

## RAZVOJ ALATA ZA OBRADU I PRILAGODBU PODATAKA PRI IZRADI PRECIZNOG FORENZIČNOG 3D MODELA

Matija Mikac<sup>1</sup>, Zlatan Novak<sup>2</sup>

<sup>1</sup>Veleučilište u Varaždinu, Varaždin, Hrvatska

<sup>2</sup>Geo 3D d.o.o., Varaždin, Hrvatska

**Sažetak:** Prošlo je nekoliko godina od najveće vatrogasne tragedije u povijesti Hrvatske, tragedije u kojoj je život izgubilo 12 vatrogasaca. Taj je nesretni događaj objedinio velik broj stručnjaka iz najrazličitijih znanstvenih disciplina čiji je cilj bio rekonstrukcija događaja i otkrivanje istine te objašnjenje vatrenog fenomena koji je naglo iznenadio i opkolio vatrogasce na Velikom Kornatu. Za potrebe forenzične analize i izrade adekvatnog 3D modela korištene su najnovije tehnologije i metode prikupljanja i obrade prostornih podataka – članak opisuje korištene tehnologije uz naglasak na obradu i prilagodbu podataka koja je prethodila izradi 3D simulacijskog modela – za tu namjenu je razvijen autorski program Rasterizer koji se posebno opisuje u ovom članku. Konačan je 3D model predstavljao jedan od ključnih elemenata u daljnjem znanstvenom i praktičnom proučavanju požara.

**Ključne riječi:** 3D model, prikupljanje podataka, obrada i prilagodba, izrada simulacijskog modela, razvoj specijaliziranog softvera

**Abstract:** It has been few years since the biggest firefighter tragedy in the Croatian history took place. It was a tragedy in which twelve firefighters lost their lives. This unlucky event gathered a group of scientists from various fields of expertise in order to discover the truth of what really happened. In order to provide detailed forensic analysis and study of the event latest technologies and data collection methods were used – this article will give short overview of used technologies and coverage of data acquisition and adaptation process. For data processing and adaptation we developed application called Rasterizer, which is described in details. Final 3D model became the key element in further scientific and practical study of the fire phenomenon.

**Key words:** 3D model, data collection, data acquisition, model adaptation, specialized software development

### 1. UVOD

Najnovije tehnologije i metode prikupljanja geodetskih podataka svoju primjenu nalaze u mnogim znanstvenim i stručnim područjima. U ovom članku opisuje se dio multidisciplinarnog istraživanja vezanog uz rasvjetljavanje okolnosti i forenzičku analizu najveće

vatrogasne tragedije u povijesti Hrvatske, tragedije u kojoj je u kolovozu 2007. godine na Velikom Kornatu živote izgubilo 12 vatrogasaca.

Dio istraživanja koji se opisuje ovim člankom vezan je uz geodetska mjerenja i prikupljanje detaljnih i preciznih podataka za izradu 3D modela opečarenog područja, uz naglasak na razvoj alata za prilagodbu podataka za potrebe simulacije meteoroloških uvjeta.

U prvom poglavlju se opisuje postupak i oprema korištena u izvedbi samih mjerenja, te se kvantitativno opisuju podaci dobiveni mjerenjem. U drugom poglavlju se razmatraju postupci korišteni u prilagodbi podataka za različite namjene kao i nemogućnosti brze izvedbe nekih specifičnih adaptacija što je u konačnici potaklo razvoj alata za prilagodbu. Treće poglavlje opisuje razvijeni alat i implementirane funkcionalnosti. U četvrtom poglavlju se prikazuju i komentiraju konkretni rezultati prilagodbe.

Kroz praktičnu izvedbu alata za prilagodbu podataka mjerenja su dobila dodatnu vrijednost omogućivši direktno korištenje mjerenih podataka u simulacijama meteoroloških uvjeta što je predstavljalo bitan korak u razjašnjenju mogućih okolnosti koje su dovele do tragedije. Iako je alat razvijen za potrebe konkretne primjene, dodavanjem određenih funkcija postaje univerzalno rješenje koje se često koristi i u drugim projektima mjerenja i prikupljanja geodetskih podataka.

### 2. MJERENJA I PRIKUPLJANJE PODATAKA

Korištenjem tradicionalnih geodetskih postupaka, prekrivanje i obrada predmetnog područja zbog karakteristika terena i potrebe detaljnog snimanja bilo bi gotovo neizvedivo u nekom kraćem vremenskom razdoblju. Stoga je za snimanje terena odabrana najnovