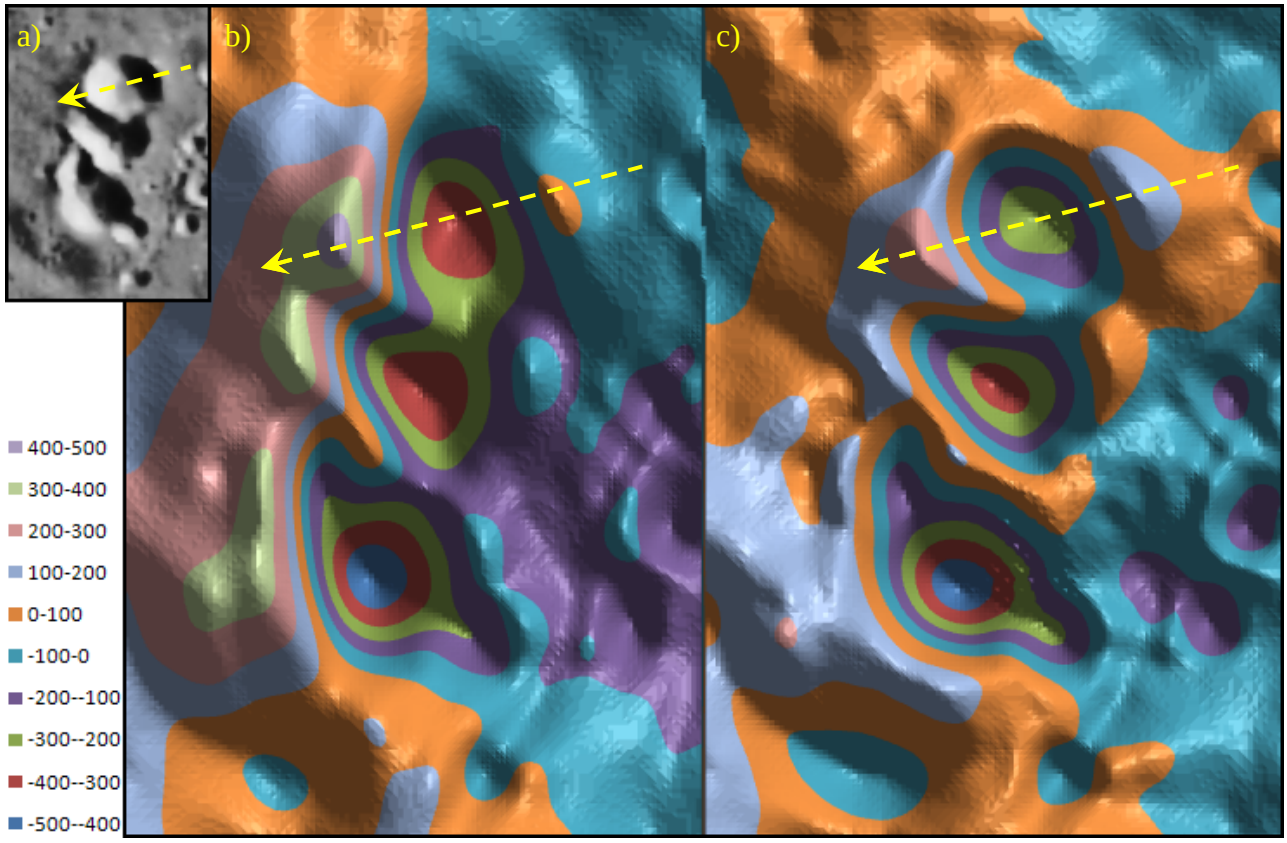


Slika 103. Osnovna razlika između LOLA podataka (gore) i rekonstruirane topografije (dolje) je velik broj područja LOLA podataka koja dosad nisu pokrivena mjerenjima pa su stoga interpolirana susjednim vrijednostima. Za CDA je stoga rekonstruirana topografija bolja za detekcije kratera.



Slika 104. Detekcije s visokom vjerojatnosti da su krateri ($0.24 \leq p$) označene su plavom bojom, a one s niskom vjerojatnošću ($0.12 \leq p < 0.24$) crvenom, gdje p određuje CDA (gore). Samo oni krateri koji su prikazani zelenom bojom (dolje) mogu se detektirati i iz 1/512° LOLA podataka.

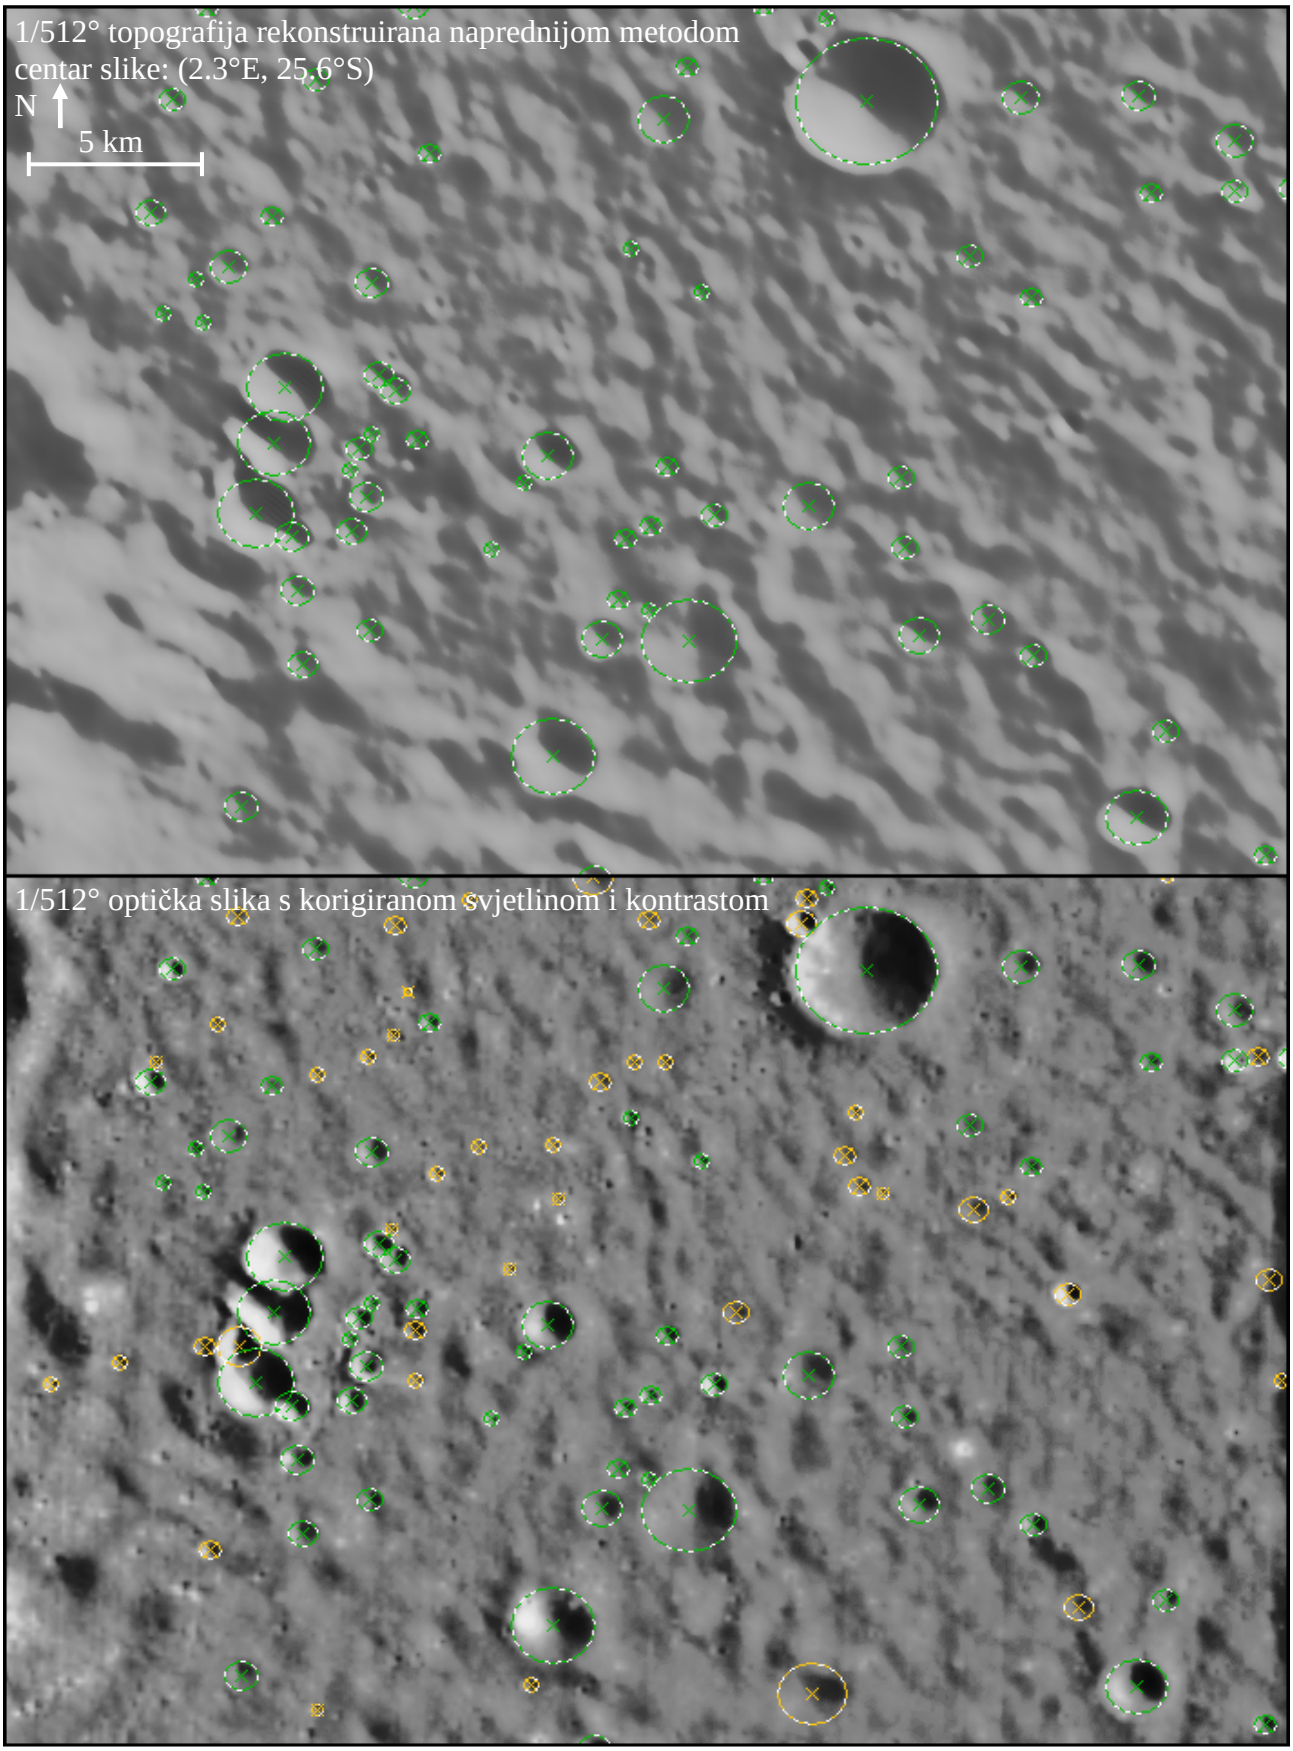
U sljedećom koraku analizirani su detektirani krateri, kao i oni koji nisu detektirani ili su detektirani s malom pridijeljenom vjerojatnosti, sa svrhom ispitivanja mogućnosti poboljšanja algoritma koji rekonstruira topografske slike iz optičkih. Slika 105 prikazuje rezultate te analize. U rekonstruiranim topografskim slikama ima naime određenih manjih nedostataka poput nejednako uspješne rekonstrukcije oblika kratera u smjeru svjetla i okomito na taj smjer. Zahvaljujući robusnosti CDA-a to nije značajnije utjecalo na rezultat, ali je postalo predmet daljnjeg usavršavanja algoritma za rekonstrukciju topografije iz optičkih slika. Slika 105 prikazuje i realističniju topografiju rekonstruiranu iz optičkih slika usavršenim algoritmom u usporedbi s očekivanim oblikom kratera. Pod očekivanim oblikom kratera podrazumijeva se oblik veće cirkularnosti. Druga se slika (c) stoga smatra realističnijom od prve (b) jer su odstupanja od prosječne elevacije u smjeru svjetla i okomito na smjer svjetla manja.



Slika 105. Rezultati analize početne (b) i poboljšane (c) verzije algoritma za rekonstrukciju topografije (Salamunićcar et al., 2011e), pri čemu strelica označava smjer svjetla na slici (a).

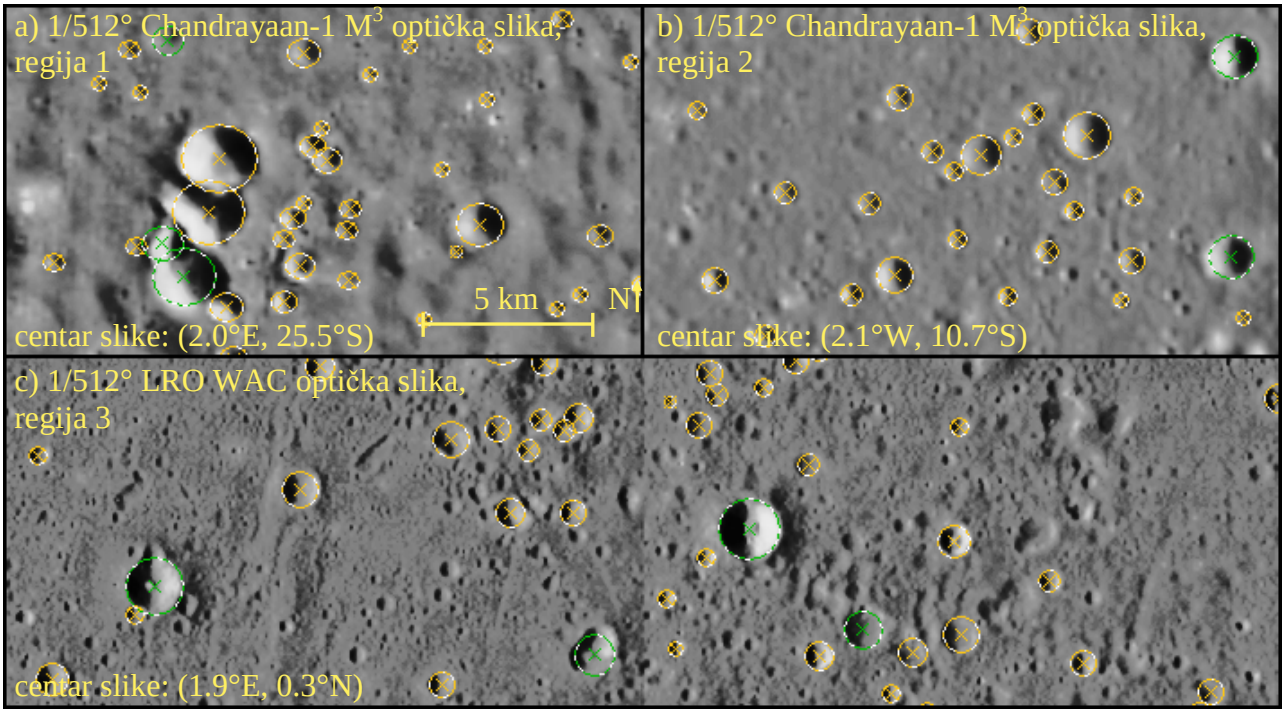
Korištenjem topografije rekonstruirane poboljšanom metodom (Wöhler i Grumpe, 2011) ponovljena je detekcija kratera CDA-om istog područja. U ovom koraku ukupno je ručno obrađeno dodatnih 567 kandidata za kratere i prethodni katalog sa 125 kratera proširen je sa 128 kratera. Slika 106 prikazuje rezultate korištenja interpolacijskog CDA-a u kombinaciji s poboljšanim algoritmom za rekonstrukciju topografije iz optičkih slika. U ovom slučaju ima još više kratera koji se mogu detektirati iz rekonstruirane topografije, ali ne mogu direktno iz LOLA podataka.

Rezultirajući katalog s 253 kratera potvrdio je znatno poboljšanje detekcije kratera iz optičkih slika, gdje je rekonstrukcija topografije međukorak. Potvrdio je i dodatnu moguću primjenu CDA-ova ovoga rada za vrednovanje metoda koje rekonstruiraju topografiju iz optičkih slika (kako je također pokazano prethodnim primjerom).



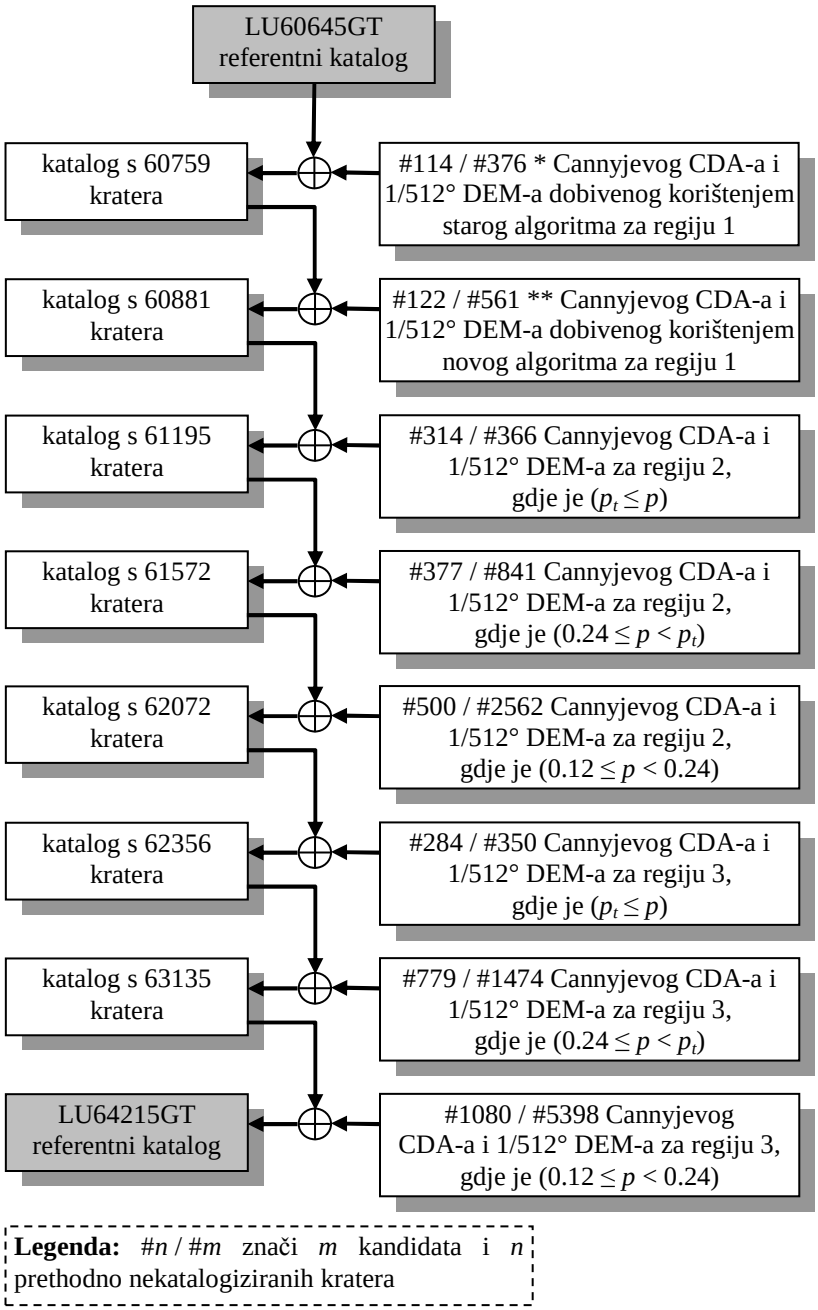
Slika 106. Prethodno detektirani krateri (označeni zelenom bojom) te krateri koji se mogu detektirati samo korištenjem topografije rekonstruirane naprednijom metodom (označeni žutom bojom); poboljšanje je prvenstveno u detekciji jako malih kratera.

Vremenom LOLA podaci postaju sve potpuniji, s obzirom na to da LRO misija i dalje traje. Svakako to može direktno doprinijeti LU60645GT katalogu dodatnim proširenjem. Međutim i pristup temeljen na rekonstrukciji topografskih slika iz optičkih svakako može doprinijeti katalogiziranju kratera Mjeseca. Znatan doprinos očekuje se s obzirom na dostupnost novih optičkih slika u vrlo visokoj horizontalnoj rezoluciji, koje će ponovo neke dijelove Mjeseca pokrivati u višoj horizontalnoj rezoluciji od topografskih. Doprinos ove metode očekuje se i u slučajevima ostalih lunarnih i planetarnih tijela, gdje topografski podaci nisu dostupni, ili su dostupni u nedovoljnoj horizontalnoj rezoluciji. Radi provjere robusnosti cjelokupnog pristupa, u završnom koraku obrađena je još jedna Chandrayaan-1 M^3 slika te jedan odabrani dio (regija) globalne LRO WAC (*Wide Angle Camera*) slike. Slika 107 prikazuje rezultate ovoga proširenja, kojim je prethodni LU60645GT katalog dodatno upotpunjen u trima odabranim regijama.



Slika 107. Proširenja prethodnog LU60645GT kataloga (zeleni krateri) s kraterima detektiranim korištenjem interpolacijskog CDA-a (žuti krateri) koji koristi topografske slike rekonstruirane iz optičkih slika (Salamunićcar et al., 2011e).

Rezultat ovoga istraživanja trenutno je najpotpuniji katalog kratera mjeseca, LU64215GT (Salamunićcar et al., 2011e). Slika 108 prikazuje doprinos interpolacijskog CDA-a prilikom izrade tog kataloga, a pri čemu su se koristile topografske slike rekonstruirane iz optičkih slika triju odabranih regija. Kao što je prikazano, prethodni katalog značajno je proširen na području dvije Chandrayaan-1 M^3 slike i odabranog dijela globalne LRO WAC slike. Time je pokazana primjenjivost predloženog pristupa za optičke slike dvije različite planetarne misije. Globalna LRO WAC slika sastavljena je od individualnih slika (mozaik), što je bio dodatni problem. Slika 107 u dijelu (c) prikazuje upravo takav slučaj, koji se manifestira u razlici između svjetlina desnog i lijevog dijela slike. Uz razliku u svjetlini dodatan problem može biti i razlika u smjeru svjetla. Navedeno rezultira lošijom rekonstrukcijom topografije iz optičkih slika blizu takvih rubova, pa je time robusnost CDA-a i ovdje važna. S druge strane, prednosti globalne LRO WAC slike u odnosu na individualne Chandrayaan-1 M^3 slike je njezina bolja registracija s LOLA podacima (čime je ručna obrada kandidata za kratere jednostavnija i brža) te mogućnost rekonstrukcije globalne topografske slike (umjesto samo za odabrane regije).



Slika 108. Doprinos hibridnog CDA-a prilikom izrade najpotpunijeg javno dostupnog LU64215GT kataloga Mjeseca (Salamunićcar et al., 2011e), korištenjem topografije rekonstruirane iz optičkih slika triju odabranih regija (11* i 6** kratera je već bilo u prethodnom LU60645GT katalogu; $p_t = 0.39068145$ - maksimum Q krivulje dobiven korištenjem MA130301GT kataloga).

Zahvaljujući registriranosti rekonstruiranih topografskih i korištenih optičkih slika, očekuje se doprinos i u kombiniranju CDA-ova koji detektiraju kratere iz topografskih slika s onima koji ih detektiraju iz optičkih. Cilj mogućeg budućeg istraživanja u tom smjeru je postignuće boljih svojstava detekcije kratera od postojećih CDA-ova koji koriste isključivo optičke ili topografske slike.

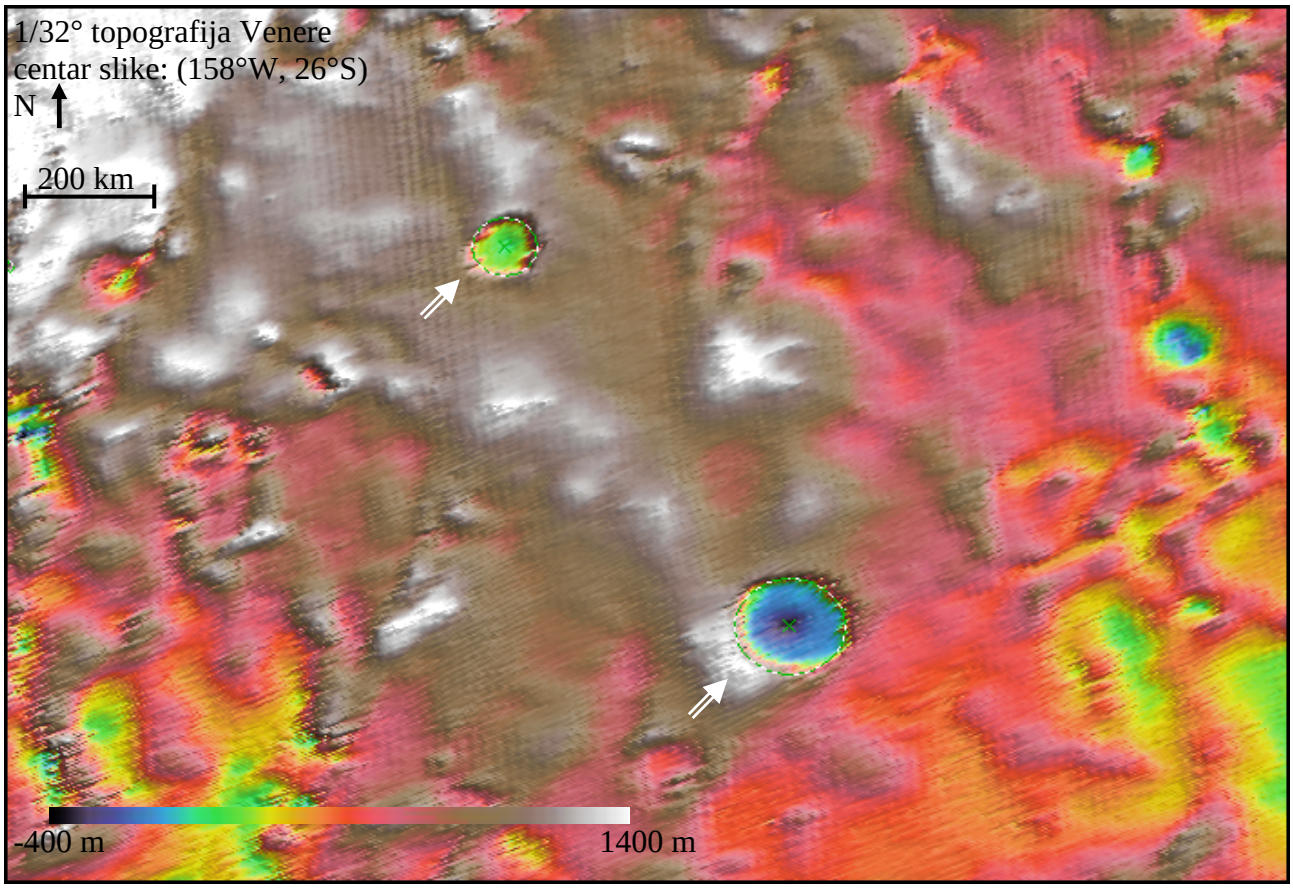
9.7. Strojna detekcija kratera Venere

Osnovna razlika Venere u usporedbi s Marsom, Mjesecom i Fobosom je njezina daleko gušća atmosfera, geološki značajno aktivnija površina, što rezultira daleko manjim brojem kratera. Kako bi se ispitala mogućnost korištenja CDA-ova ovoga rada i za detekciju kratera Venere, napravljeni su prvi koraci i u tom smjeru. I ovdje je također cilj pronaći još nekatalogizirane kratere, s obzirom na njihov ukupan mali broj.

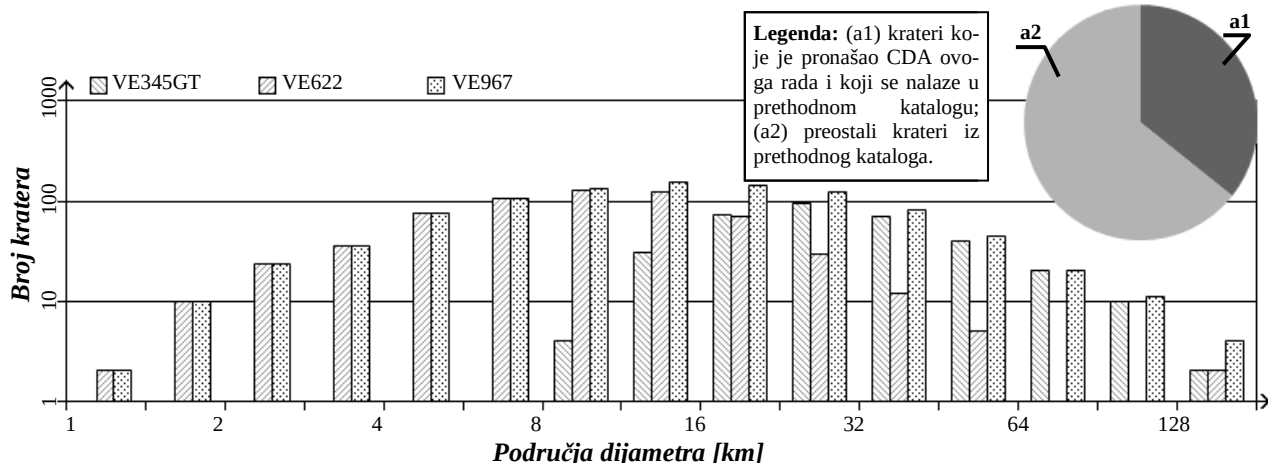
Dosad je opisan samo jedan CDA koji obrađuje slike Venere (Barata et al., 2010), no u tom slučaju koristile su se optičke, a ne topografske slike. Globalne topografske slike Venere su u vrlo niskoj horizontalnoj rezoluciji i s velikim iznosom šuma, što predstavlja dodatan problem za CDA-ove. Također, s obzirom na njihovu nisku horizontalnu rezoluciju, nije bilo moguće provjeriti ni većinu od 967 kratera iz dostupnog VE967 kataloga (USGS, 1999), to jest odrediti jesu li oni točni ili pogrešni zapisi, kako je napravljeno za sve prethodne kataloge drugih planetarnih tijela. Jedan od budućih koraka svakako bi bio i priprema globalnog optičkog mozaika za Veneru, u višoj horizontalnoj rezoluciji od dostupnih topografskih, kako bi se taj katalog revidirao i time konstruirao što potpuniji referentni katalog za Veneru.

Kako bi se preliminarno mogla ispitati uspješnost CDA-ova ovoga rada za detekciju kratera Venere, interpolacijskim CDA-om (inače se pokazao boljim od temeljnog CDA-a, dok strojno učenje nije potrebno za ovoliko malen broj kratera) izvršile su se detekcije kratera iz dostupnih topografskih slika Venere. Rezultat se usporedio s kraterima iz dostupnog kataloga. Slika 109 prikazuje dva kratera koje je CDA detektirao, a koji su se nalazili i u VE967 katalogu. Ista slika također prikazuje i puno više šuma na topografskim slikama Venere u usporedbi s topografskim slikama Marsa, Mjeseca i Fobosa. Dodatni nedostatak topografskih slika Venere je i njihova dostupnost samo do 1/32° horizontalne rezolucije. Šum se očituje kao nazubljenost topografskih vrijednosti slike, što je posebno izazov detektorima ruba. Mars, Mjesec i Fobos naime nemaju atmosferu, pa je u slučaju Marsa i Mjeseca korišten laser za preciznije mjerenje topografskih vrijednosti, a u slučaju Fobosa slika (iz koje je rekonstruirana topografija) s također puno manje šuma. Venere ima iznimno gustu atmosferu, pa ovakva mjerenja nisu bila moguća. Stoga se koristio radar, što je omogućilo dobivanje topografskih slika, no puno lošije kvalitete.

Rezultat interpolacijskog CDA-a koji koristi Cannyjev detektor ruba i iste parametre korištene i za Mars, Mjesec i Fobos, uspoređen je s VE967 katalogom, korištenjem napredne metode za uparivanje kratera do f_m<3. Svaki krater je i ručno provjeren prilikom registracije u referentni katalog. Provjera se oslanjala prije svega na činjenicu da je krater i naveden u korištenom katalogu i detektiran korištenjem CDA-a, što je bilo dostatno za registraciju istog. Ovaj pristup se koristio jer još nije pripremljen i globalni optički mozaik, a opravdan je dosadašnjim iskustvima na ostalim lunarnim i planetarnim tijelima. Pritom se nisu dorađivale koordinate i radijusi detektiranih kratera, također zbog loše kvalitete topografskih slika, već su se koristile vrijednosti iz VE967 kataloga. Rezultat je 345 kratera, odnosno VE345GT katalog. Time je pokazano postojanje znatnog broja kratera iz VE967 kataloga koje je CDA uspio detektirati, a koji su prvenstveno najveći krateri iz VE967 kataloga, dovoljno veliki za detekciju iz dostupnih topografskih slika. Stoga je izgledna mogućnost korištenja CDA-a u pronalaženju još uvijek nekatalogiziranih kratera Venere. Slika 110 prikazuje distribuciju kratera iz kataloga VE967 i VE345GT, kao i iz VE622 kataloga koji se dobiva izuzimanjem svih kratera iz VE967 kataloga koji se nalaze u VE345GT katalogu (krateri detektirani CDA-om ovoga rada). Najveći krater iz VE345GT kataloga velik je 270 km u dijametru (Mead krater), a najmanji 7.6 km u dijametru (Oma krater). Horizontalna rezolucija 1/32° topografske slike je ~3.3 km po slikovnom elementu, što objašnjava nemogućnost detekcije manjih kratera iz ovih topografskih slika.



Slika 109. Detekcija kratera na Veneri, Stanton krater (gore lijevo) i Isabella krater (dolje desno).

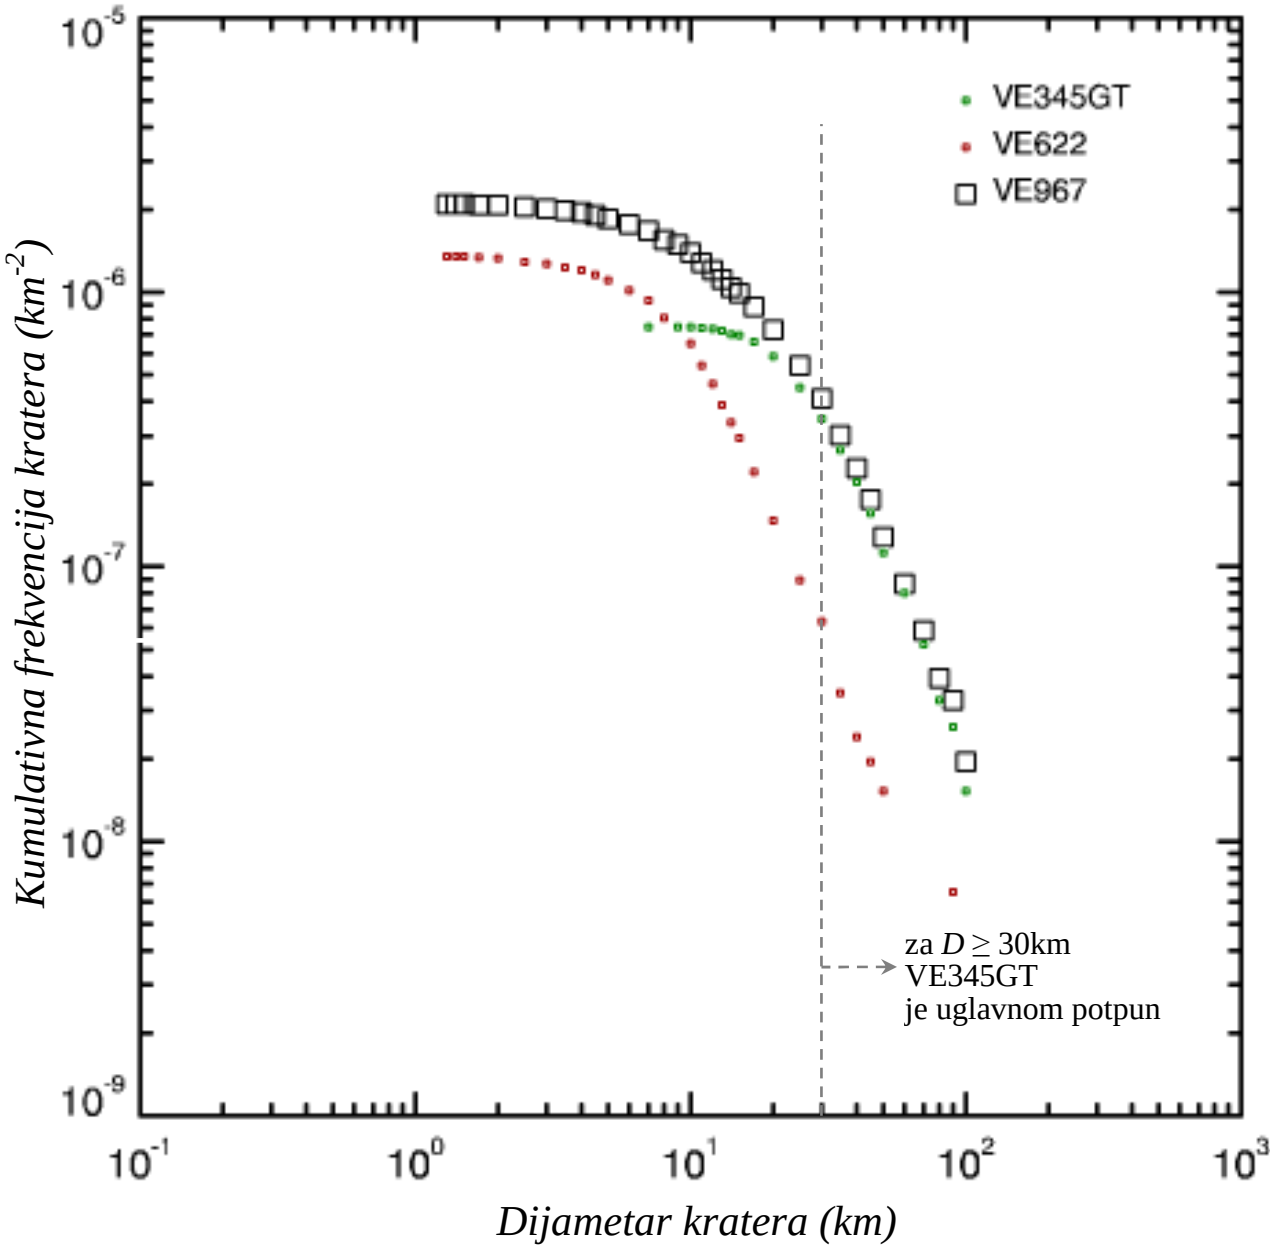


VE345GT	0	0	0	0	0	1	4	30	73	96	70	39	20	10	2
VE622	2	10	23	35	75	105	130	123	70	29	12	5	0	1	2
VE967	2	10	23	35	75	106	134	153	143	125	82	44	20	11	4

Slika 110. Glavni graf prikazuje distribuciju kratera iz VE345GT, VE622 i VE967 kataloga, gdje je $\log_{10}$ broja kratera dan za različite veličine dijametra. Manji graf prikazuje distribuciju kratera iz prethodnog VE967 kataloga, s obzirom na to je li iste pronašao i interpolacijski CDA ovoga rada.

U sljedećom koraku procijenjena je potpunost VE345GT kataloga te je taj katalog uspoređen s VE622 i VE967 katalozima, također korištenjem programa Craterstats (Michael, 2010). Slika 111 prikazuje potpunost VE345GT kataloga za kratere veće od 30 km u dijametru, što je područje uspješne detekcije većine kratera iz VE967 kataloga. Za kratere od 30 km do otprilike 16 km u dijametru podjednaki je broj onih detektiranih i onih kratera koji se ne mogu detektirati interpolacijskim CDA-om. Još manji krateri većinom nisu detektirani, što je prije svega posljedica

limita horizontalne rezolucije 1/32° i visoke razine šuma u slikama. Stoga su krivulje na sljedećoj slici unutar očekivanja. CDA je detektirao skoro sve najveće kratere, pa se krivulje VE345GT i VE967 gotovo u potpunosti podudaraju. Te iste krivulje se počinju razilaziti kada horizontalna rezolucija i prisutni šum CDA-u postaju problem za uspješnu detekciju sve manjih i manjih kratera.



Slika 111. Procjena potpunosti VE345GT kataloga. Graf prikazuje potpunost kataloga za kratere veće od 30 km u dijametru.

Mogućnost strojne detekcije kratera Venere iz njezinih topografskih slika stoga je zasigurno jedno od potencijalno zanimljivih budućih istraživanja. S obzirom na to da topografske slike imaju ograničenu horizontalnu rezoluciju i poprilićnu količinu šuma, ova istraživanja bilo bi dobro provesti u kombinaciji s CDA-om koji obrađuje optičke slike.

9.8. Strojna detekcija kratera Zemlje

Osnovna razlika Zemlje u usporedbi s Marsom, Mjesecom i Fobosom, kao i u slučaju Venere, je njezina daleko gušća atmosfera, geološki značajno aktivnija površina, što rezultira daleko manjim brojem kratera. Dodatna razlika u odnosu na Veneru je još veći utjecaj aktivnih geoloških procesa (kao što su tektonski pomaci kontinentalnih ploča) na brisanje odnosno eroziju kratera, stoga ih je još manje sačuvanih nego na Veneri. Kako bi se ispitala mogućnost korištenja CDA-ova ovoga rada za detekciju kratera Zemlje, napravljeni su prvi koraci i u tom smjeru. Cilj je i ovdje pronalaženje još nekatalogiziranih kratera s obzirom na njihov ukupan mali broj.

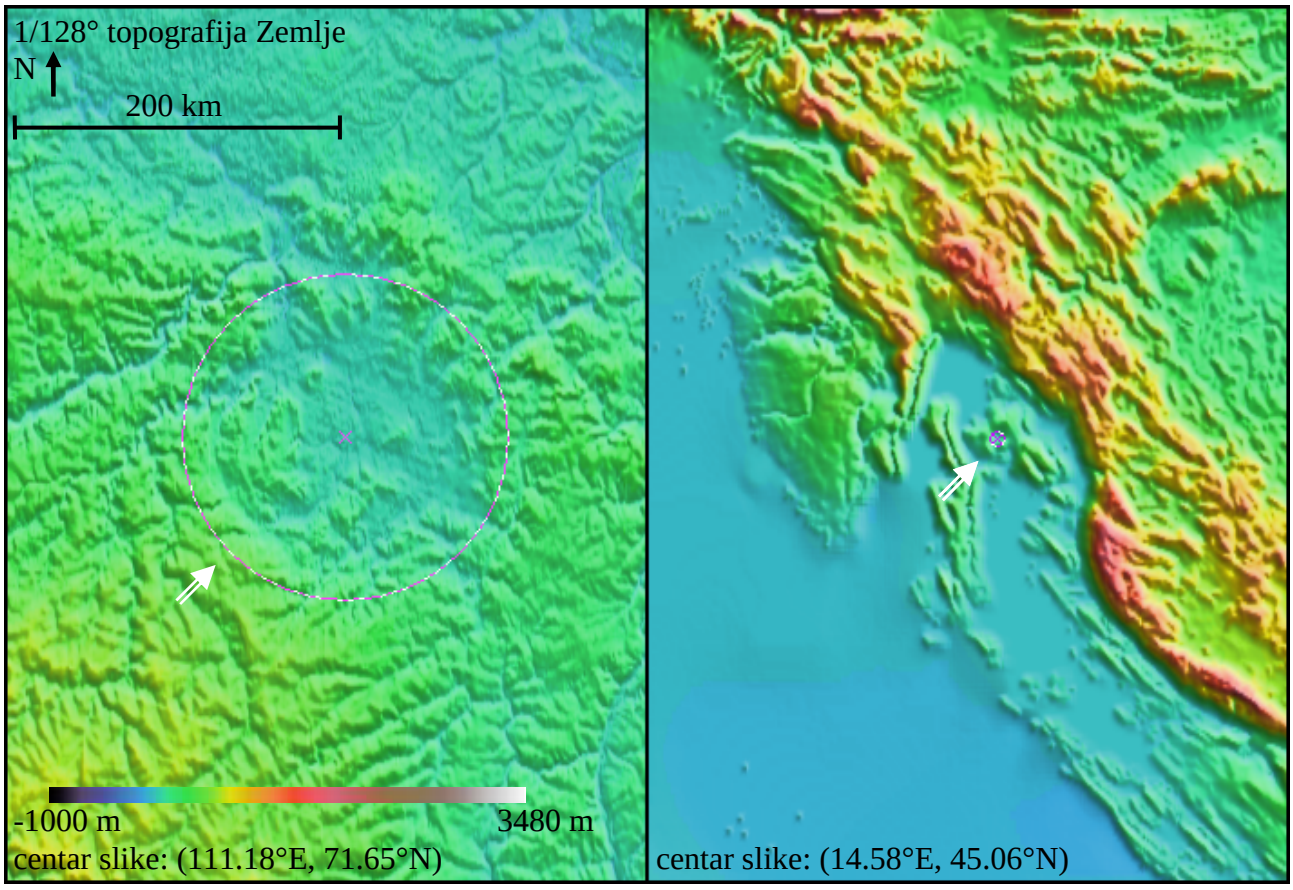
Globalne topografske slike Zemlje dostupne su u višoj horizontalnoj rezoluciji od dostupnih za sva ostala lunarna i planetarna tijela obrađena u ovome radu. Kao i u slučaju Marsa, Mjeseca i Fobosa, za provjeru kandidata za kratere potrebni su globalni optički mozaici u još višoj horizontalnoj rezoluciji od one topografskih slika korištenih za obradu. Stoga također nije bilo moguće provjeriti ni većinu od 178 kratera iz dostupnog kataloga, to jest odrediti jesu li oni točni ili pogrešni zapisi, kako je prethodno napravljeno za kataloge drugih planetarnih tijela. U ovom poglavlju korištene su ACE2 (*Altimeter Corrected Elevations)* topografske slike u horizontalnoj rezoluciji od 30 minuta, što je 1/120°, uzorkovane u standardnu horizontalnu rezoluciju od 1/128°, koja se primarno koristila i za detekciju kratera Marsa i Mjeseca (za Fobos su dostupne topografske slike samo do horizontalne rezolucije 1/4°, a za Veneru do 1/32°).

Neki od mogućih budućih koraka svakako uključuju i korištenje globalnih optičkih mozaika za Zemlju, u višoj horizontalnoj rezoluciji od dostupnih topografskih, kako bi se revidirao postojeći katalog te konstruirao prvi referentni katalog za Zemlju. Jedan od budućih koraka bi mogao biti i obrada topografskih podataka u horizontalnoj rezoluciji od 3 minute (1/1200°).

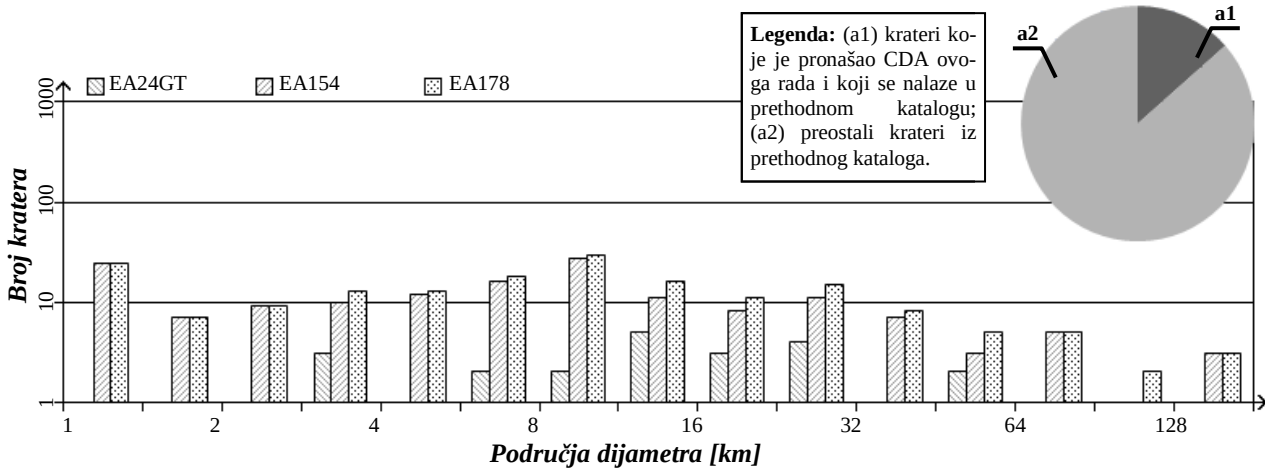
Kako bi se preliminarno mogla ispitati mogućnost korištenja CDA-ova ovoga rada za detekciju kratera Zemlje, interpolacijskim CDA-om (zbog istih razloga kao i za Veneru) obradile su se topografske slike Zemlje. Rezultat se usporedio s kraterima iz dostupnog kataloga EA178 (Planetary and Space Science Centre, 2011). Analizom se potvrdila uspješna detekcija 24 kratera: Popigai, Charlevoix, Kara-Kul, Clearwater West, Mistastin, Clearwater East, Ries, Lappajärvi, Logancha, Dellen, El'gygytgyn, Jänisjärvi, Gweni-Fada, Deep Bay, Serra da Cangalha, Vargeão Dome, Bosumtwi, Vista Alegre, Wanapitei, Middlesboro, Goat Paddock, Steinheim, Brent i Ouarkziz. Navedeno je rezultiralo EA24GT katalogom. Slika 112 (lijevo) prikazuje Popigai krater koji se nalazi u EA178 katalogu i ujedno je i najveći krater koji je CDA uspješno detektirao, velik 100 km u dijametru. Najmanji krater koji je CDA detektirao je Ouarkziz krater, velik svega 3.5 km u dijametru. Horizontalna rezolucija 1/128° topografske slike je ~868.7 m po slikovnom elementu, pa se manji krateri ne mogu detektirati. Postoji stoga manji dio kratera iz referentnog kataloga koje je CDA uspio detektirati, a koji su prvenstveno oni najveći krateri iz kataloga, gdje je horizontalna rezolucija topografskih slika bila dostatna za detekciju. Stoga je izgledna mogućnost korištenja CDA-a u pronalaženju još uvijek nekatalogiziranih kratera Zemlje. Slika 112 (desno) prikazuje primjer detekcije CDA-a koja se ne nalazi u EA178 katalogu, no za koju su prethodna istraživanja postavila hipotezu da se također radi o krateru (Marjanac et al., 2003). Uvidom u drugi dostupni javni katalog, koji uz potvrđene detekcije sadrži i one koje još uvijek nisu službeno potvrđene (Rajmon, 2011), detekcija ima status da se vjerojatno radi o krateru. Analiza i preostalih potencijalnih kratera iz Rajmonovog (2011) kataloga, kao i onih koje je detektirao CDA s većim pridijeljenim vjerojatnostima da se zaista radi o kraterima, svakako je jedna od mogućih tema za buduća istraživanja.

Kao i u prethodnom slučaju za Veneru, analizirala se distribucija kratera iz EA178 i EA24GT kataloga, kao i EA154 kataloga koji sadrži sve one kratere iz EA178 kataloga, koje CDA nije uspio detektirati. Slika 113 prikazuje rezultate. Za razliku od Venere, može se primijetiti nedetektiranost i

većine najvećih kratera. To međutim nije posljedica lošijih svojstava CDA-a ovoga rada za topografske slike Zemlje. Na Zemlji je naime potvrđeno dosta kratera i drugim mjerenjima (primjerice gravimetrije), koji uopće nisu vidljivi na topografskim slikama.



Slika 112. Detekcija kratera na Zemlji, Popigai krater (lijevo) i potencijalni krater na Krku (desno).

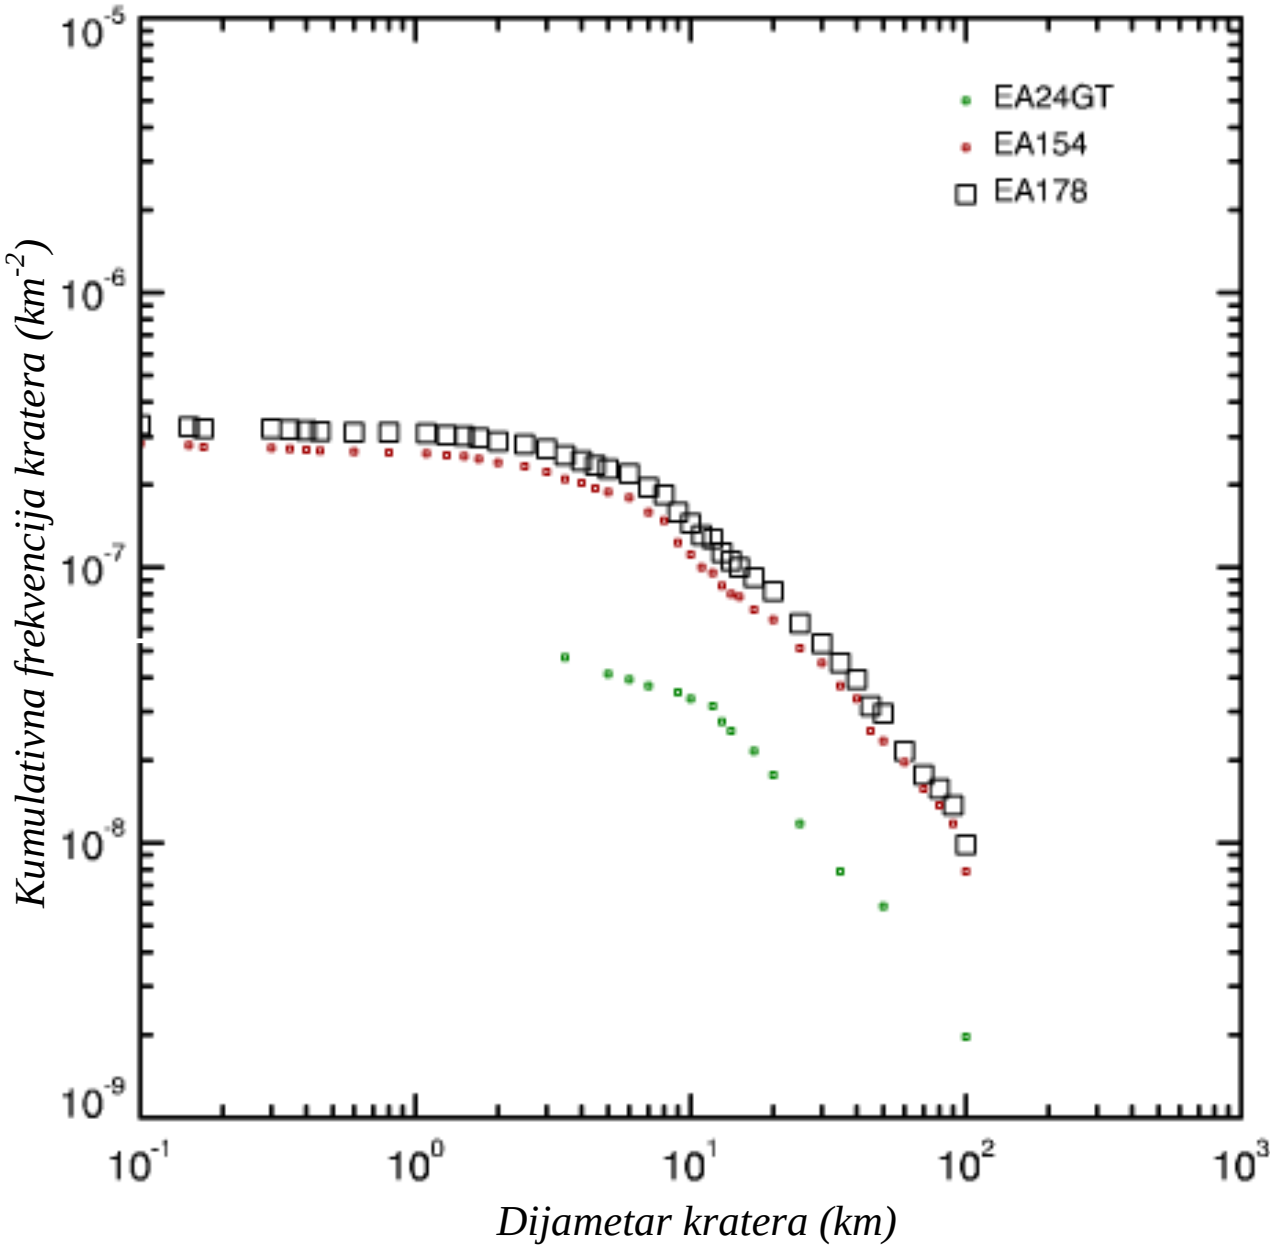


EA24GT	0	0	0	3	1	2	2	5	3	4	1	2	0	1	0
EA154	24	7	9	10	12	16	27	11	8	11	7	3	5	1	3
EA178	24	7	9	13	13	18	29	16	11	15	8	5	5	2	3

Slika 113. Glavni graf prikazuje distribucija kratera iz EA24GT, EA154 i EA178 kataloga, gdje je $\log_{10}$ broja kratera dan za različite veličine dijametra. Manji graf prikazuje distribuciju kratera iz prethodnog EA178 kataloga, s obzirom na to je li iste pronašao i interpolacijski CDA ovoga rada.

U sljedećom koraku procijenjena je potpunost EA24GT kataloga te je isti uspoređen s EA154 i EA178 katalozima, također korištenjem programa Craterstats (Michael, 2010). Slika 114 potvrđuje

prethodnu analizu: broj kratera koji se može detektirati iz topografskih slika samo je jedan manji dio od ukupne populacije.



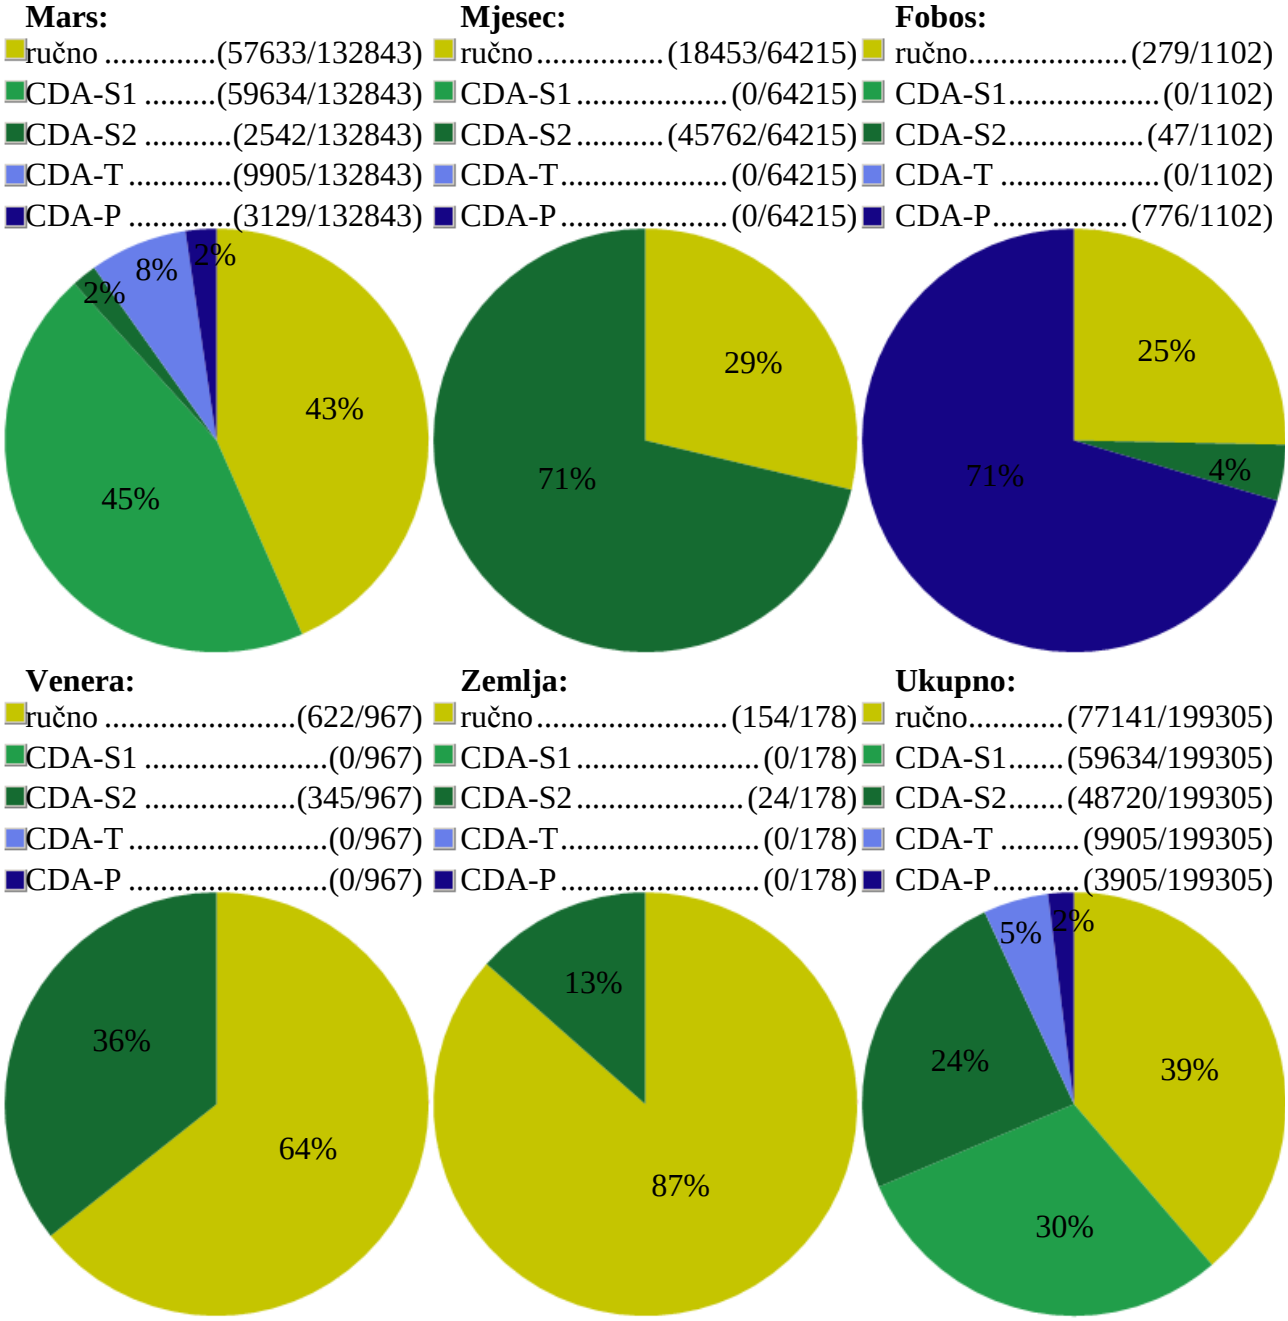
Slika 114. Analiza EA24GT kataloga; broj kratera je premalen za procjenu potpunosti, a razlog je velik broj kratera koji nisu vidljivi na topografskim slikama.

Uspješne detekcije pokazuju nam zanimljivost teme strojne detekcije kratera Zemlje iz njezinih topografskih slika za buduća istraživanja. Posebna prednost u odnosu na detekcije kratera na ostalim lunarnim i planetarnim tijelima je mogućnost proučavanja kandidata za kratere geološkim istraživanjima na samom terenu. Time se potencijalno može ili potvrditi ili opovrgnuti status kratera svakog kandidata za krater. Ova istraživanja su važna i za buduće procjene opasnosti udara objekata koji su putanjom bliski Zemlji, odnosno čija putanja presijeca Zemljinu putanju.

9.9. Ukupni doprinos metoda za detekciju u katalogizaciji kratera

Cilj ovoga rada, uz razvoj same metode za detekciju kratera (temeljne, temeljene na interpolaciji, temeljene na strojnom učenju), izrada je što potpunijih kataloga kratera što većeg broja lunarnih i planetarnih tijela. Pritom se najviše kratera katalogiziralo u slučaju Marsa i Mjeseca.

Slika 115 prikazuje doprinose korištenih metoda za detekciju. Doprinosi CDA-ova veći su od doprinosa svih prethodno ručno katalogiziranih kratera. Također, doprinosi CDA-ova ovoga rada (~54%) veći su od sveukupnog doprinosa prethodnih kataloga i CDA-ova drugih autora (~46%). Time je pokazana značajna primjenjivost rezultata ovoga rada.



Slika 115. Doprinosi prethodnih kataloga i CDA-ova u katalogizaciji kratera: (1) ručna katalogizacija; (2) CDA-S1 – temeljni CDA ovoga rada; (3) CDA-S2 – interpolacijski CDA ovoga rada; (4) CDA-T – Stepinskog i Urbacha (2008); i (5) CDA-P – Bandeire et al. (2007b).

10. ZAKLJUČAK

Izvorni znanstveni doprinos ovoga rada je prije svega nova metoda za detekciju kratera iz topografskih slika. Metoda je razvijena kroz tri koraka gdje je svaki rezultirao i zasebnom metodom korištenom prilikom izrade sve potpunijih kataloga kratera Marsa, Mjeseca, Fobosa, Venere i Zemlje. Nova metoda sastoji se od sljedećih modula:

- Modul 1: Detekcija ruba i analiza gradijenta;
- Modul 2: Izmijenjena Houghova transformacija;
- Modul 3: Analiza morfometrije i parametarskog prostora (konstrukcija topografskog-poprečnog-profila; određivanje odnosa dubine i dijametra; mjerenje cirkularnosti u topografskom području; mjerenje cirkularnosti u parametarskom području; detekcija i mjerenje ruba kratera; detekcija i mjerenje centralnog uzvišenja kratera; određivanja područja očuvanosti kratera);
- Modul 4: Adaptivna korekcija vjerojatnosti;
- Modul 5: Podešavanje kandidata za kratere pomicanjem;
- Modul 6: Interpolacija prilagođena obliku kratera;
- Modul 7: Adaptivne korekcije s obzirom na radijus planetarnog tijela;
- Modul 8: Učenje strojem s potpornim vektorima (učenje o oblicima kratera; učenje o geološkom kontekstu kao dodatak učenju o kraterima; dohvat značajki strojnog učenja; metoda strojnog učenja temeljena na stroju s potpornim vektorima; integracija rezultata strojnog učenja).

Sveobuhvatni izvorni doprinos ovoga rada s metodama za detekciju kratera i popratnim istraživanjima je sljedeći:

(1) okolina (metode s pripadajućim podacima) za razvoj i osnovno vrednovanje algoritama za detekciju kratera, kojima se obuhvaća (Salamunićcar i Lončarić, 2008d): (1a) definicija mjere udaljenosti između kratera u LLR prostoru; (1b) metoda za automatsku registraciju kataloga koji je rezultat CDA-ova i kratera iz referentnog kataloga; (1c) površina ispod F-ROC krivulje kao mjera CDA kvalitete; (1d) MA17582GT referentni katalog; (1e) globalne 1/64° topografske slike Marsa;

(2) referentni katalog za vrednovanje CDA-ova (Salamunićcar i Lončarić, 2008e) te pripadajuće metode i podaci koji osiguravaju sve potrebno za objektivno vrednovanje algoritama za detekciju kratera, kojima se obuhvaća: (2a) MA57633GT referentni katalog kao proširenje prethodnog, MA17582GT kataloga; (2b) metoda za integraciju kratera iz različitih kataloga; (2c) metoda za provjeru konzistentnosti kataloga;

(3) temeljna metoda za detekciju kratera (Salamunićcar i Lončarić, 2010b): (3a) pokazala je daleko bolje karakteristike detekcije od ostalih publiciranih metoda (kako je pokazano korištenjem MA17582GT i MA57633GT kataloga te F-ROC vrednovanjem do f_m<0.5); (3b) može se koristiti za automatska morfometrijska mjerenja značajki kratera; (3c) prethodni referentni katalog MA57633GT značajno je proširila s 57 592 prethodno nekatalogiziranih kratera, što je rezultiralo najpotpunijim (u vremenu publikacije) katalogom kratera Marsa, MA115225GT;

(4) metodologija za napredno vrednovanje algoritama za detekciju kratera (Salamunićcar et al., 2011a): (4a) metoda za registraciju kratera između kataloga koja je temeljena na kontekstu; (4b) napredna metoda za provjeru i registraciju kratera u kataloge; (4c) raznolikost podržanih mjera za vrednovanje; (4d) postupak usporedbe algoritama za detekciju kratera iz topografskih

i optičkih slika; (4e) razvoj novog, najpotpunijeg (u vremenu publikacije) referentnog MA130301GT kataloga (proširenje prethodnog kataloga MA115225GT) Marsa;

(5) metoda za detekciju kratera (zasnovana na temeljnoj metodi) koja koristi posebno razvijenu interpolaciju, temeljenu na uobičajenom obliku kratera (Salamunićcar et al., 2011f): (5a) pokazala je još bolja svojstva detekcije od temeljne metode (kako je pokazano korištenjem MA57633GT i MA132843GT kataloga za f_m<0.5 i f_m<3 te korištenjem i F-ROC i A-ROC vrednovanja); (5b) može se koristiti za topografske slike i Marsa i Mjeseca; (5c) referentni katalog Marsa značajno je proširila s 2542 prethodno nekatalogiziranih kratera (koje nije uspio detektirati temeljni CDA), što je rezultiralo novim, najpotpunijim (u vremenu publikacije) katalogom kratera Marsa, MA132843GT; (5d) referentni katalog Mjeseca značajno je proširila sa 42 192 kratera, što je rezultiralo novim, najpotpunijim katalogom kratera Mjeseca, LU60645GT;

(6) metoda za detekciju kratera (zasnovana na interpolacijskoj metodi) koja koristi strojno učenje strojem s potpornim vektorima (Salamunićcar i Lončarić, 2010d): (6a) pokazala je još bolja svojstva detekcije te je u cijelom području bolja od Stepinskovog i Urbachovog (2008) CDA-a (kako je pokazano korištenjem MA57633GT, MA132843GT i LU60645GT kataloga za f_m<0.5 i f_m<3 te korištenjem i F-ROC i A-ROC i Q vrednovanja); (6b) smanjila je broj pogrešnih detekcija, dok su ostala dobra svojstva sačuvana.

Očekuje se velika mogućnost primjene navedenih rezultata u budućim znanstvenim istraživanjima, što je u suradnji s drugim autorima pokazano eksperimentalnim putem za:

(1) detekciju kratera Fobosa, što je uz kombinaciju s metodom drugih autora za detekciju kratera iz optičkih slika rezultiralo prvim katalogom kratera Fobosa, PH504GT (Salamunićcar et al., 2011c), te daljnjim razvojem i još potpunijim katalogom kratera Fobosa, PH1102GT (Salamunićcar et al., 2011d);

(2) analizu laboratorijskih kratera formalnom metodom koja uključuje: 3D-skeniranje laboratorijskih kratera, umetanje 3D-podataka u topografske slike Marsa i Mjeseca, vrednovanje korištenjem metoda za detekciju kratera ovoga rada (provjera detekcije laboratorijskih kratera i pridijeljenih vjerojatnosti) te za prikaz njihovih topografskih profila s ciljem usporedbe s profilima kratera Marsa i Mjeseca (Vojković et al., 2010a, 2010b; Salamunićcar et al., 2010b; Vinković et al., 2011);

(3) detekciju kratera iz optičkih slika, kao rezultat korištenja metode za rekonstrukciju topografskih slika iz optičkih, s ciljem korištenja metoda ovoga rada za detekcije kratera iz optičkih slika i vrednovanje metoda koje rekonstruiraju topografske slike iz optičkih (Lončarić et al., 2011), gdje je rezultat još potpuniji katalog kratera Mjeseca LU64215GT (Salamunićcar et al., 2011e);

(4) detekciju kratera iz topografskih slika Venere, s 345 uspješno detektiranih kratera;

(5) detekciju kratera iz topografskih slika Zemlje, s 24 uspješno detektiranih kratera.

Moguća buduća istraživanja vezana su i za nove metode koje će detektirati kratere direktno iz optičkih slika, koristeći metode za topografske slike, razvijene u ovome radu (Salamunićcar i Lončarić, 2010a). Također se novi katalozi kratera, rezultat ovoga rada, mogu koristiti za daljnja statistička istraživanja procesa na lunarnim i planetarnim tijelima (Salamunićcar et al., 2010a).

Izvorni doprinos ovoga rada stoga je značajan znanstveni doprinos u području detekcije kratera iz topografskih slika, gdje su nove metode ovoga rada u suradnji s drugim znanstvenicima već uspješno korištene u brojne svrhe.

11. POPIS LITERATURE

[1] I. E. Abdou, "Quantitative methods of edge detection.", Image Processing Institute, University of Southern California, USCIPI Technical Report 830, Los Angeles, USA, July 1978, pp. 95.

[2] A. S. Alekseev, V. P. Pyatkin, G. I. Salov, "Crater detection in aero-space imagery using simple nonparametric statistical tests.", *Lecture Notes in Computer Science (5th International Conference on Computer Analysis of Images and Patterns, CAIP 1993, Budapest, Hungary, September 1993)*, Springer-Verlag GmbH, Berlin / Heidelberg, Germany, 1993, vol. 719 pp. 793-799, doi:10.1007/3-540-57233-3_110.

[3] E. I. Alves, "A New Crater Recognition Method and its Application to Images of Mars. (Abstract)", *Geophysical Research Abstracts*, Copernicus GmbH, Katlenburg-Lindau, Germany, 2003, vol. 5 no. 08974 pp. 1-1.

[4] L.A. Andersson, E.A. Whitaker, "NASA catalogue of Lunar nomenclature.", NASA Reference Publication 1097, USA, 1982.

[5] H. Araki, S. Tazawa, H. Noda, Y. Ishihara, S. Goossens, S. Sasaki, N. Kawano, I. Kamiya, H. Otake, J. Oberst, C. Shum, "Lunar Global Shape and Polar Topography Derived from Kaguya-LALT Laser Altimetry.", *Science*, February 2009, vol. 323 num. 5916 pp. 897-900, doi: 10.1126/science.1164146.

[6] E. Argyle, "Techniques for Edge Detection.", *Proc. IEEE*, IEEE, February 1971, vol. 59 pp. 285-286.

[7] N. Asada, N. Harada, N. Hirata, H. Demura, J. Haruyama, M. Ohtake, T. Matsunaga, Y. Yokota, T. Morota, C. Honda, Y. Ogawa, M. Torii, "Recognition tool of craters and linear features on Digital Terrain Model derived from LISM/TC, Kaguya.", *39th Annual Lunar and Planetary Science Conference – 39thLPSC*, NASA LPI, Houston, USA, March 2008a, no. 2431 pp. 1-2.

[8] N. Asada, N. Harada, N. Hirata, H. Demura, J. Haruyama, M. Ohtake, T. Matsunaga, Y. Yokota, T. Morota, C. Honda, Y. Ogawa, "Craters Recognition Tool on Digital Terrain Model from LISM/TC, KAGUYA. (Abstract)", Japan, 2008b, pp. 1-1, "http://wwwsoc.nii.ac.jp/jepsjmo/cd-rom/2008cd-rom/program/pdf/P221/P221-P022_e.pdf".

[9] L. P. C. Bandeira, J. Saraiva, P. Pina, "Enhancing impact crater contours to increase recognition rates.", *International Conference on Computer Vision Theory and Applications*, Setúbal, Portugal, February 2006a, pp. 407-412.

[10] L. P. C. Bandeira, J. Saraiva, P. Pina, "Automated crater recognition: one goal, many paths.", *1st International Conference on Impact Cratering in the Solar System*, ESA, Noordwijk, Netherlands, May 2006b, no. 295644 pp. 1-1.

[11] L. Bandeira, J. Saraiva, P. Pina, "Development of a Methodology for Automated Crater Detection on Planetary Images.", *Lecture Notes in Computer Science (Pattern Recognition and Image Analysis, Third Iberian Conference, IbPRIA 2007, Girona, Spain, June 2007)*, Springer-Verlag GmbH, Berlin / Heidelberg, Germany, July 2007a, vol. 4477 pp. 193-200.

[12] L. Bandeira, J. Saraiva, P. Pina, "Impact Crater Recognition on Mars Based on a Probability Volume Created by Template Matching.", *Transactions on Geoscience and Remote Sensing*, IEEE, December 2007b, vol. 45 num. 12 pp. 4008-4015, doi:10.1109/TGRS.2007.904948.

[13] L. Bandeira, C. Barreira, P. Pina, J. Saraiva, "A comparison of automated crater detection methods.", *3rd European Planetary Science Congress*, Münster, Germany, September 2008a, pp. 1-2, "http://cerena.ist.utl.pt/lpcbandeira/docs/EPSC2008/EPSC2008-A-00294-1.pdf".

[14] L. Bandeira, C. Barreira, P. Pina, J. Saraiva, "Crater mapping in the Gusev crater area using an automated method.", *3rd European Planetary Science Congress*, Münster, Germany, September 2008b, pp. 1-2, "http://cerena.ist.utl.pt/lpcbandeira/docs/EPSC2008/EPSC2008-A-00360-1.pdf".

[15] L. Bandeira, W. Ding, T. F. Stepinski, "Automatic Detection of Sub-km Craters Using Shape and Texture Information.", *41st Annual Lunar and Planetary Science Conference – 41stLPSC*, NASA LPI, Houston, USA, March 2010a, no. 1144 pp. 1-2.

[16] L. Bandeira, J. S. Marques, J. Saraiva, P. Pina, "Automated Detection of Sand Dunes on Mars.", *Lecture Notes in Computer Science (7th International Conference on Image Analysis and Recognition, ICIAR 2010, Povoa de Varzim, Portugal, June 2010)*, Springer-Verlag GmbH, Berlin / Heidelberg, Germany, 2010b, vol. 6112 pp. 306-315, doi:10.1007/978-3-642-13775-4_31.

[17] T. Barata, E. I. Alves, J. Saraiva, P. Pina, "Automatic Recognition of Impact Craters on the Surface of Mars.", *Lecture Notes in Computer Science (International Conference on Image Analysis and Recognition – ICIAR 2004, Porto, Portugal, September 29 - October 1, 2004, Proceedings, Part II)*, Springer-Verlag GmbH, Berlin / Heidelberg, Germany, 2004, vol. 3212 pp. 489-496.

[18] M. T. Barata, P. Pina, J. Saraiva, E. I. Alves, "Extraction of Craters and Ejecta from Venus SAR Imagery.", *41st Annual Lunar and Planetary Science Conference – 41stLPSC*, NASA LPI, Houston, USA, March 2010, no. 1412 pp. 1-2.

[19] N. G. Barlow, C. W. Barnes, O. S. Barnouin-Jha, J. M. Boyce, C. R. Chapman, F. M. Costard, R. A. Craddock, J. B. Garvin, R. Greeley, T. M. Hare, R. O. Kuzmin, P. J. Mouginis-Mark, H. E. Newsom, S. E. H. Sakimoto, S. T. Stewart, L. A. Soderblom, "Utilizing GIS in Martian Impact Crater Studies.", *ISPRS WG IV/9 Extraterrestrial Mapping Workshop: Advances in Planetary Mapping 2003*, Houston, USA, March 2003, pp. 1-5.

[20] M. Barni, A. Mecocci, L. Perugini, "Craters detection via possibilistic shell clustering.", *International Conference on Image Processing*, Vancouver, Canada, 2000, vol. 2 pp. 720-723.

[21] A. W. Bauer, T. F. Stepinski, "Machine Cataloging of Lunar Craters from Digital Terrain Model.", *42nd Annual Lunar and Planetary Science Conference – 42ndLPSC*, NASA LPI, Houston, USA, March 2011, no. 1292 pp. 1-2.

[22] E. B. Bierhaus, W. J. Merline, C. R. Chapman, M. C. Burl, "Characterization of Secondary Craters Using Machine Vision.", *Proc. 6th Int. Symp. on Artificial Intelligence, Robotics, and Automation in Space*, Montreal, Canada, June 2001, no. AM114 pp. 1-7.

[23] A. Bijaoui, M. M. Froeschle, "A new algorithm to determine image edges - Application to lunar craters.", *Astronomy and Astrophysics*, Springer-Verlag GmbH, Germany, July 1980, vol. 87 num. 1-2 pp. 250-251.

[24] T. Blu, P.-L. Dragotti, M. Vetterli, P. Marziliano, L. Coulot, "Sparse Sampling of Signal Innovations.", *Signal Processing Magazine*, IEEE, New York, USA, March 2008, vol. 25 num. 2 pp. 31-40, doi:10.1109/MSP.2007.914998.

[25] J. M. Boyce, P. Mouginis-Mark, H. Garbeil, "Ancient oceans in the northern lowlands of Mars: Evidence from impact crater depth/diameter relationships.", *Journal of Geophysical Research - Planets*, AGU, USA, March 2005, vol. 110 num. E03008 pp. 1-15, doi:10.1029/2004JE002328.

[26] S. P. Brumby, C. S. Plesko, E. Asphaug, "Evolving automated feature extraction algorithms for planetary science.", *ISPRS WG IV/9: Extraterrestrial Mapping Workshop - Advances in Planetary Mapping 2003*, Houston, Texas, USA, March 2003, pp. 1-2.

[27] L. Bruzzone, L. Lizzi, P. G. Marchetti, J. Earl, M. Milnes, "Recognition and Detection of Impact Craters from EO Products.", *Proceedings of ESA-EUSC 2004 - Theory and Applications of Knowledge-Driven Image Information Mining with Focus on Earth Observation (ESA SP-553)*, Madrid, Spain, March 2004, no. 13B pp. 1-8.

[28] B. D. Bue, T. F. Stepinski, "Machine Detection of Martian Craters from Digital Topography.", *37th Annual Lunar and Planetary Science Conference – 37thLPSC*, NASA LPI, Houston, USA, March 2006, no. 1178 pp. 1-2.

[29] B. D. Bue, T. F. Stepinski, "Machine Detection of Martian Impact Craters From Digital Topography Data.", *Transactions on Geoscience and Remote Sensing*, IEEE, January 2007, vol. 45 num. 1 pp. 265-274, doi:10.1109/TGRS.2006.885402.

[30] M. C. Burl, L. Asker, P. Smyth, U. Fayyad, P. Perona, J. Aubele, L. Crumpler, "Learning to Recognize Volcanoes on Venus.", *Machine Learning*, Kluwer Academic Publishers, Boston, USA, April 1998, vol. 30, num. 2-3, pp. 165-195.

[31] M. C. Burl, C. Fowlkes, J. Roden, A. Stechert, S. Mukhtar, "Diamond Eye: A Distributed Architecture for Image Data Mining.", *SPIE AeroSense Conference on Data Mining and Knowledge Discovery*, Orlando, Florida, USA, April 1999, pp. 1-10.

[32] M. C. Burl, T. Stough, W. Colwell, E. B. Bierhaus, W. J. Merline, C. R. Chapman, "Automated Detection of Craters and Other Geological Features.", *Proc. 6th Int. Symposium on Artificial Intelligence, Robotics, and Automation in Space*, Montreal, Canada, June 2001, no. AM118 pp. 1-18.

[33] J. F. Canny, "A computational approach to edge detection.", *IEEE Transactions on Pattern Analysis and Machine Intelligence (IEEE PAMI)*, IEEE, November 1986, vol. 8 num. 6 pp. 679-698.

[34] Y. Cheng, A. E. Johnson, L. H. Matthies, C. F. Olson, "Optical Landmark Detection for Spacecraft Navigation. (Abstract)", *13th AAS/AIAA Space Flight Mechanics Meeting*, Ponce, Puerto Rico, February 2003, pp. 1-1.

[35] Y. Cheng, J. Goguen, A. Johnson, C. Leger, L. Matthies, M. San Martin, R. Willson, "The Mars Exploration Rovers Descent Image Motion Estimation System.", *IEEE Intelligent Systems*, IEEE, May-June 2004, vol. 19 num. 3 pp. 13-21, doi:10.1109/MIS.2004.18.

[36] Y. Cheng, A. Johnson, L. Matthies, "MER-DIMES: A Planetary Landing Application of Computer Vision.", *IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2005)*, San Diego, USA, June 2005, pp 1-8.

[37] Y. Cheng, A. Huertas, "Automatic Lunar Crater Detection and Mapping.", *1st Planetary Crater Consortium meeting*, US Geological Survey in Flagstaff-AZ, USA, September 2010, no. 1013 pp 1-2.

[38] A. Chicarro, G. Michael, P. G. Marchetti, M. Costantini, F. Di Stadio, M. Di Martino, "Unravelling the Earth's Geological History from Space using Impact Craters.", *ESA*

Bulletin, Netherlands, May 2003, num. 114 pp. 68-75, "http://earth.esa.int/rtd/Articles/Crater.pdf".

[39] M. J. Cintala, C. A. Wood, S. U. Grenander, M. E. Dibner-Dunlap, T. A. Mutch, J. W. Head, "Mercury Crater Analyses: An Automated Data Gathering and Handling System.", *Conference on Comparisons of Mercury and the Moon*, NASA LPI, Houston, USA, 1976, no. 262 pp. 5-5.

[40] S. Clerc, M. Spigai, V. Simard-Bilodeau, "A crater detection and identification algorithm for autonomous lunar landing.", *7th IFAC Symposium on Intelligent Autonomous Vehicles (2010) – IAV 2010*, Lecce, Italy, September 2010, pp. 1-6, doi:10.3182/20100906-3-IT-2019.00091.

[41] S. J. Conway, N. Mangold, V. Ansan, "Crater Shape Evolution with Latitude in Terra Cimmeria, Mars – Implications for Climate.", *42nd Annual Lunar and Planetary Science Conference – 42ndLPSC*, NASA LPI, Houston, USA, March 2011a, no. 2174 pp. 1-2.

[42] S. Conway, N. Mangold, "Observations and Modelling on Crater Shape Evolution with Latitude in Terra Cimmeria, Mars - Implications for Climate.", *European Geosciences Union General Assembly*, Vienna, Austria, April 2011b, no. 8692 pp. 1-1.

[43] S. Conway, N. Mangold, V. Ansan, "The Role of Gullies in Martian Impact Crater Degradation.", *EPSC-DPS Joint Meeting*, Nantes, France, October 2011c, no. 1168 pp. 1-2.

[44] G. R. J. Cooper, "Feature detection using sun shading.", *Computers & Geosciences*, Elsevier Science, Oxford, UK, October 2003, vol. 29 num. 8 pp. 941-948, doi:10.1016/S0098-3004 (03)00091-8.

[45] G. R. J. Cooper, D. R. Cowan, "The detection of circular features in irregularly spaced data.", *Computers & Geosciences*, Elsevier Science, Oxford, UK, February 2004, vol. 30 num. 1 pp. 101-105, doi:10.1016/j.cageo.2003.08.006.

[46] M. Costantini, F. Di Stadio, M. Zavagli, M. Di Martino, P. G. Marchetti, "Crater Recognition.", *International Geoscience and Remote Sensing Symposium IGARSS 2002*, Toronto, Canada, June 2002, pp. 1-1, "http://earth.esa.int/rtd/Articles/Crater_IGARSS2002_poster.pdf".

[47] M. Davis, "Scientific Papers and Presentations." 2nd Ed., *Academic Press (an imprint of Elsevier)*, New York, USA, 2005.

[48] R. A. Day, B. Gastel, "How to Write and Publish a Scientific Paper, 6th ed.", Greenwood Press, Westport - CT, USA, 2006.

[49] S. R. Deans, "Hough Transform from the Radon Transform.", *IEEE Transactions on Pattern Analysis and Machine Intelligence (IEEE PAMI)*, IEEE, March 1981, vol. 3 num. 2 pp. 185-188.

[50] M. Degirmenci, S. Ashyralyev, "Impact Crater Detection on Mars Digital Elevation and Image Model.", *International Conferences on Computer Graphics, Vision and Mathematics – GraVisMa*, Brno, Czech Republic, September 2010, pp. 131-138.

[51] F. Di Stadio, M. Costantini, M. Di Martino, "Craters – Executive Summary: Survey of Algorithms for Automatic Recognition of Impact Craters.", ESA Contract Report, Rome, Italy, July 2002, pp. 1-30, "http://www.esa.int/gsp/completed/ExecSumAll01_A19.pdf".

[52] W. Ding, T. F. Stepinski, L. Bandeira, R. Vilalta, Y. Wu, Z. Lu, T. Cao, "Automatic Detection of Craters in Planetary Images: An Embedded Framework Using Feature Selection and Boosting.", *19th ACM International Conference on Information and Knowledge Management – CIKM 2010*, Toronto, Canada, October 2010, pp. 1-10.

[53] W. Ding, T. F. Stepinski, Y. Mu, L. Bandeira, R. Ricardo, Y. Wu, Z. Lu, T. Cao, X. Wu, "Sub-Kilometer Crater Discovery with Boosting and Transfer Learning.", *Transactions on Intelligent Systems and Technology*, ACM, USA, July 2011, vol. 2 num. 4 pp. 1-22, doi:10.1145/1989734.1989743.

[54] R. O. Duda, P. E. Hart, "Use of the Hough Transformation To Detect Lines and Curves in Pictures.", *Communications*, ACM, January 1972, pp. 11 - 15.

[55] H. Dypvik, S. O. Krøgli, B. Etzelmüller, L. Sørbel, T. A. A. Thoresen, "The Hunt for Impact Structures in Norway.", *37th Annual Lunar and Planetary Science Conference – 37thLPSC*, NASA LPI, Houston, USA, March 2006, no. 1013 pp. 1-2.

[56] J. Earl, A. Chicarro, C. Koeberl, P. G. Marchetti, M. Milnes, "Automatic recognition of crater-like structures in satellite images of Earth and Mars. (Abstract)", *1st Mars Express Science Conference*, Noordwijk, Netherlands, February 2005a, pp. 234.

[57] J. Earl, A. F. Chicarro, C. Koeberl, P. G. Marchetti, M. Milnes, "Automatic Recognition of Crater-like Structures in Terrestrial and Planetary Images.", *36th Annual Lunar and Planetary Science Conference – 36thLPSC (presented also on: Workshop on the Role of Volatiles and Atmospheres on Martian Impact Craters, Laurel, USA, July 2005, no. 3053)*, NASA LPI, Houston, USA, March 2005b, no. 1319 pp. 1-2.

[58] J. Earl, A. Chicarro, C. Koeberl, P. G. Marchetti, M. Milnes, "Automatic recognition of crater-like structures in terrestrial images.", *3rd ESA CHRIS/Proba Workshop*, Frascati, Italy, March 2005c, pp. 1-1, "http://earth.esa.int/workshops/chris_proba_05/Session_3/02J.Earl_Session3.pdf".

[59] A. Flores-Méndez, "Crater Marking and Classification Using Computer Vision.", *Lecture Notes in Computer Science (Progress in Pattern Recognition, Speech and Image Analysis, 8th Iberoamerican Congress on Pattern Recognition – CIARP 2003, Havana, Cuba, November 26-29, 2003)*, Springer-Verlag GmbH, Berlin / Heidelberg, Germany, 2003, vol. 2905 pp. 79-86.

[60] A. Flores-Méndez, A. Suarez-Cervantes, "Circular Degree Hough Transform.", Lecture Notes in Computer Science (14th Iberoamerican Congress on Pattern Recognition, CIARP 2009, Guadalajara, Jalisco, México, 15-18 November 2009), Springer-Verlag GmbH, Berlin / Heidelberg, Germany, November 2009, vol. 5856 pp. 287-294, doi:10.1007/978-3-642-10268-4_34.

[61] W. Frei, C.-C. Chen, "Fast boundary detection: A generalization and a new algorithm.", *IEEE Transactions of Computers*, IEEE, October 1977, vol. C-26 num. 10 pp. 988-998.

[62] H. V. Frey, J. H. Roark, K. M. Shockey, E. L. Frey, S. E. H. Sakimoto, "Ancient lowlands on Mars", *Geophysical Research Letters*, AGU, USA, May 2002, vol. 29 no. 10 pp. 1-4, doi:10.1029/2001GL013832.

[63] C. Furlanello, S. Merler, S. Menegon, E. Paoli, S. Fontanari, "Mapping the Risk of Unexploded Bombs from World War Two. (Abstract)", Italy, 2003, pp. 1-2, "http://geomatica.como.polimi.it/workbooks2/n3/abstract/a_cfsmsmepsf.pdf".

[64] A. Grumpe, C. Wöhler, "A Photometric Approach to the Construction of Lunar Digital Elevation Maps Using Chandrayaan-1 M3 Imagery in Combination With Laser Altimetry Data.", *42nd Annual Lunar and Planetary Science Conference – 42ndLPSC*, NASA LPI, Houston, USA, March 2011, no. 1478 pp. 1-2.

[65] R. M. Hadad, A. de A. Araújo, P. P. Martins Jr., "Using the Hough Transform to Detect Circular Forms in Satellite Imagery.", *14th Brazilian Symposium on Computer Graphics and Image Processing – SIBGRAPI 2001*, Florianopolis, Brazil, October 2001, pp. 1-1.

[66] R. W. Hanks, "The Chicxulub Impact Site - Discovery and Effects: Modeling Impact.", February 2011 (datum pristupa: 22.02.2011.), "http://palaeo.gly.bris.ac.uk/communication/hanks/ind.html", "http://palaeo.gly.bris.ac.uk/communication/Hanks/eff.html#7", "http://palaeo.gly.bris.ac.uk/Communication/Hanks/Fig6.gif".

[67] N. Harada, T. Karino, N. Hirata, H. Demura, N. Asada, "Recognition Algorithm for Craters, Ridges, and Grabens.", *38th Annual Lunar and Planetary Science Conference – 38thLPSC*, NASA LPI, Houston, USA, March 2007a, no. 1451 pp. 1-2.

[68] N. Harada, T. Hayashi, N. Hirata, H. Demura, N. Asada, "Crater recognition technique that uses General Hough Transform.", *40th ISAS Lunar and Planetary Symposium*, Kanagawa, Japan, 2007b, pp. 1-4.

[69] N. Harada, N. Asada, H. Demura, N. Hirata, "Recognition algorithm for craters, ridges, and grabens. (Abstract)", Japan, 2007c, pp. 1-1, "http://wwwsoc.nii.ac.jp/jepsjmo/cd-rom/2007cd-rom/program/pdf/P224/P224-014_e.pdf".

[70] N. Harada, T. Hayashi, N. Hirata, H. Demura, N. Asada, "Recognition Algorithm for Topographic Features.", *7th IEEE International Conference on Computer and Information Technology*, Aizu-Wakamatsu City, Fukushima, Japan, October 2007d, pp. 685-689, doi:10.1109/CIT.2007.151.

[71] W. K. Hartmann, G. Neukum, "Cratering chronology and the evolution of Mars.", *Space Science Reviews*, Kluwer Academic Publisher, Netherlands, 2001, vol. 96 pp. 165-194.

[72] J. He, H. Cui, J. Feng, "Edge Information Based Crater Detection and Matching for Lunar Exploration.", *International Conference on Intelligent Control and Information Processing*, Dalian, China, August 2010, pp. 1-6.

[73] J. W. Head, C. I. Fassett, S. J. Kadish, D. E. Smith, M. T. Zuber, G. A. Neumann, E. Mazarico, "Global Distribution of Large Lunar Craters: Implications for Resurfacing and Impactor Populations.", *Science*, September 2010, vol. 329 num. 5998 pp. 1504-1507, doi: 10.1126/science.1195050.

[74] M. A. Hearst, S. T. Dumais, E. Osuna, J. Platt, B. Schölkopf, "Support vector machines.", IEEE Intelligent systems, July/August 1998, pp. 18-28.

[75] K. Homma, H. Yamamoto, T. Isobe, K. Matsushima, J. Ohkubo, "Massively Parallel Processing for Crater Recognition.", *28th Annual Lunar and Planetary Science Conference – 28thLPSC*, NASA LPI, Houston, USA, March 1997, p. 589 pp. 1-2.

[76] R. Honda, R. Azuma, "Crater extraction and classification system for lunar images.", *Mem. Fac. Sci. Kochi Univ. (Inform. Sci.)*, Kochi City, Japan, 2000, pp. 1-12.

[77] R. Honda, Y. Iijima, T. Kikuchi, O. Konishi, "Knowledge Discovery Support System for a Large-scale Satellite Image Data. (Abstract)", Japan, 2000a, pp. 1-2, "http://www.is.kochi-u.ac.jp/~honda/paper/ds00honda.pdf".

[78] R. Honda, O. Konishi, R. Azuma, H. Yokogawa, S. Yamanaka, Y. Iijima, "Data mining system for planetary images - crater detection and categorization.", *International Workshop on Machine Learning of Spatial Knowledge in conjunction with ICML*, Stanford, USA, July 2000b, pp. 103-108.

[79] R. Honda, Y. Iijima, O. Konishi, "Mining of topographic feature from heterogeneous imagery and its application to lunar craters.", *Progress of Discovery Science*, LNAI 2281, Springer Verlag, Berlin Heiderberg, Germany, 2002, pp. 395-407.

[80] B. K. P. Horn, "Height and gradient from shading.", *International Journal of Computer Vision*, Springer-Verlag GmbH, Berlin / Heidelberg, Germany, August 1990, vol. 5 num. 1 pp. 37-75, doi:10.1007/BF00056771.

[81] P. V. C. Hough, "Method and means for recognizing complex patterns.", *United States Patent and Trademark Office*, Alexandria, VA, USA, filed: 25th March 1960, patented: 18th December 1962, Pat. No. US3069654.

[82] H. Jahn, "Crater detection by linear filters representing the Hough Transform.", *ISPRS Commission III Symposium: Spatial Information from Digital Photogrammetry and Computer Vision*, SPIE, Munich, Germany, August 1994, vol. 2357 pp. 427-431.

[83] A. Johnson, R. Willson, J. Goguen, J. Alexander, D. Meller, "Field Testing of the Mars Exploration Rovers Descent Image Motion Estimation System.", *IEEE International Conference on Robotics and Automation (ICRA 2005)*, Barcelona, Spain, April 2005, pp. 1-7.

[84] S. J. Kadish, C. I. Fassett, J. W. Head, D. E. Smith, M. T. Zuber, G. A. Neumann, E. Mazarico, "A global catalog of large Lunar craters (≥20 km) from the Lunar Orbiter Laser Altimeter.", 42nd Annual Lunar and Planetary Science Conference – 42ndLPSC, NASA LPI, Houston, USA, March 2011, no. 1006 pp. 1-2.

[85] M. J. Katz, "From Research to Manuscript: A Guide to Scientific Writing." 2nd Ed., *Springer*, USA, 2009.

[86] W. S. Kiefer, "Lunar Impact Crater Geology and Structure.", February 2011 (datum pristupa: 25.02.2011.), "http://www.lpi.usra.edu/expmoon/science/craterstructure.html", "http://www.lpi.usra.edu/expmoon/science/craterstructure.gif".

[87] J. R. Kim, J.-P. Muller, J. G. Morley, K. L. Mitchell, "Automated Registration of MDIM with MOLA Tracks.", *32nd Annual Lunar and Planetary Science Conference – 32ndLPSC*, Houston, USA, March 2001, no. 2087 pp. 1-2.

[88] J. R. Kim, J-P. Muller, "Impact crater detection on optical images and DEMs.", *ISPRS WG IV/9: Extraterrestrial Mapping Workshop - Advances in Planetary Mapping 2003*, Houston, Texas, USA, March 2003, pp. 1-3.

[89] J. R. Kim, J.-P. Muller, J. G. Morley, "Quantitative Assessment of Automated Crater Detection on Mars.", *XXth ISPRS Congress*, Istanbul, Turkey, July 2004, pp. 816-821.

[90] J.-R. Kim, J.-P. Muller, J. G. Morley, S. van Gasselt, G. Neukum, the HRSC Col team, "Automatic crater detection and 3D reconstruction for Mars geochronology. (Abstract)", *1st Mars Express Science Conference*, Noordwijk, Netherlands, February 2005a, pp. 239-240.

[91] J. R. Kim, J.-P. Muller, S. van Gasselt, J. G. Morley, G. Neukum, and the HRSC Col Team, "Automated Crater Detection, A New Tool for Mars Cartography and Chronology.", *Photogrammetric Engineering & Remote Sensing*, October 2005b, vol. 71 num. 10 pp. 1205-1217.

[92] J. R. Kim, J. P. Muller, J. G. Morley, G. Neukum, "Automatic crater detection and 3D reconstruction using HRSC and THEMIS Visible images.", *1st International Conference on Impact Cratering in the Solar System*, ESA, Noordwijk, Netherlands, May 2006, no. 307245 pp. 1-2.

[93] J.-R. Kim, J. L. Simpson, J.-P. Muller, S.-Y. Lin, "3D crater data base construction using automated and manual components for crater morphology. (Abstract)", *Geophysical Research Abstracts*, Copernicus GmbH, Vienna, Austria, 13-18 April 2008, vol. 10 no. EGU2008-A-11490 pp. 1-1.

[94] R. A. Kirsch, "Computer determination of the constituent structure of biological images", *Computers and Biomedical Research*, June 1971, vol. 4 num. 3 pp. 315-328.

[95] H. Knežević, G. Salamunićcar, S. Lončarić, "Crater Detection Algorithms Based on Prewitt, Abdou, Argyle, Macleod, Derivative-of-Gaussian and Canny Gradient Edge Detectors.", *39th Annual Lunar and Planetary Science Conference – 39thLPSC*, NASA LPI, Houston, USA, March 2008, no. 1378 pp. 1-2.

[96] S. O. Krøgli, H. Dypvik, B. Etzelmüller, "Automatic detection of circular depressions in digital elevation data in the search for potential Norwegian impact structures.", *Norwegian Journal of Geology*, Trondheim, Norway, 2007, vol. 87 num. 1&2 pp. 157-166.

[97] S. O. Krøgli, H. Dypvik, B. Etzelmüller, "Automatic Detection of Circular Outlines from Images of Gravity and Aeromagnetic Fields.", *39th Annual Lunar and Planetary Science Conference – 39thLPSC*, NASA LPI, Houston, USA, March 2008, no. 1210 pp. 1-2.

[98] S. O. Krøgli, H. Dypvik, "Automatic detection of circular outlines in regional gravity and aeromagnetic data in the search for impact structure candidates.", *Computers & Geosciences*, Elsevier Science, Oxford, UK, April 2010, vol. 36 num. 4 pp. 477-488, doi:10.1016/j.cageo.2009.07.010.

[99] B. Leroy, G. Medioni, E. Johnson, L. Matthies, "Crater detection for autonomous landing on asteroids.", *Image and Vision Computing*, Elsevier Science, Oxford, UK, September 2001, vol. 19 num. 11 pp. 787-792, doi:10.1016/S0262-8856(00)00111-6.

[100] R. Li, F. Ma, F. Xu, L. H. Matthies, C. F. Olson, R. E. Arvidson, "Localization of Mars rovers using descent and surface-based image data.", *Journal of Geophysical Research - Planets*, AGU, USA, August 2002, vol. 107, issue E11, pp. 1-8, doi:10.1029/2000JE001443.

[101] C.-J. Lin, "LIBSVM & LIBLINEAR.", January 2010 (datum pristupa: 05.01.2010.), "http://www.csie.ntu.edu.tw/~cjlin/".

[102] S. Liu, W. Ding, T. F. Stepinski, "Semi-Supervised Active Class Selection for Automatic Identification of Sub-Kilometer Craters.", *7th International Symposium on Image and Signal Processing and Analysis – ISPA 2011*, Dubrovnik, Croatia, September 2011, no. 274 pp. 615-620.

[103] S. Lončarić, G. Salamunićcar, "Extensions of the Framework for Evaluation of Crater Detection Algorithms Based on New Algorithm for Registration of Craters and GT-115225 Catalogue.", *41st Annual Lunar and Planetary Science Conference – 41stLPSC*, NASA LPI, Houston, USA, March 2010, no. 1417 pp. 1-2.

[104] S. Lončarić, G. Salamunićcar, A. Grumpe, C. Wöhler, "Automatic Detection of Lunar Craters Based on Topography Reconstruction from Chandrayaan-1 M3 Imagery.", *42nd Annual Lunar and Planetary Science Conference – 42ndLPSC*, NASA LPI, Houston, USA, March 2011, no. 1454 pp. 1-2.

[105] B. Maass, H. Krüger, S. Theil, "An Edge-Free, Scale-, Pose- and Illumination-Invariant Approach to Crater Detection for Spacecraft Navigation.", *7th International Symposium on Image and Signal Processing and Analysis – ISPA 2011*, Dubrovnik, Croatia, September 2011, no. 265 pp. 603-608.

[106] I. D. G. Macleod, "Comments on 'Techniques for Edge Detection'", *Proc. IEEE*, IEEE, March 1972, vol. 60 pp. 344-344.

[107] M. Magee, C. R. Chapman, S. W. Dellenback, B. Enke, W. J. Merline, M. P. Rigney, "Automated Identification of Martian Craters Using Image Processing.", *34th Annual Lunar*

and Planetary Science Conference – 34thLPSC, Houston, USA, March 2003, no. 1756 pp. 1-2.

[108] M. Maimone, A. Johnson, Y. Cheng, R. Willson, L. Matthies, "Autonomous Navigation Results from the Mars Exploration Rover (MER) Mission.", *9th International Symposium on Experimental Robotics (ISER-2004)*, Singapore, June 2004, pp. 1-10.

[109] B. Malmfors, P. Garnsworthy, M. Grossman, "Writing and Presenting Scientific Papers." 2nd Ed., *Nottingham University Press*, Nottingham, UK, 2004.

[110] N. S. Maravell, et al., "Space Science: New Research.", *Nova Science Publishers*, New York, USA, 2006.

[111] T. Marjanac, A. M. Tomša, Lj. Marjanac, "Krk-breccia, possible impact-crater fill, Island of Krk in eastern Adriatic sea (Croatia)", in "Cratering in Marine Environments and on Ice: Impact Studies", edited by H. Dypvik, M. Burchell and P. Claeys, Springer-Verlag GmbH, Berlin / Heidelberg, Germany, 2003, pp. 115-134.

[112] R. Martins, P. Pina. J. S. Marques, M. Silveira, "A Boosting Algorithm for Crater Recognition.", *13ª Conferência Portuguesa de Reconhecimento de Padrões*, Lisboa, Portugal, October 2007, pp. 1-2.

[113] R. Martins, P. Pina, J. S. Marques, M. Silveira, "A Boosting Algorithm for Crater Detection.", *Visualization, Imaging, and Image Processing – VIIP 2008*, Palma de Mallorca, Spain, September 2008, pp. 1-5.

[114] R. Martins, P. Pina, J. S. Marques, M. Silveira, "Crater Detection by a Boosting Approach.", *Geoscience and Remote Sensing Letters*, IEEE, January 2009, vol. 6 num. 1 pp. 127-131, doi:10.1109/LGRS.2008.2006004.

[115] N. Matsumoto, N. Asada, H. Demura, "Automatic Crater Recognition on Digital Terrain Model.", *36th Annual Lunar and Planetary Science Conference – 36thLPSC*, NASA LPI, Houston, USA, March 2005a, no. 1995 pp. 1-2.

[116] N. Matsumoto, N. Asada, H. Demura, "Automatic crater recognition on digital terrain model. (Abstract)", Japan, 2005b, pp. 1-1, "http://earth2005.jtbcom.co.jp/session/pdf/p099/p099p-006_e.pdf".

[117] E. Mazarico, O. S. Barnouin, G. Salamunićcar, M. T. Zuber, "Impact Melt Volume Estimates of Small- to Medium-Sized Lunar Craters from Lunar Reconnaissance Orbiter Data.", *42nd Annual Lunar and Planetary Science Conference – 42ndLPSC*, NASA LPI, Houston, USA, March 2011, no. 2075 pp. 1-2.

[118] J. McDowell, "A merge of a digital version of the list of lunar craters from Andersson and Whitaker (1982) with the list from the USGS site.", 2004~2007, "http://www.planet4589.org/astro/lunar/Craters".

[119] H. J. Melosh, B. A. Ivanov, "Impact Crater Collapse.", *Annual Review Of Earth And Planetary Sciences*, 1999, vol. 27 pp. 385-415.

[120] D. Meng, C. Yun-feng, W. Qing-xian, "Autonomous Craters Detection from Planetary Image.", *3rd International Conference on Innovative Computing Information and Control – ICICIC 2008*, Dalian-Liaoning, China, June 2008, pp. 443-447, doi:10.1109/ICICIC.2008.181.

[121] D. Meng, C. Yunfeng, W. Qingxian, "Method of Passive Image Based Crater Autonomous Detection.", *Chinese Journal of Aeronautics*, Elsevier Science, Oxford, UK, June 2009a, vol. 22 num. 3 pp. 301-306, doi:10.1016/S1000-9361(08)60103-X.

[122] D. Meng, C. Yunfeng, W. Qingxian, "Crater Region Detection Based on Census Transform and Boosting (samo sažetak je na engleskom, ostalo je na kineskom).", *Journal of Nanjing University of Aeronautics & Astronautics*, China, October 2009b, vol. 41 num. 5 pp. 682-687.

[123] G. G. Michael, "Coordinate registration by automated crater recognition.", *Microsymposium 36*, Moscow, Russia, October 2002, no. MS068, pp. 1-2.

[124] G. G. Michael, "Coordinate registration by automated crater recognition.", *Planetary and Space Science*, Elsevier Science, Oxford, UK, August 2003a, vol. 51 num. 9-10 pp. 563-568, doi:10.1016/S0032-0633(03)00074-6.

[125] G. G. Michael, "Survey of Mars crater topography from MOLA data.", *Microsymposium 38*, Moscow, Russia, October 2003b, no. MS067, pp. 1-1.

[126] G. G. Michael, "Craterstats application.", 2010, "http://hrscview.fu-berlin.de/craterstats.html".

[127] W. I. Miller, T. F. Stepinski, Y. Mu, W. Ding, "Cascading Crater Detection with Active Learning.", *42nd Annual Lunar and Planetary Science Conference – 42ndLPSC*, NASA LPI, Houston, USA, March 2011, no. 1469 pp. 1-2.

[128] E. Mjolsness, D. DeCoste, "Machine Learning for Science: State of the Art and Future Prospects.", *Science*, September 2001, vol. 293, pp. 2051-2055.

[129] NASA, "Possible String of Impact Craters, Chad", August 2005 (datum pristupa: 22.02.2011), <http://neo.jpl.nasa.gov/images/chad.html>.

[130] NASA/JPL-Caltech/University of Arizona, "Phobos from 6800 Kilometers.", May 2008a (datum pristupa: 26.07.2011.), "http://www.nasa.gov/mission_pages/MRO/multimedia/pia10368.html".

[131] NASA/JPL-Caltech/University of Arizona, "'Victoria Crater' at Meridiani Planum.", May 2008b (datum pristupa: 22.01.2009.), "http://www.nasa.gov/mission_pages/MRO/multimedia/pia08813.html".

[132] NASA/JPL-Caltech/MSSS, "Endeavour Crater in Context.", January 2009 (datum pristupa: 22.01.2009.), "http://www1.nasa.gov/mission_pages/mer/images/pia11837.html".

[133] R. Nevatia, K. R. Babu, "Linear Feature Extraction and Description.", *Computer Graphics and Image processing*, Academic Press, 1980, vol. 13 pp. 257-269.

[134] H. Novosel, G. Salamunićcar, S. Lončarić, "Crater Detection Algorithms Based on Pixel-Difference, Separated-Pixel-Difference, Roberts, Prewitt, Sobel and Frei-Chen Gradient Edge Detectors.", *38th Annual Lunar and Planetary Science Conference – 38thLPSC*, NASA LPI, Houston, USA, March 2007, no. 1351 pp. 1-2.

[135] Ž. Pauše, "Vjerojatnost: informacija, stohastički procesi: pojmovi - metode - primjene.", *Školska knjiga*, Zagreb, Croatia, 1988.

[136] S. Pavlek, "Algoritmi strojnog učenja u paketu Weka", seminar, Croatia, Zagreb, 2002.

[137] M. M. Pedrosa, J. R. Nogueira, E. A. Silva, "Application of Morphological Operators in Detection Impact Craters on Mars.", *42nd Annual Lunar and Planetary Science Conference – 42ndLPSC*, NASA LPI, Houston, USA, March 2011, no. 1987 pp. 1-2.

[138] P. Pina, I. Alves, T. Barata, J. Saraiva, D. Vaz, L. Bandeira, "Analysis and Automatic Feature Recognition on Images of the Surface of Mars. (Abstract)", *1st Mars Express Science Conference*, Noordwijk, Netherlands, February 2005, pp. 248.

[139] P. Pina, J. Saraiva, L. Bandeira, T. Barata, "Identification of Martian Polygonal Patterns Using the Dynamics of Watershed Contours.", Lecture Notes in Computer Science (Image Analysis and Recognition, Third International Conference, ICIAR 2006, Póvoa de Varzim, Portugal, September 18-20, 2006, Proceedings, Part II), Springer-Verlag GmbH, Berlin / Heidelberg, Germany, September 2006, vol. 4142 pp. 691-699, doi:10.1007/11867661.

[140] Planetary and Space Science Centre, "Earth Impact Database", March 2011 (datum pristupa: 28.03.2011), "http://www.passc.net/EarthImpactDatabase/index.html".

[141] C. S. Plesko, S. P. Brumby, C. Leovy, "Automatic feature extraction for panchromatic Mars Global Surveyor Mars Orbiter camera imagery.", *4480 Imaging Spectrometry VII*, SPIE, SPIE, San Diego, USA, August 2001, pp. 139-146.

[142] C. Plesko, S. Brumby, E. Asphaug, "Automated Development of Feature Extraction Tools for Planetary Science Image Datasets.", *34th Annual Lunar and Planetary Science Conference – 34thLPSC*, Houston, USA, March 2003a, no. 1758 pp. 1-2.

[143] C. S. Plesko, E. Asphaug, S. P. Brumby, G. R. Gisler, "Automated Feature Extraction and Hydrocode Modeling of Impact Related Structures on Mars: Preliminary Report.", *Sixth International Conference on Mars – 6thMARS*, Pasadena, California, USA, July 2003b, no. 3227 pp. 1-3.

[144] C. Plesko, S. Brumby, E. Asphaug, D. Chamberlain, T. Engel, "Automatic Crater Counts on Mars.", *35th Annual Lunar and Planetary Science Conference – 35thLPSC*, NASA LPI, Houston, USA, March 2004, no. 1935 pp. 1-2.

[145] C. Plesko, S. Brumby, E. Asphaug, "A Comparison of Automated and Manual Surveys of Small Craters in Elysium Planitia.", *36th Annual Lunar and Planetary Science Conference – 36thLPSC*, NASA LPI, Houston, USA, March 2005a, no.1971 pp. 1-2.

[146] C. S. Plesko, S. C. Werner, S. P. Brumby, B. H. Foing, E. Asphaug, G. Neukum, H. Team, I. Team, "From Crater to Graph: Manual and Automated Crater Counting Techniques. (Abstract)", *AGU Fall Meeting*, San Francisco, California, USA, December 2005b, no. #P23A-0185 pp. 1-1.

[147] C. S. Plesko, S. C. Werner, S. P. Brumby, E. Asphaug, G. Neukum, HRSC Investigator Team, "A Statistical Analysis of Automated Crater Counts in MOC and HRSC Data.", *37th Annual Lunar and Planetary Science Conference – 37thLPSC*, NASA LPI, Houston, USA, March 2006, no. 2012 pp. 1-2.

[148] H. Pohlheim, "The Multipopulation Genetic Algorithm: Local Selection and Migration.", February 2011 (datum pristupa: 22.02.2011.), "http://www.pohlheim.com/Papers/mpga_gal95/gal2_1.html".

[149] R. S. Portugal, C. R. De Souza Filho, P. A. Bland, "Automatic Crater Detection Using DEM and Circular Coherency Analysis - A Case Study on South American Craters.", *67th Annual Meeting of the Meteoritical Society*, Rio de Janeiro, Brazil, August 2004, no. 5096, pp. 1-1.

[150] W. K. Pratt, "Digital Image Processing: PIKS Inside." 3rd Ed., *John Wiley & Sons Inc.*, New York, USA, 2001, pp. 443-508 (pp. 456).

[151] J. Prewitt, "Object enhancement and extraction.", in *Picture Processing and Psychopictories* (B. Lipkin and A. Rosenfeld, Eds.), Academic Press, New York, USA, 1970, pp. 75-149.

[152] D. Rajmon, "Impact Database v. 2010.1", March 2011 (datum pristupa: 26.03.2011), "http://impacts.rajmon.cz/IDdata.html".

[153] T. Rajput, "Satellite-Derived Digital Topography-Based Crater Boundary Detection and Attribute Measurements by Segmentation and Moments Measure Techniques.", *Master of*

Science Thesis, Faculty of Geo-Information Science and Earth Observation, University of Twente, Enschede, Netherlands, April 2011, pp. 1-59.

[154] G. Repinc, "Slučajna šuma (random forest).", February 2009 (datum pristupa: 22.02.2011.), "http://web.math.hr/nastava/ui/index.php/download_file/-/view/48/".

[155] L. G. Roberts, "Machine perception of three-dimensional solids.", in *Optical and Electro-Optical Information Processing* (J. T. Tippett et al. Eds.), MA: MIT Press, Cambridge, USA, 1965, pp. 159-197.

[156] S. J. Robbins, B. M. Hynek, "A new automated method of determining depth, diameter, and volume of craters.", *10th Mars Crater Consortium meeting*, US Geological Survey in Flagstaff-AZ, USA, October 2007, pp. 1-2, "http://www.marscraterconsortium.nau.edu/RobbinsMCC10.pdf".

[157] S. J. Robbins, B. M. Hynek, "Progress Towards a New Global Catalog of Martian Craters and Layered Ejecta Properties, Complete to 1.5 km.", *41st Annual Lunar and Planetary Science Conference – 41stLPSC*, NASA LPI, Houston, USA, March 2010, no. 2257 pp. 1-2.

[158] S. J. Robbins, B. M. Hynek, "It's done! A new Martian global crater database to 1.0 km.", *2nd Planetary Crater Consortium meeting*, US Geological Survey in Flagstaff-AZ, USA, September 2011, pp 1-2, "http://www.planetarycraterconsortium.nau.edu/Robbins1PCC2.pdf".

[159] J. F. Rodionova, A. A. Karlov, T. P. Skobeleva, E. V. Konotopskaya, V. V. Shevchenko, K. E. Kozubskiy, K. I. Dekhtyareva, T. F. Smolyakova, L. I. Tishik, E. A. Fedorova, V. V. Shevchenko (editor), "Morphological catalogue of the craters of the Moon.", 1987, "http://selena.sai.msu.ru/Home/Moon_Cat/Moon_cate.htm".

[160] G. Salamunićcar, "Applying the Mathematical Theory of Stochastic Processes to lunar and planetary science: the ancient oceans on Mars case.", *Advances in Space Research*, Elsevier Science, Oxford, UK, June 2004, vol. 33 num. 12 pp. 2281-2287, doi:10.1016/S0273-1177(03)00521-0.

[161] G. Salamunićcar, S. Lončarić, "Estimation of Ground Truth for Evaluation of Crater Detection Algorithms.", *37th Annual Lunar and Planetary Science Conference – 37thLPSC*, NASA LPI, Houston, USA, March 2006a, no. 1137 pp. 1-2.

[162] G. Salamunićcar, S. Lončarić, "Estimation of False Detections for Evaluation of Crater Detection Algorithms.", *37th Annual Lunar and Planetary Science Conference – 37thLPSC*, NASA LPI, Houston, USA, March 2006b, no. 1138 pp. 1-2.

[163] G. Salamunićcar, S. Lončarić, "Framework for more standardized evaluation of crater detection algorithms. (Abstract)", *36th COSPAR Scientific Assembly*, Beijing, China, July 2006c, no. B0.2-0054-06 pp. 1-1.

[164] G. Salamunićcar, S. Lončarić, "From Evaluation of Ground Truth Catalogue of Martian Craters Towards Estimation of Possible Improvements of Catalogues of Craters.", *38th Annual Lunar and Planetary Science Conference – 38thLPSC*, NASA LPI, Houston, USA, March 2007a, no. 1087 pp. 1-2.

[165] G. Salamunićcar, S. Lončarić, "From Cross-Analysis Using Ground Truth Catalogue of Martian Craters Towards New Generation of Catalogues of Craters.", *38th Annual Lunar and Planetary Science Conference – 38thLPSC*, NASA LPI, Houston, USA, March 2007b, no. 1088 pp. 1-2.

[166] G. Salamunićcar, S. Lončarić, "Circular-Consistency and Slip-Tuning Improvements of Crater Detection Algorithms Based on Gradient Edge Detectors and Radon/Hough

Transform.", *Seventh International Conference on Mars – 7th MARS*, Caltech, Los Angeles - Pasadena, USA, July 2007c, no. 3066 pp. 1-6.

[167] G. Salamunićcar, S. Lončarić, "Cross-Analysis-Based Improvements of Ground Truth Catalogue of Large Martian Craters.", *Seventh International Conference on Mars – 7th MARS*, Caltech, Los Angeles - Pasadena, USA, July 2007d, no. 3067 pp. 1-6.

[168] G. Salamunićcar, S. Lončarić, "Merge of Five Previous Catalogues Into the Ground Truth Catalogue and Registration Based on MOLA Data with THEMIS-DIR, MDIM and MOC Data-Sets.", *39th Annual Lunar and Planetary Science Conference – 39th LPSC*, NASA LPI, Houston, USA, March 2008a, no. 1372 pp. 1-2.

[169] G. Salamunićcar, S. Lončarić, "Gradient Amplification and Gradient Orientation Improvements of Crater Detection Algorithms Based on Edge Detectors and Radon/Hough Transform.", *39th Annual Lunar and Planetary Science Conference – 39th LPSC*, NASA LPI, Houston, USA, March 2008b, no. 1375 pp. 1-2.

[170] G. Salamunićcar, S. Lončarić, "Extensions of the framework for evaluation of crater detection algorithms: new ground truth catalogue with 57633 craters, additional subsystems and evaluations. (Abstract)", *37th COSPAR Scientific Assembly*, Montréal, Canada, July 2008c, no. B02-0061-08 pp. 1-1.

[171] G. Salamunićcar, S. Lončarić, "Open framework for objective evaluation of crater detection algorithms with first test-field subsystem based on MOLA data.", *Advances in Space Research*, Elsevier Science, Oxford, UK, July 2008d, vol. 42 num. 1 pp. 6-19, doi:10.1016/j.asr.2007.04.028.

[172] G. Salamunićcar, S. Lončarić, "GT-57633 catalogue of Martian impact craters developed for evaluation of crater detection algorithms.", *Planetary and Space Science*, Elsevier Science, Oxford, UK, December 2008e, vol. 56 num. 15 pp. 1992-2008, doi:10.1016/j.pss.2008.09.010.

[173] G. Salamunićcar, "The first new application of the Mathematical Theory of Stochastic Processes to lunar and planetary science: Topography-Profile Diagrams of Mars.", *Advances in Space Research*, Elsevier Science, Oxford, UK, January 2009, vol. 43 num. 2 pp. 308-316, doi:10.1016/j.asr.2008.04.014.

[174] G. Salamunićcar, S. Lončarić, "Morphometry, Votes-Analysis and Calibration Improvements of Crater Detection Algorithms Based on Edge Detectors and Radon/Hough Transform.", *40th Annual Lunar and Planetary Science Conference – 40th LPSC*, NASA LPI, Houston, USA, March 2009a, no. 1084 pp. 1-2.

[175] G. Salamunićcar, S. Lončarić, "Automated Depth/Diameter and Topographic-Cross-Profile Measurements Based on GT-57633 Catalogue of Martian Impact Craters and MOLA Data.", *40th Annual Lunar and Planetary Science Conference – 40th LPSC*, NASA LPI, Houston, USA, March 2009b, no. 1085 pp. 1-2.

[176] G. Salamunićcar, S. Lončarić, "Basic Principles and Prototype of Crater Detection Algorithm for Detection of Craters from Global Mosaics of Visual Images for the Whole Mars.", *41st Annual Lunar and Planetary Science Conference – 41st LPSC*, NASA LPI, Houston, USA, March 2010a, no. 1421 pp. 1-2.

[177] G. Salamunićcar, D. Vinković, L. Karbonini, M. Vojković, S. Lončarić, "Differences in Distribution in GT-115225 Global Catalogue of Martian Craters Between Shallow and Deep Craters and Between Large and Small Craters.", *41st Annual Lunar and Planetary Science Conference – 41st LPSC*, NASA LPI, Houston, USA, March 2010a, no. 1426 pp. 1-2.

[178] G. Salamunićcar, S. Lončarić, "Method for crater detection from Martian digital topography data using gradient value/orientation, morphometry, votes-analysis, slip-tuning and calibration.", *Transactions on Geoscience and Remote Sensing*, IEEE, New York, USA, May 2010b, vol. 48 num. 5 pp. 2317-2329, doi:10.1109/TGRS.2009.2037750.

[179] G. Salamunićcar, S. Lončarić, "Method for crater detection from digital topography data: interpolation based improvement and application to Lunar SELENE LALT data. (Abstract)", *38th COSPAR Scientific Assembly*, Bremen, Germany, July 2010c, no. B02-0042-10 pp. 1-1.

[180] G. Salamunićcar, S. Lončarić, "Application of machine learning using support vector machines for crater detection from Martian digital topography data. (Abstract)", *38th COSPAR Scientific Assembly*, Bremen, Germany, July 2010d, no. B02-0043-10 pp. 1-1.

[181] G. Salamunićcar, D. Vinković, S. Lončarić, D. Vučina, I. Pehnec, M. Vojković, M. Gomerčić, T. Hercigonja, "Method for evaluation of laboratory craters using crater detection algorithm for digital topography data. (Abstract)", *38th COSPAR Scientific Assembly*, Bremen, Germany, July 2010b, no. B02-0044-10 pp. 1-1.

[182] G. Salamunićcar, S. Lončarić, P. Pina, L. Bandeira, J. Saraiva, "MA130301GT catalogue of Martian impact craters and advanced evaluation of crater detection algorithms using diverse topography and image datasets.", *Planetary and Space Science*, Elsevier Science, Oxford, UK, January 2011a, vol. 59 num. 1 pp. 111-131, doi:10.1016/j.pss.2010.11.003.

[183] G. Salamunićcar, S. Lončarić, E. Mazarico, "From Interpolation Based Crater Detection Algorithm and LOLA Data Towards the Most Complete Global Catalog of Lunar Craters.", *42nd Annual Lunar and Planetary Science Conference – 42ndLPSC*, NASA LPI, Houston, USA, March 2011b, no. 1449 pp. 1-2.

[184] G. Salamunićcar, S. Lončarić, P. Pina, L. Bandeira, J. Saraiva, "Machine Detection and Global Catalog of Phobos Craters.", *42nd Annual Lunar and Planetary Science Conference – 42ndLPSC*, NASA LPI, Houston, USA, March 2011c, no. 1451 pp. 1-2.

[185] G. Salamunićcar, S. Lončarić, P. Pina, L. Bandeira, J. Saraiva, "Integrated Crater Detection Algorithm and Systematic Cataloging of Phobos Craters.", *7th International Symposium on Image and Signal Processing and Analysis – ISPA 2011*, Dubrovnik, Croatia, September 2011d, no. 175 pp. 591-596.

[186] G. Salamunićcar, S. Lončarić, A. Grumpe, C. Wöhler, "Hybrid Method for Detection of Lunar Craters Based on Topography Reconstruction from Optical Images.", *7th International Symposium on Image and Signal Processing and Analysis – ISPA 2011*, Dubrovnik, Croatia, September 2011e, no. 263 pp. 597-602.

[187] G. Salamunićcar, S. Lončarić, E. Mazarico, "LU60645GT and MA132843GT catalogues of Lunar and Martian impact craters developed using a Crater Shape-based interpolation crater detection algorithm for topography data.", *Planetary and Space Science*, Elsevier Science, Oxford, UK, 2011f, pp. 1-12, doi:10.1016/j.pss.2011.09.003, accepted.

[188] J. Saraiva, L. P. C. Bandeira, P. Pina, "A Structured Approach to Automated Crater Detection.", *37th Annual Lunar and Planetary Science Conference – 37thLPSC*, NASA LPI, Houston, USA, March 2006, no. 1142 pp. 1-2.

[189] J. Saraiva, L. P. C. Bandeira, P. Pina, "Automatic Crater Detection in 'Ridged Plains' Areas of Mars.", *38th Annual Lunar and Planetary Science Conference – 38thLPSC*, NASA LPI, Houston, USA, March 2007, no. 1311 pp. 1-2.

[190] J. Saraiva, L. Bandeira, P. Pina, C. Barreira, "Can automated crater detection be trusted? (Abstract)", *33rd International Geology Congress*, Oslo, Norway, August 2008, pp. 1-1.

[191] Y. Sawabe, T. Matsunaga, S. Rokugawa, "Automatic extraction of craters in the Moon surface. (Abstract)", Japan, 2003, pp. 1-1, "http://www-jm.eps.s.u-tokyo.ac.jp/2003cd-rom/pdf/j034/j034-p003_e.pdf".

[192] Y. Sawabe, T. Matsunaga, S. Rokugawa, "Automatic detection and classification of craters from image data acquired by lunar orbiting spacecraft using multiple approaches. (Abstract)", *35th COSPAR Scientific Assembly*, Paris, France, July 2004, no. B0.3/F0.1/PPP3-0017-04 pp. 1-1.

[193] Y. Sawabe, T. Matsunaga, S. Rokugawa, "Automated detection and classification of lunar craters using multiple approaches.", *Advances in Space Research*, Elsevier Science, Oxford, UK, 2006, vol. 37 num. 1 pp. 21-27, doi:10.1016/j.asr.2005.08.022.

[194] A. P. Saygin, I. Cicekli, V. Akman, "Turing Test: 50 Years Later.", *Minds and Machines*, Kluwer Academic Publishers, Hingham-MA, USA, November 2000, vol. 10 num. 4 pp. 463-518, doi:10.1023/A:1011288000451.

[195] J. Shen, S. Castan, "An Optimal Linear Operator for Step Edge Detection.", *Computer Vision, Graphics, and Image Processing: Graphical Models and Image Processing*, Academic Press, March 1992, vol. 54 num. 2 pp. 112-133.

[196] J. I. Simpson, J. R. Kim, J.-P. Muller, "3D Crater database production on Mars by automated crater detection and data fusion.", *21st ISPRS Congress*, Beijing, China, July 2008, pp. 1049-1054.

[197] A. A. Smirnov, "Exploratory study of automated crater detection algorithm.", Technical Report, Boulder, Colorado, USA, May 2002, pp. 1-7, "http://www.cs.colorado.edu/~rossnd/fcdmf/CraterPaper.pdf".

[198] D. E. Smith, M. T. Zuber, G. A. Neumann, F. G. Lemoine, E. Mazarico, M. H. Torrence, J. F. McGarry, D. D. Rowlands, J. W. Head III, T. H. Duxbury, O. Aharonson, P. G. Lucey, M. S. Robinson, O. S. Barnouin, J. F. Cavanaugh, X. Sun, P. Liiva, D.-d. Mao, J. C. Smith, A. E. Bartels, "Initial observations from the Lunar Orbiter Laser Altimeter (LOLA).", *Geophysical Research Letters*, AGU, USA, September 2010, vol. 37 num. L18204, pp. 1-6, doi:10.1029/2010GL043751.

[199] I. Sobel, "Neighborhood coding of binary images for fast contour following and general binary array processing.", *Computer Graphics and Image Processing*, Academic Press, New York, USA, 1978, vol. 8 pp. 127-135.

[200] T. F. Stepinski, M. P. Mendenhall, "Machine Identification and Characterization of Martian Craters from Digital Topography.", *9th Mars Crater Consortium meeting*, US Geological Survey in Flagstaff-AZ, USA, October 2006a, pp. 1-2, "http://www.marscraterconsortium.nau.edu/StepinskiMCC9.pdf".

[201] T. F. Stepinski, M. P. Mendenhall, I. Molloy, B. D. Bue, W. Luo, "Automated Identification and Characterization of Landforms on Mars.", USA, October 2006, pp. 1-27, "http://aisrp.nasa.gov/projects/presentations/10e85cbdefd.pdf".

[202] T. F. Stepinski, M. P. Mendenhall, "Robust System for Automated Identification of Martian Impact Craters. (Abstract)", *AGU Fall Meeting*, San Francisco, California, USA, December 2006b, no. #P34B-02, pp. 1-1.

[203] T. F. Stepinski, M. P. Mendenhall, B. D. Bue, "Robust Automated Identification of Martian Impact Craters.", *38th Annual Lunar and Planetary Science Conference – 38thLPSC*, NASA LPI, Houston, USA, March 2007a, no. 1202 pp. 1-2.

[204] T. F. Stepinski, S. Ghosh, W. Luo, R. Vilalta, "Toward Machine Geomorphic Mapping of Planetary Surfaces.", *ISPRS WG IV/7 Extraterrestrial Mapping Workshop: Advances in Planetary Mapping 2007*, Houston, USA, March 2007b, pp. 1-2.

[205] T. F. Stepinski, E. R. Urbach, "Toward machine cataloging of martian craters.", *10th Mars Crater Consortium meeting*, US Geological Survey in Flagstaff-AZ, USA, October 2007, pp. 1-2, "http://www.marscraterconsortium.nau.edu/stepinskiMCC10.pdf".

[206] T. F. Stepinski, E. R. Urbach, "Completion of the first automatic survey of craters on Mars.", *11th Mars Crater Consortium meeting*, US Geological Survey in Flagstaff-AZ, USA, September 2008, pp. 1-2, "http://www.marscraterconsortium.nau.edu/stepinski1103.pdf".

[207] T. F. Stepinski, E. R. Urbach, "The First Automatic Survey of Impact Craters on Mars: Global Maps of Depth/Diameter Ratio.", *40th Annual Lunar and Planetary Science Conference – 40thLPSC*, NASA LPI, Houston, USA, March 2009, no. 1117 pp. 1-2.

[208] T. F. Stepinski, M. P. Mendenhall, B. D. Bue, "Machine cataloging of impact craters on Mars.", *Icarus*, September 2009, vol. 203 num. 1 pp. 77-87, doi:10.1016/j.icarus.2009.04.026.

[209] S. A. Stewart, "Estimates of yet-to-find impact crater population on Earth.", *Journal of the Geological Society*, London, UK, January 2011, vol. 168 num. 1 pp. 1-13, doi:10.1144/0016-76492010-006.

[210] P. J. Stooke, "New Photomaps of Phobos, Deimos, Itokawa, Steins, Wild 2 and Tempel 1.", *42nd Annual Lunar and Planetary Science Conference – 42ndLPSC*, NASA LPI, Houston, USA, March 2011, no. 1312 pp. 1-2.

[211] G. Troglio, J. A. Benediktsson, G. Moser, S. B. Serpico, "Crater detection based on marked point processes.", *2010 IEEE International Geoscience and Remote Sensing Symposium – IGARSS 2010*, Honolulu-HI, USA, July 2010, pp. 1378-1381, doi:10.1109/IGARSS.2010.5651044.

[212] M. Turhan Taner, "Kohonen's Self Organizing Networks with 'Conscience'.", November 1997 (datum pristupa: 22.02.2011.), "http://www.rocksolidimages.com/pdf/kohonen.pdf".

[213] E. R. Urbach, "Classification of objects consisting of multiple segments with application to crater detection.", *8th International Symposium on Mathematical Morphology*, Rio de Janeiro, Brazil, October 2007, vol. 2 pp. 81-82.

[214] E. R. Urbach, T. F. Stepinski, "Automatic Detection of Sub-kilometer Craters in High Resolution Images of Mars.", *39th Annual Lunar and Planetary Science Conference – 39thLPSC*, NASA LPI, Houston, USA, March 2008, no. 2184 pp. 1-2.

[215] E. R. Urbach, T. F. Stepinski, "Automatic detection of sub-km craters in high resolution planetary images.", *Planetary and Space Science*, Elsevier Science, Oxford, UK, June 2009, vol. 57 num. 7 pp. 880-887, doi:10.1016/j.pss.2009.03.009.

[216] USGS, "Venus Impact Craters Database", 29th March 1999 (datum pristupa: 27.12.2010.), "http://astrogeology.usgs.gov/Projects/VenusImpactCraters/venus_download.html" & "http://astrogeology.usgs.gov/Projects/VenusImpactCraters/venuscraters.xls".

[217] V. Vapnik, "The Nature of Statistical Learning Theory." 2nd Ed., *Springer*, New York, USA, 2000, pp. 1-314.

[218] R. Vetro, D. A. Simovici, "Entropic Quadtrees and Mining Mars Craters.", *Lecture Notes in Computer Science (10th Industrial Conference on Advances in Data Mining. Applications and Theoretical Aspects, ICDM 2010, Berlin, Germany, July 2010)*, Springer-Verlag GmbH,

Berlin / Heidelberg, Germany, 2010, vol. 6171 pp. 210-221, doi:10.1007/978-3-642-14400-4_17.

[219] D. Vinković, G. Salamunićcar, S. Lončarić, D. Vučina, M. Gomerčić, I. Pehnec, M. Vojković, T. Hercigonja, "Test-Field for Evaluation of Laboratory Craters Using Interpolation-Based Crater Detection Algorithm and Comparison with Martian Impact Craters.", *42nd Annual Lunar and Planetary Science Conference – 42ndLPSC*, NASA LPI, Houston, USA, March 2011, no. 1453 pp. 1-2.

[220] D. Vinković, "A laboratory proxy for Martian craters.", December 2009 (datum pristupa: 21.03.2011.), "http://vinkovic.org/Projects/Craters/".

[221] T. Vinogradova, E. Mjolsness, "Systematic comparison of automated geological feature detection methods for impact craters. (Abstract)", *AGU Fall Meeting*, San Francisco, California, USA, December 2001, no. #P42A-0563, pp. 1-1.

[222] T. Vinogradova, R. C. Anderson, E. Mjolsness, "Can Tectonic and Fluvial Structures be Used to Date a Planetary Surface?", *33rd Annual Lunar and Planetary Science Conference – 33rdLPSC*, Houston, USA, March 2002a, no. 2044 pp. 1-2.

[223] T. Vinogradova, M. Burl, E. Mjolsness, "Training of a crater detection algorithm for Mars crater imagery.", *IEEE Aerospace Conference*, Big Sky, Montana, USA, March 2002b, vol. 7 pp. 7-3201 - 7-3210.

[224] M. Vojković, L. Karbonini, D. Vinković, G. Salamunićcar, S. Lončarić, "Laboratory Craters and their Comparison with Craters from GT-115225 Global Catalogue of Martian Impact Craters.", *41st Annual Lunar and Planetary Science Conference – 41stLPSC*, NASA LPI, Houston, USA, March 2010a, no. 1428 pp. 1-2.

[225] M. Vojković, I. Pehnec, D. Vučina, D. Vinković, G. Salamunićcar, S. Lončarić, M. Gomerčić, T. Hercigonja, "3D topography of laboratory craters and their comparison with Martian impact craters. (Abstract)", *38th COSPAR Scientific Assembly*, Bremen, Germany, July 2010b, no. B02-0052-10 pp. 1-1.

[226] M. Wählisch, K. Willner, J. Oberst, K.-D. Matz, F. Scholten, T. Roatsch, H. Hoffmann, S. Semm, G. Neukum, "A new topographic image atlas of Phobos.", *Earth and Planetary Science Letters*, 2010, vol. 294 pp. 547-553, doi:10.1016/j.epsl.2009.11.003.

[227] J. Wang, W. Ding, B. Fradkin, C. H. Pham, P. Sherman, B. D. Tran, D. Wang, Y. Yang, T. F. Stepinski, "Effective Classification for Crater Detection: A Case Study on Mars.", *9th IEEE International Conference on Cognitive Informatics*, Beijing, China, July 2010, pp. 688-695.

[228] P. G. Wetzler, R. Honda, B. Enke, W. J. Merline, C. R. Chapman, M. C. Burl, "Learning to Detect Small Impact Craters.", *Seventh IEEE Workshop on Applications of Computer Vision (WACV/MOTION'05)*, Breckenridge, Colorado, USA, January 2005, pp. 178-184.

[229] I. H. Witten, E. Frank, L. Trigg, M. Hall, G. Holmes, S. J. Cunningham, "Weka: Practical Machine Learning Tools and Techniques with Java Implementations.", *ICONIP/ANZIIS/ANNES International Workshop on Emergent Knowledge Engineering and Connectionist-Based Information Systems*, University of Otago, Dunedin, New Zealand, pp. 192-196, 1999.

[230] C. Wöhler, A. Grumpe, "Planetary DEMs: A photometric approach to image-based construction of lunar DEMs.", March 2011 (datum pristupa: 22.03.2011.), "http://www.bv.e-technik.tu-dortmund.de/Contents/FO_Planetary_DEM.html".

[231] H. Yamamoto, T. Isobe, K. Homma, M. Shimizu, "Shape Recognition of Craters in Clementine Images", *30th Annual Lunar and Planetary Science Conference – 30thLPSC*, NASA LPI, Houston, USA, March 1999, no. 1066 pp. 1-2.

[232] M. Yang, W. Ding, D. Tao, T. F. Stepinski, "Biologically Inspired Model for Crater Detection.", *International Joint Conference on Neural Networks – IJCNN*, San Jose-CA, USA, July-August 2011, pp. 1-8.

[233] Z. Y. Yue, J. Z. Liu, G. G. Wu, "Automated detection of lunar craters based on object-oriented approach.", *Chinese Science Bulletin*, Science China Press co-published with Springer, China, December 2008, vol. 53 num. 23 pp. 3699-3704, doi:10.1007/s11434-008-0413-3.

[234] B. Zitová, J. Flusser, "Image registration methods: a survey.", *Image and Vision Computing*, Elsevier Science, Oxford, UK, October 2003, vol. 21 num. 11 pp. 977-1000, doi:10.1016/S0262-8856(03)00137-9.

12. KAZALO POJMOVA

ACE2 – *Altimeter Corrected Elevations*

A-ROC – *Approximation-of Receiver Operating Characteristics*

CDA – *Crater Detection Algorithm*

CLEMBASE – *Clementine Basemap Mosaic version 2*

DEM – *Digital Elevation Model*

FECDA – *Framework for Evaluation of Crater Detection Algorithms*

F-ROC – *Free-response Receiver Operating Characteristics*

IMRAD – *Introduction, Materials and Methods, Results and Discussion*

LASGW – *Lunar Airbrushed Shadedrelief Warped to ULCN2005*

LIBSVM – *Library for Support Vector Machines*

LIBLINEAR – *Library for Large Linear Classification*

LLR – *Longitude Latitude Radius*

LALT – *Laser Altimetry*

LOLA – *Lunar Orbiter Laser Altimeter*

LOM – *Lunar Orbiter Global Mosaic*

LRO – *Lunar Reconnaissance Orbiter*

MOLA – *Mars Orbiter Laser Altimeter*

MDIM – *Mars Global Digital Image Mosaic*

MOC – *Mars Orbiter Camera Wide Angle Atlas*

ROC – *Receiver Operating Characteristics*

THEMIS-DIR – *THEMIS Day IR Global Mosaic*

WAC – *Wide Angle Camera*

13. PRILOZI

Prilaže se:

- popis priloga na optičkom disku;
- životopis na hrvatskom jeziku; i
- životopis na engleskom jeziku.

POPIS PRILOGA NA OPTIČKOM DISKU

X:\GSC_PhD.pdf - doktorski rad u PDF formatu

X:\GSC_PhD.pps - prezentacija obrane doktorskog rada u PPS formatu

X:\GSC_PhD.txt - naslov, sažetak i ključne riječi na hrvatskom i engleskom u TXT formatu

X:\GSC_CV.txt - životopis u TXT formatu

X:\GSC_publikacije.zip - publikacije (među ostalim i objavljeni znanstveni radovi) u PDF formatu

X:\FECDA2011B* - datoteke temeljnog DVD-a okoline za razvoj i vrednovanje CDA-ova

X:\FECDA_draft* - radne verzije datoteka pripremljene za sljedeće FECDA verzije

Dodatni prilozi su okolina za razvoj i vrednovanje algoritama za detekciju kratera, koja je dostupna na 8 DVD-ova. Molim da me se kontaktira ako se na bilo koji način žele koristiti radne verzije datoteka, s obzirom na to da iste sadrže rezultate znanstvenih istraživanja koja još nisu objavljena u znanstvenim časopisima. Sve ostale datoteke navedene u sljedećoj tablici su rezultati objavljeni u znanstvenim časopisima, a iste su javno dostupne i smiju se slobodno koristiti u znanstvenim istraživanjima. Autoru se može obratiti na adresu gsc@ieee.org, kako bi DVD-ove po potrebi poslao i poštom, te asistirao i u reprodukciji rezultata ove doktorske disertacije.

Tablica 8. Dodatni DVD-ovi s podacima.

ime diska / sadržaj	**datum objave**
FECDA2011B:	2011, listopad
F2_4_0.PDF (dokumentacija)	2011-10-09
Craters5_81.zip (C++ izvorni kod CDA-ova)	2011-04-01
Topolyzer5_81_bins.zip (izvršni kod CDA-ova)	2011-04-01
CratersData.zip (XML-ovi i skripte za CDA-ove)	2011-04-22
C0001_GS_SL.zip (arhiva)	2006-07-02
C0002_HN_GS_SL.zip (arhiva)	2007-01-20
C0003_GS_SL.zip (arhiva)	2007-06-18
C0004_GS_HK_SL.zip (arhiva)	2008-02-05
C0005_GS_SL.zip (arhiva)	2009-03-13
C0006_GS_SL.zip (rezultati temeljnog CDA-a)	2009-10-07
C0007_GS_SL.zip (vrednovanje CDA-ova)	2009-12-27
C0008_GS_SL_EM.zip (rezultati interpolacijskog CDA-a)	2011-01-11
MA0100_0256_PinaBandeiraSaraiva_Tiles.zip	2010-03-22
MA0100_0256_PinaBandeiraSaraiva_Results.zip	2010-03-23
MA0100_0256_PinaBandeiraSaraiva_Craters.zip	2010-03-23
PH0005_016_PinaBandeiraSaraiva_Tiles.zip	2010-12-28
PH0005_016_PinaBandeiraSaraiva_Results.zip	2010-12-30
PH0005_016_PinaBandeiraSaraiva_Craters.zip	2010-12-30
PH0018_016_PinaBandeiraSaraiva_Tiles.zip	2011-01-13
PH0018_016_PinaBandeiraSaraiva_Results.zip	2011-04-21
PH0018_016_PinaBandeiraSaraiva_Craters.zip	2011-04-21
PH0019_016_PinaBandeiraSaraiva_Tiles.zip	2011-01-13
PH0019_016_PinaBandeiraSaraiva_Results.zip	2011-04-21
PH0019_016_PinaBandeiraSaraiva_Craters.zip	2011-04-21
LU0010_Wohler.zip	2011-02-05
LU0016_Wohler.zip	2011-03-08
DEMT64.img (DEM-MOLA)	2005-01-05

DEMT128.img (DEM-MOLA)	2007-06-10
MA17582GT.xml	2005-12-25
MA18711GT.xml	2007-06-17
MA57633GT.xml	2008-01-01
MA115225GT.xml	2009-07-20
MA130301GT.xml	2010-06-30
MA130301GT.xlsx	2010-10-27
MA130301GT_GIS.zip	2010-11-11
MA132843GT.xml	2010-07-04
MA132843GT.xlsx	2010-11-16
LU58357GT.xml	2010-11-14
LU58357GT.xlsx	2010-12-12
LU60645GT.xml	2010-12-31
LU60645GT.xlsx	2011-01-08
scale.xml (konfiguracije za generirati slike)	
scale*.bmp (skale od 1 do 7)	
scr_GenerateDEMsAndBMPs.bat	2011-10-09
AcDisk00001FECDA:	2009, ožujak
THM_DIR_256.bmp* (OPT)	2007-08-31
AcDisk00002FECDA:	2009, ožujak
MDIM_256.bmp* (OPT)	2007-08-31
AcDisk00003FECDA:	2009, ožujak
MOC_256.bmp* (OPT)	2007-08-31
AcDisk00004FECDA:	2010, prosinac
LU_LALT_16.jp2* (DEM-SELENE)	2010-04-14
LU_LDEM_64.jp2* (DEM-LOLA)	2010-04-14
LU_LDEM_128.jp2* (DEM-LOLA)	2010-04-14
LU_LDEM_256.jp2* (DEM-LOLA)	2010-12-08
LU_LASGW_64.jp2* (OPT)	2010-04-14
LU_CLEMBASE_256.jp2* (OPT)	2010-04-14
LU_LOM_512.jp2* (OPT)	2010-04-14
AcDisk00005FECDA:	2010, prosinac
MA_MOLA_DEMT_512.jp2* (DEM)	2010-10-18
PH_DEM1_4.jp2* (DEM)	2010-12-16
PH_BASEMAP1_16.jp2* (OPT)	2010-12-16
AcDisk00006FECDA:	2010, prosinac
LU_LDEM_512.jp2* (DEM-LOLA)	2010-12-09
AcDisk00007FECDA:	2011, kolovoz
VE_DEM1_32.jp2* (DEM)	2011-02-06
EA_DEM1_128.jp2* (DEM-ACE2)	2011-03-26
LU_LROC1_109164x54582.jp2* (OPT)	2011-04-10
LU_GDEM1_512.jp2* (DEM)	2011-04-19
LU_GDEM2_512.jp2* (DEM)	2011-04-19
LU_GOPT2_512.jp2* (OPT)	2011-04-19
PH_STOOKE1_14400x7200.jp2* (OPT)	2011-04-24
MA__H0905_0000_ND4__8248x65448.jp2* (OPT)	2011-06-04
MA__H0905_0000_DA4__2062x16362.jp2* (DEM)	2011-06-04
MA__DTEPC_001462_2630_001580_2630_U01__8589x8164.jp2* (DEM)	2011-06-19
MA__DTEEC_002118_1510_003608_1510_A01__7135x20409.jp2* (DEM)	2011-06-19
MA__DTEEC_014011_1315_014288_1315_A01__6225x15246.jp2* (DEM)	2011-08-24
LU__NAC_DTM_LINNECRATER_E280N0120__2463x14229.jp2* (DEM)	2011-08-24

Prethodne datoteke dostupne su preko sljedećih poveznica (FECDA.zip datoteka sadrži sve datoteke FECDA2011B DVD-a):
http://dora.zesoi.fer.hr/FECDA/FECDA.zip
http://dora.zesoi.fer.hr/FECDA/THM_DIR_256.bmp
http://dora.zesoi.fer.hr/FECDA/MDIM_256.bmp
http://dora.zesoi.fer.hr/FECDA/MOC_256.bmp
http://dora.zesoi.fer.hr/FECDA/LU_LALT_16.TXT
http://dora.zesoi.fer.hr/FECDA/LU_LALT_16.jp2
http://dora.zesoi.fer.hr/FECDA/LU_LDEM_64.jp2
http://dora.zesoi.fer.hr/FECDA/LU_LDEM_128.jp2
http://dora.zesoi.fer.hr/FECDA/LU_LDEM_256.jp2
http://dora.zesoi.fer.hr/FECDA/LU_LASGW_64.jp2
http://dora.zesoi.fer.hr/FECDA/LU_CLEMBASE_256.jp2
http://dora.zesoi.fer.hr/FECDA/LU_LOM_512.jp2
http://dora.zesoi.fer.hr/FECDA/MA_MOLA_DEMT_512.jp2
http://dora.zesoi.fer.hr/FECDA/PH_DEM1_4.jp2
http://dora.zesoi.fer.hr/FECDA/PH_BASEMAP1_16.jp2
http://dora.zesoi.fer.hr/FECDA/LU_LDEM_512.jp2
http://dora.zesoi.fer.hr/FECDA/VE_DEM1_32.jp2
http://dora.zesoi.fer.hr/FECDA/EA_DEM1_128.TXT
http://dora.zesoi.fer.hr/FECDA/EA_DEM1_128.jp2
http://dora.zesoi.fer.hr/FECDA/LU_LROC1_109164x54582.jp2
http://dora.zesoi.fer.hr/FECDA/LU_GDEM1_512.jp2
http://dora.zesoi.fer.hr/FECDA/LU_GDEM2_512.jp2
http://dora.zesoi.fer.hr/FECDA/LU_GOPT2_512.jp2
http://dora.zesoi.fer.hr/FECDA/PH_STOOKE1_14400x7200.jp2
http://dora.zesoi.fer.hr/FECDA/MA__H0905_0000_ND4__8248x65448.jp2
http://dora.zesoi.fer.hr/FECDA/MA__H0905_0000_DA4__2062x16362.jp2
http://dora.zesoi.fer.hr/FECDA/MA__DTEPC_001462_2630_001580_2630_U01__8589x8164.jp2
http://dora.zesoi.fer.hr/FECDA/MA__DTEEC_002118_1510_003608_1510_A01__7135x20409.jp2
http://dora.zesoi.fer.hr/FECDA/MA__DTEEC_014011_1315_014288_1315_A01__6225x15246.jp2
http://dora.zesoi.fer.hr/FECDA/LU__NAC_DTM_LINNECRATER_E280N0120__2463x14229.jp2
http://vinkovic.org/Projects/Craters/archive/MA__DTEPC_001462_2630_001580_2630_U01__8589x8164.jp2
http://vinkovic.org/Projects/Craters/archive/MA__DTEEC_002118_1510_003608_1510_A01__7135x20409.jp2
http://vinkovic.org/Projects/Craters/archive/MA__DTEEC_014011_1315_014288_1315_A01__6225x15246.jp2
http://vinkovic.org/Projects/Craters/archive/LU__NAC_DTM_LINNECRATER_E280N0120__2463x14229.jp2

Dodatne radne verzije datoteka navedene su u sljedećoj tablici. Datoteke od C0001_*.zip do C0005_*.zip koristile su kod objave preliminarnih rezultata na konferencijama i nisu bitne za reprodukciju rezultata prikazanih u ovome radu. Rezultati korišteni u ovome radu nalaze se u datotekama od C0006_*.zip do C0012_*.zip, kako je navedeno u prethodnoj i sljedećoj tablici. Rezultati se mogu reproducirati sljedećim koracima. Potrebno je računalo sa 64-bitnim operacijskim sustavom, 20 GB radne memorije i 8 CPU jezgri. U protivnom je reprodukcija rezultata još uvijek moguća u nekim slučajevima, ali vrijeme obrade može biti znatno duže. Također su potrebne aplikacije Kakadu 6.4.1 i GZIP 1.2.4. U prvom koraku, u neki direktorij treba prekopirati sve datoteke iz prethodne tablice, a potom iz sljedeće, te sve datoteke iz Topolyzer*_bins.zip arhive raspakirati u isti direktorij. U drugom koraku, treba se pokrenuti skripta scr_GenerateDEMsAndBMPs.bat, kako bi se generirale sve potrebne datoteke iz osnovnih datoteka. U trećem koraku treba prekopirati sve XML-ove i BAT-datoteke iz CratersData.zip, pa pokrenuti ili go_topolyzer.bat ili go_craters.bat. Prva opcija služi za korištenje CDA-ova iz već pripremljene izvršne datoteke Topolyzer.exe (kopija Topolyzer_80x64.exe inačice). Druga opcija služi za korištenje CDA-ova iz datoteke Craters.exe (kopija Craters_80x64.exe inačice), koja se može dobiti prevođenjem koda iz Craters5_81.zip, korištenjem *Visual Studio 8.0* (2005) kompajlera s opcijom generiranja 64-bitnog koda, a koja se nalazi i u Topolyzer5_81_bins.zip arhivi. Ako se koristi druga opcija, samo jednim dijelom se koristi Topolyzer aplikacija koja priprema digitalnu topografiju koja sadrži i laboratorijske kratere. Kod strojnog učenja dodatno je potrebno koristiti Topolyzer aplikaciju za pripremu značajki te obradu rezultata nakon pokretanja skripta koje pozivaju stroj s potpornim vektorima. Za vrednovanje CDA-ova, Topolyzer aplikacijom treba otvoriti XML datoteku koja sadrži katalog kratera, rezultat CDA-a, te XML datoteku s referentnim katalogom.

Tablica 9. Dodatne radne verzije datoteka (FECDA_draft).

ime diska / sadržaj	datum objave
C0009_GS_DVi_SL_DVu_MG_IP_MV_TH.zip (laboratorijski krateri)	2011-01-18
C0010_GS_SL.zip (rezultati CDA-a temeljenog na strojnom učenju)	2011-02-24
C0010_GS_SL_TrainPredict.zip (ručni koraci obrade rezultata strojnog učenja)	2011-02-25
C0011_GS_SL_PP_LB_JS.zip (Fobos)	2011-01-18
C0012_GS_SL.zip (Venera, Zemlja)	2011-03-26
LU64215GT.xml	2011-05-05
PH504GT.xml	2010-12-31
PH1102GT.xml	2011-05-04
VE345GT.xml	2011-03-30
EA24GT.xml	2011-03-30

Sljedeća tablica sadrži primjere skripta korištenih u implementaciji strojnog učenja, a koje se uz XML-ove također nalaze u CratersXml.zip datoteci. Značenja pojedinih parametara opisana su u dokumentaciji korištenih, LIBSVM i LIBLINEAR biblioteka (Lin, 2010).

Tablica 10. Skripte koje sadrže dio implementacije strojnog učenja koristeći stroj s potpornim vektorima.

ime	kod
R1	SvmTrain -h 0 -t 2 -c 38 -g 7 -b 1 ml_R_train_71.txt ml_R1_model_71.txt SvmPredict -b 1 ml_R_predict_72.txt ml_R1_model_71.txt ml_R_results_72.txt SvmTrain -h 0 -t 2 -c 38 -g 7 -b 1 ml_R_train_61.txt ml_R1_model_61.txt SvmPredict -b 1 ml_R_predict_62.txt ml_R1_model_61.txt ml_R_results_62.txt SvmTrain -h 0 -t 2 -c 38 -g 7 -b 1 ml_R_train_51.txt ml_R1_model_51.txt SvmPredict -b 1 ml_R_predict_52.txt ml_R1_model_51.txt ml_R_results_52.txt SvmTrain -h 0 -t 2 -c 38 -g 7 -b 1 ml_R_train_41.txt ml_R1_model_41.txt SvmPredict -b 1 ml_R_predict_42.txt ml_R1_model_41.txt ml_R_results_42.txt SvmTrain -h 0 -t 2 -c 38 -g 7 -b 1 ml_R_train_31.txt ml_R1_model_31.txt SvmPredict -b 1 ml_R_predict_32.txt ml_R1_model_31.txt ml_R_results_32.txt SvmTrain -h 0 -t 2 -c 38 -g 7 -b 1 ml_R_train_21.txt ml_R1_model_21.txt SvmPredict -b 1 ml_R_predict_22.txt ml_R1_model_21.txt ml_R_results_22.txt SvmTrain -h 0 -t 2 -c 38 -g 7 -b 1 ml_R_train_11.txt ml_R1_model_11.txt SvmPredict -b 1 ml_R_predict_12.txt ml_R1_model_11.txt ml_R_results_12.txt
R2	SvmTrain -h 0 -t 2 -c 38 -g 7 -b 1 ml_R_train_72.txt ml_R2_model_72.txt SvmPredict -b 1 ml_R_predict_71.txt ml_R2_model_72.txt ml_R_results_71.txt SvmTrain -h 0 -t 2 -c 38 -g 7 -b 1 ml_R_train_62.txt ml_R2_model_62.txt SvmPredict -b 1 ml_R_predict_61.txt ml_R2_model_62.txt ml_R_results_61.txt SvmTrain -h 0 -t 2 -c 38 -g 7 -b 1 ml_R_train_52.txt ml_R2_model_52.txt SvmPredict -b 1 ml_R_predict_51.txt ml_R2_model_52.txt ml_R_results_51.txt SvmTrain -h 0 -t 2 -c 38 -g 7 -b 1 ml_R_train_42.txt ml_R2_model_42.txt SvmPredict -b 1 ml_R_predict_41.txt ml_R2_model_42.txt ml_R_results_41.txt SvmTrain -h 0 -t 2 -c 38 -g 7 -b 1 ml_R_train_32.txt ml_R2_model_32.txt SvmPredict -b 1 ml_R_predict_31.txt ml_R2_model_32.txt ml_R_results_31.txt SvmTrain -h 0 -t 2 -c 38 -g 7 -b 1 ml_R_train_22.txt ml_R2_model_22.txt SvmPredict -b 1 ml_R_predict_21.txt ml_R2_model_22.txt ml_R_results_21.txt SvmTrain -h 0 -t 2 -c 38 -g 7 -b 1 ml_R_train_12.txt ml_R2_model_12.txt SvmPredict -b 1 ml_R_predict_11.txt ml_R2_model_12.txt ml_R_results_11.txt
S1	SvmLinearTrain -s 0 -c 5 ml_S_train_71.txt ml_S1_model_71.txt SvmLinearPredict -b 1 ml_S_predict_72.txt ml_S1_model_71.txt ml_S_results_72.txt SvmLinearTrain -s 0 -c 5 ml_S_train_61.txt ml_S1_model_61.txt SvmLinearPredict -b 1 ml_S_predict_62.txt ml_S1_model_61.txt ml_S_results_62.txt SvmLinearTrain -s 0 -c 5 ml_S_train_51.txt ml_S1_model_51.txt SvmLinearPredict -b 1 ml_S_predict_52.txt ml_S1_model_51.txt ml_S_results_52.txt SvmLinearTrain -s 0 -c 5 ml_S_train_41.txt ml_S1_model_41.txt SvmLinearPredict -b 1 ml_S_predict_42.txt ml_S1_model_41.txt ml_S_results_42.txt SvmLinearTrain -s 0 -c 5 ml_S_train_31.txt ml_S1_model_31.txt

	SvmLinearPredict -b 1 ml_S_predict_32.txt ml_S1_model_31.txt ml_S_results_32.txt SvmLinearTrain -s 0 -c 5 ml_S_train_21.txt ml_S1_model_21.txt SvmLinearPredict -b 1 ml_S_predict_22.txt ml_S1_model_21.txt ml_S_results_22.txt SvmLinearTrain -s 0 -c 5 ml_S_train_11.txt ml_S1_model_11.txt SvmLinearPredict -b 1 ml_S_predict_12.txt ml_S1_model_11.txt ml_S_results_12.txt
S2	SvmLinearTrain -s 0 -c 5 ml_S_train_72.txt ml_S2_model_72.txt SvmLinearPredict -b 1 ml_S_predict_71.txt ml_S2_model_72.txt ml_S_results_71.txt SvmLinearTrain -s 0 -c 5 ml_S_train_62.txt ml_S2_model_62.txt SvmLinearPredict -b 1 ml_S_predict_61.txt ml_S2_model_62.txt ml_S_results_61.txt SvmLinearTrain -s 0 -c 5 ml_S_train_52.txt ml_S2_model_52.txt SvmLinearPredict -b 1 ml_S_predict_51.txt ml_S2_model_52.txt ml_S_results_51.txt SvmLinearTrain -s 0 -c 5 ml_S_train_42.txt ml_S2_model_42.txt SvmLinearPredict -b 1 ml_S_predict_41.txt ml_S2_model_42.txt ml_S_results_41.txt SvmLinearTrain -s 0 -c 5 ml_S_train_32.txt ml_S2_model_32.txt SvmLinearPredict -b 1 ml_S_predict_31.txt ml_S2_model_32.txt ml_S_results_31.txt SvmLinearTrain -s 0 -c 5 ml_S_train_22.txt ml_S2_model_22.txt SvmLinearPredict -b 1 ml_S_predict_21.txt ml_S2_model_22.txt ml_S_results_21.txt SvmLinearTrain -s 0 -c 5 ml_S_train_12.txt ml_S2_model_12.txt SvmLinearPredict -b 1 ml_S_predict_11.txt ml_S2_model_12.txt ml_S_results_11.txt

Poveznice za datoteke koje su korištene u ovome radu za pripremu globalnih topografskih slika i optičkih mozaika, su:

DEMT64.img
http://pds-geosciences.wustl.edu/missions/mgs/megdr.html
http://pds-geosciences.wustl.edu/geodata/mgs-m-mola-5-megdr-l3-v1/mgsl_300x/meg064/megt90n000gb.img
http://pds-geosciences.wustl.edu/geodata/mgs-m-mola-5-megdr-l3-v1/mgsl_300x/meg064/megt90n180gb.img
http://pds-geosciences.wustl.edu/geodata/mgs-m-mola-5-megdr-l3-v1/mgsl_300x/meg064/megt00n000gb.img
http://pds-geosciences.wustl.edu/geodata/mgs-m-mola-5-megdr-l3-v1/mgsl_300x/meg064/megt00n180gb.img

DEMT128.img
http://pds-geosciences.wustl.edu/missions/mgs/megdr.html
http://pds-geosciences.wustl.edu/geodata/mgs-m-mola-5-megdr-l3-v1/mgsl_300x/meg128/megt88n000hb.img
http://pds-geosciences.wustl.edu/geodata/mgs-m-mola-5-megdr-l3-v1/mgsl_300x/meg128/megt88n090hb.img
http://pds-geosciences.wustl.edu/geodata/mgs-m-mola-5-megdr-l3-v1/mgsl_300x/meg128/megt88n180hb.img
http://pds-geosciences.wustl.edu/geodata/mgs-m-mola-5-megdr-l3-v1/mgsl_300x/meg128/megt88n270hb.img
http://pds-geosciences.wustl.edu/geodata/mgs-m-mola-5-megdr-l3-v1/mgsl_300x/meg128/megt44n000hb.img
http://pds-geosciences.wustl.edu/geodata/mgs-m-mola-5-megdr-l3-v1/mgsl_300x/meg128/megt44n090hb.img
http://pds-geosciences.wustl.edu/geodata/mgs-m-mola-5-megdr-l3-v1/mgsl_300x/meg128/megt44n180hb.img
http://pds-geosciences.wustl.edu/geodata/mgs-m-mola-5-megdr-l3-v1/mgsl_300x/meg128/megt44n270hb.img
http://pds-geosciences.wustl.edu/geodata/mgs-m-mola-5-megdr-l3-v1/mgsl_300x/meg128/megt00n000hb.img
http://pds-geosciences.wustl.edu/geodata/mgs-m-mola-5-megdr-l3-v1/mgsl_300x/meg128/megt00n090hb.img
http://pds-geosciences.wustl.edu/geodata/mgs-m-mola-5-megdr-l3-v1/mgsl_300x/meg128/megt00n180hb.img
http://pds-geosciences.wustl.edu/geodata/mgs-m-mola-5-megdr-l3-v1/mgsl_300x/meg128/megt00n270hb.img
http://pds-geosciences.wustl.edu/geodata/mgs-m-mola-5-megdr-l3-v1/mgsl_300x/meg128/megt44s000hb.img
http://pds-geosciences.wustl.edu/geodata/mgs-m-mola-5-megdr-l3-v1/mgsl_300x/meg128/megt44s090hb.img
http://pds-geosciences.wustl.edu/geodata/mgs-m-mola-5-megdr-l3-v1/mgsl_300x/meg128/megt44s180hb.img
http://pds-geosciences.wustl.edu/geodata/mgs-m-mola-5-megdr-l3-v1/mgsl_300x/meg128/megt44s270hb.img

THM_DIR_256.bmp
http://www.mars.asu.edu/data/thm_dir/
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-30_000.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-30_030.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-30_060.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-30_090.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-30_120.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-30_150.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-30_180.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-30_210.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-30_240.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-30_270.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-30_300.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-30_330.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-60_000.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-60_030.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-60_060.png

http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-60_090.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-60_120.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-60_150.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-60_180.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-60_210.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-60_240.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-60_270.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-60_300.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-60_330.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-90_000.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-90_030.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-90_060.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-90_090.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-90_120.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-90_150.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-90_180.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-90_210.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-90_240.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-90_270.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-90_300.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N-90_330.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N00_000.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N00_030.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N00_060.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N00_090.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N00_120.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N00_150.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N00_180.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N00_210.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N00_240.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N00_270.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N00_300.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N00_330.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N30_000.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N30_030.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N30_060.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N30_090.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N30_120.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N30_150.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N30_180.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N30_210.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N30_240.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N30_270.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N30_300.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N30_330.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N60_000.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N60_030.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N60_060.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N60_090.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N60_120.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N60_150.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N60_180.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N60_210.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N60_240.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N60_270.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N60_300.png
http://www.mars.asu.edu/data/thm_dir/large/thm_dir_N60_330.png

MDIM_256.bmp

http://astrogeology.usgs.gov/Projects/MDIM21/
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI15N023E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI15N068E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI15N113E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI15N158E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI15N203E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI15N248E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI15N293E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI15N338E.JPG

http://astrogeology.usgs.gov/Projects/MDIM21/data/MI15S023E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI15S068E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI15S113E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI15S158E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI15S203E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI15S248E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI15S293E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI15S338E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI48N030E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI48N090E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI48N150E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI48N210E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI48N270E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI48N330E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI48S030E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI48S090E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI48S150E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI48S210E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI48S270E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI48S330E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI70N180E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI70S180E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI83N180E.JPG
http://astrogeology.usgs.gov/Projects/MDIM21/data/MI83S180E.JPG

MOC_256.bmp
http://www.mars.asu.edu/data/moc_256/
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-30_000.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-30_030.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-30_060.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-30_090.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-30_120.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-30_150.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-30_180.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-30_210.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-30_240.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-30_270.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-30_300.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-30_330.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-60_000.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-60_030.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-60_060.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-60_090.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-60_120.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-60_150.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-60_180.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-60_210.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-60_240.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-60_270.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-60_300.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-60_330.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-90_000.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-90_030.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-90_060.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-90_090.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-90_120.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-90_150.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-90_180.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-90_210.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-90_240.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-90_270.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-90_300.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N-90_330.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N00_000.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N00_030.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N00_060.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N00_090.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N00_120.png

http://www.mars.asu.edu/data/moc_256/large/moc_256_N00_150.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N00_180.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N00_210.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N00_240.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N00_270.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N00_300.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N00_330.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N30_000.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N30_030.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N30_060.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N30_090.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N30_120.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N30_150.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N30_180.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N30_210.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N30_240.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N30_270.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N30_300.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N30_330.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N60_000.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N60_030.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N60_060.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N60_090.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N60_120.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N60_150.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N60_180.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N60_210.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N60_240.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N60_270.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N60_300.png
http://www.mars.asu.edu/data/moc_256/large/moc_256_N60_330.png

LU_LALT_16.jp2
http://www.jaxa.jp/policy_e.html
ftp.soac.selene.isas.jaxa.jp (potrebno ih je tražiti korisničko ime i zaporku)
LALT_GGT_MAP.sl2 (sadrži LALT_GGT_MAP.img)

LU_LDEM_64.jp2
http://imbrium.mit.edu/DATA/LOLA_GDR/LDEM_64.IMG

LU_LDEM_128.jp2
Osobna komunikacija s Erwanom Mazaricom; datoteka horizontalne rezolucije ~1/91°, uzorkovana u 1/128°.

LU_LDEM_256.jp2
http://imbrium.mit.edu/DATA/LOLA_GDR/CYLINDRICAL/IMG/LDEM_256_00N_90N_000_180.IMG
http://imbrium.mit.edu/DATA/LOLA_GDR/CYLINDRICAL/IMG/LDEM_256_00N_90N_180_360.IMG
http://imbrium.mit.edu/DATA/LOLA_GDR/CYLINDRICAL/IMG/LDEM_256_90S_00S_000_180.IMG
http://imbrium.mit.edu/DATA/LOLA_GDR/CYLINDRICAL/IMG/LDEM_256_90S_00S_180_360.IMG

LU_LASGW_64.jp2
http://webgis.wr.usgs.gov/pigwad/down/moon_airbrushed_shadedrelief_warp.htm
ftp://pdsimage2.wr.usgs.gov/pub/pigpen/moon/shaded_relief/lunarShade_ULCN2005_Warp/lunar_airbrushed_shadedrelief_global_warp.tif

LU_CLEMBASE_256.jp2
http://webgis.wr.usgs.gov/pigwad/down/moon_clementine_750nm_basemapV2.htm
ftp://pdsimage2.wr.usgs.gov/pub/pigpen/moon/clementine/UVVIS_ULCN2005_Basemap_v2/mosaic_256ppd/UVVIS_Clementine_Basemap_v2_ll.jp2

LU_LOM_512.jp2
http://nssdc.gsfc.nasa.gov/planetary/lunar/lunarorb.html
ftp://pdsimage2.wr.usgs.gov/pub/pigpen/moon/lunar_orbiter/Mosaics/LO_Global_Mosaic2_Mar08_lossy10.jp2

MA_MOLA_DEMT_512.jp2
Datoteka DEMT128.img, odnosno sve koje su se koristile za nju, uz dodatne datoteke:
ftp://pds-geosciences.wustl.edu/geo-ftp/mgs-m-mola-5-megdr-l3-v1/mgsl_300x/polar/megt_n_128_1.img
ftp://pds-geosciences.wustl.edu/geo-ftp/mgs-m-mola-5-megdr-l3-v1/mgsl_300x/polar/megt_s_128_1.img
ftp://pds-geosciences.wustl.edu/geo-ftp/mgs-m-mola-5-megdr-l3-v1/mgsl_300x/polar/megt_n_256_1.img
ftp://pds-geosciences.wustl.edu/geo-ftp/mgs-m-mola-5-megdr-l3-v1/mgsl_300x/polar/megt_s_256_1.img
ftp://pds-geosciences.wustl.edu/geo-ftp/mgs-m-mola-5-megdr-l3-v1/mgsl_300x/polar/megt_n_512_1.img
ftp://pds-geosciences.wustl.edu/geo-ftp/mgs-m-mola-5-megdr-l3-v1/mgsl_300x/polar/megt_s_512_1.img

PH_DEM1_4.jp2
http://europlanet.dlr.de/node/index.php?id=381
http://europlanet.dlr.de/node/fileadmin/pictures/hrsc/phobos/base_dtm_phobos.pds

PH_BASEMAP1_16.jp2
http://europlanet.dlr.de/node/index.php?id=381
http://europlanet.dlr.de/node/fileadmin/pictures/hrsc/phobos/base_map_phobos.tif

LU_LDEM_512.jp2
http://imbrium.mit.edu/DATA/LOLA_GDR/CYLINDRICAL/IMG/LDEM_512_00N_45N_000_090.IMG
http://imbrium.mit.edu/DATA/LOLA_GDR/CYLINDRICAL/IMG/LDEM_512_00N_45N_090_180.IMG
http://imbrium.mit.edu/DATA/LOLA_GDR/CYLINDRICAL/IMG/LDEM_512_00N_45N_180_270.IMG
http://imbrium.mit.edu/DATA/LOLA_GDR/CYLINDRICAL/IMG/LDEM_512_00N_45N_270_360.IMG
http://imbrium.mit.edu/DATA/LOLA_GDR/CYLINDRICAL/IMG/LDEM_512_45N_90N_000_090.IMG
http://imbrium.mit.edu/DATA/LOLA_GDR/CYLINDRICAL/IMG/LDEM_512_45N_90N_090_180.IMG
http://imbrium.mit.edu/DATA/LOLA_GDR/CYLINDRICAL/IMG/LDEM_512_45N_90N_180_270.IMG
http://imbrium.mit.edu/DATA/LOLA_GDR/CYLINDRICAL/IMG/LDEM_512_45N_90N_270_360.IMG
http://imbrium.mit.edu/DATA/LOLA_GDR/CYLINDRICAL/IMG/LDEM_512_45S_00S_000_090.IMG
http://imbrium.mit.edu/DATA/LOLA_GDR/CYLINDRICAL/IMG/LDEM_512_45S_00S_090_180.IMG
http://imbrium.mit.edu/DATA/LOLA_GDR/CYLINDRICAL/IMG/LDEM_512_45S_00S_180_270.IMG
http://imbrium.mit.edu/DATA/LOLA_GDR/CYLINDRICAL/IMG/LDEM_512_45S_00S_270_360.IMG
http://imbrium.mit.edu/DATA/LOLA_GDR/CYLINDRICAL/IMG/LDEM_512_90S_45S_000_090.IMG
http://imbrium.mit.edu/DATA/LOLA_GDR/CYLINDRICAL/IMG/LDEM_512_90S_45S_090_180.IMG
http://imbrium.mit.edu/DATA/LOLA_GDR/CYLINDRICAL/IMG/LDEM_512_90S_45S_180_270.IMG
http://imbrium.mit.edu/DATA/LOLA_GDR/CYLINDRICAL/IMG/LDEM_512_90S_45S_270_360.IMG

VE_DEM1_32.jp2
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f01.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f02.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f03.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f04.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f05.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f06.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f07.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f08.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f09.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f10.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f11.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f12.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f13.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f14.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f15.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f16.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f17.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f18.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f19.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f20.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f21.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f22.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f23.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f24.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f25.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f26.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f27.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f28.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f29.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f30.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f31.img
http://pds-geosciences.wustl.edu/geo/mgn-v-gxdr-v1/mg_3002/gtdr/sinus/f32.img

EA_DEM1_128.jp2
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/shared/webdownload_30secs
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/00N000E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/00N015E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/00N015W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/00N030E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/00N030W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/00N045E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/00N045W_BOTH_30S.ACE2.gz

http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/00N060E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/00N060W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/00N075E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/00N075W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/00N090E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/00N090W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/00N105E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/00N105W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/00N120E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/00N120W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/00N135E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/00N135W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/00N150E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/00N150W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/00N165E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/00N165W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/00N180W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15N000E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15N015E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15N015W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15N030E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15N030W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15N045E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15N045W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15N060E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15N060W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15N075E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15N075W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15N090E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15N090W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15N105E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15N105W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15N120E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15N120W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15N135E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15N135W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15N150E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15N150W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15N165E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15N165W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15N180W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15S000E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15S015E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15S015W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15S030E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15S030W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15S045E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15S045W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15S060E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15S060W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15S075E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15S075W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15S090E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15S090W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15S105E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15S105W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15S120E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15S120W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15S135E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15S135W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15S150E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15S150W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15S165E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15S165W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/15S180W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30N000E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30N015E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30N015W_BOTH_30S.ACE2.gz

http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30N030E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30N030W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30N045E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30N045W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30N060E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30N060W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30N075E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30N075W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30N090E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30N090W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30N105E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30N105W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30N120E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30N120W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30N135E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30N135W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30N150E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30N150W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30N165E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30N165W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30N180W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30S000E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30S015E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30S015W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30S030E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30S030W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30S045E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30S045W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30S060E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30S060W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30S075E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30S075W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30S090E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30S090W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30S105E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30S105W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30S120E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30S120W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30S135E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30S135W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30S150E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30S150W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30S165E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30S165W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/30S180W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45N000E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45N015E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45N015W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45N030E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45N030W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45N045E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45N045W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45N060E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45N060W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45N075E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45N075W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45N090E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45N090W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45N105E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45N105W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45N120E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45N120W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45N135E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45N135W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45N150E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45N150W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45N165E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45N165W_BOTH_30S.ACE2.gz

http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45N180W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45S000E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45S015E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45S015W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45S030E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45S030W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45S045E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45S045W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45S060E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45S060W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45S075E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45S075W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45S090E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45S090W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45S105E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45S105W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45S120E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45S120W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45S135E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45S135W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45S150E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45S150W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45S165E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45S165W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/45S180W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60N000E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60N015E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60N015W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60N030E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60N030W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60N045E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60N045W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60N060E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60N060W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60N075E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60N075W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60N090E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60N090W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60N105E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60N105W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60N120E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60N120W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60N135E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60N135W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60N150E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60N150W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60N165E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60N165W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60N180W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60S000E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60S015E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60S015W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60S030E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60S030W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60S045E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60S045W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60S060E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60S060W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60S075E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60S075W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60S090E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60S090W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60S105E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60S105W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60S120E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60S120W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60S135E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60S135W_BOTH_30S.ACE2.gz

http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60S150E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60S150W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60S165E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60S165W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/60S180W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75N000E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75N015E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75N015W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75N030E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75N030W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75N045E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75N045W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75N060E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75N060W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75N075E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75N075W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75N090E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75N090W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75N105E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75N105W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75N120E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75N120W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75N135E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75N135W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75N150E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75N150W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75N165E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75N165W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75N180W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75S000E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75S015E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75S015W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75S030E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75S030W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75S045E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75S045W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75S060E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75S060W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75S075E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75S075W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75S090E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75S090W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75S105E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75S105W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75S120E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75S120W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75S135E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75S135W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75S150E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75S150W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75S165E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75S165W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/75S180W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/90S000E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/90S015E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/90S015W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/90S030E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/90S030W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/90S045E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/90S045W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/90S060E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/90S060W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/90S075E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/90S075W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/90S090E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/90S090W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/90S105E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/90S105W_BOTH_30S.ACE2.gz

http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/90S120E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/90S120W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/90S135E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/90S135W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/90S150E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/90S150W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/90S165E_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/90S165W_BOTH_30S.ACE2.gz
http://tethys.eaprs.cse.dmu.ac.uk/ACE2/links/ACE2_30_SECONDS/ACE2_30S_BOTH/90S180W_BOTH_30S.ACE2.gz
-

ŽIVOTOPIS

Autor je rođen 6. srpnja 1972. u Karlovcu, Republici Hrvatskoj. Završetkom obrazovanja u Karlovačkoj gimnaziji, 1991. godine upisao je Elektrotehnički fakultet (sada Fakultet elektrotehnike i računarstva) Sveučilišta u Zagrebu. Za primjeran uspjeh na 2. godini studija dodijeljeno mu je priznanje *Josip Lončar*. Također mu je dodijeljena *Sveučilišna stipendija* za 4. godinu studija i *Stipendija Grada Zagreba* za 9. (posljednji) semestar studija. Zahvaljujući pokazanom uspjehu odobren mu je završetak studija s naglaskom na znanstveno-istraživačkom radu na programu *Zasnivanje pogonske sabirnice za prilagodljive obradne sustave*. Diplomirao je 5. veljače 1996. s izvrsnim uspjehom, na smjeru Industrijska elektronika. Zahvaljujući srednjoj ocjeni ispita 4.68 te pokazanim znanstveno-istraživačkim rezultatima, oslobođen je plaćanja poslijediplomskog znanstvenog magistarskog studija. Iste godine na Fakultetu elektrotehnike i računarstva, na Zavodu za elektroniku, mikroelektroniku, računalne i inteligentne sustave, upisuje poslijediplomski znanstveni magistarski studij, smjer Jezgra računarskih znanosti. Sve upisane ispite položio je s ocjenom izvrstan (5). Magistrirao je na području računarstva na istome fakultetu 20. lipnja 2000. godine, na temi *Modeliranje pristupa kolekcijama raznorodnih podataka unutar informacijske infrastrukture*. Zaposlen je na razvoju programske podrške više od 13 godina, prije u PELSYS d.o.o., a sada u AVL-AST d.o.o., u Zagrebu. Od 2002. godine predaje na Tehničkom veleučilištu u Zagrebu o objektno-orijentiranom razvoju programske podrške. Od 2003. godine volontira kao voditelj popisa članova Hrvatske Mense. Autor je (ili koautor) 7 znanstvenih publikacija u recenziranim međunarodnim časopisima indeksiranim u CC i SCIE, jednog poglavlja u knjizi, jednog patenta (“Sigurnosni anti-spam email protokol temeljen na javnoj/privatnoj/ pozivnoj email adresi.”, pat. br. US7617284 i HR-P20060241) i 50 znanstvenih publikacija u zbornicima konferencija. Njegovi radovi dosad su citirani u 41 znanstvenih radova, gdje on nije jedan od koautora. Član je IEEE-a (*Institute of Electrical and Electronics Engineers*), ACM-a (*Association for Computing Machinery*), AGU-a (*American Geophysical Union*), AAAS-a (*American Association for the Advancement of Science*) i Mense, te COSPAR-a (*Committee on Space Research*) i MEPAG-a (*Mars Exploration Program Analysis Group*).

BIOGRAPHY

The author was born in Karlovac, Croatia, on July 6th, 1972. After graduating from Karlovac high school in summer 1991, he enrolled the Faculty of Electrical Engineering and Computing – University of Zagreb. He received the *Josip Lončar Award* for outstanding academic success, as well as a *University of Zagreb Scholarship* and *City of Zagreb Scholarship* for the 4th year and 9th (last) semester respectively. Because of his high ranking, he was also granted a diploma assignment with scientific emphasis, with a thesis on *Field-bus modeling*. He received a degree in electrical engineering from the University of Zagreb, Faculty of Electrical Engineering and Computing, on 5th February 1996. Having an average grade during undergraduate studies of 4.68, he was also granted the *Faculty of Electrical Engineering and Computing Scholarship* for graduate studies (each year given to the five most promising students). He had an average grade during graduate studies of 5.00. He received an M.Sc. degree in computer science from the same institution on 20th June 2000, with a thesis on *Modeling of access to collections of heterogeneous data within information infrastructure*. He has been employed as a software developer for more then 13 years, first with PELSYS d.o.o., and now with AVL-AST d.o.o., Zagreb, Croatia. He has been teaching object-oriented software development at the Polytechnic of Zagreb, Croatia, since 2002. He has been volunteering as Membership Officer of Mensa Croatia, since 2003. He is the author (or co-author) of 7 scientific publications in peer-reviewed international journals, 1 book chapter, 1 patent ("Public/private/invitation email address based secure anti-spam email protocol.", Pat. No. US7617284 and HR-P20060241), and 50 scientific publications in conference proceedings. His work has been cited so far by 41 scientific publications wherein he is not one of coauthors. He is a member of IEEE (*Institute of Electrical and Electronics Engineers*), ACM (*Association for Computing Machinery*), AGU (*American Geophysical Union*), AAAS (*American Association for the Advancement of Science*) and Mensa. He is also an associate of COSPAR (*Committee on Space Research*) and MEPAG (*Mars Exploration Program Analysis Group*).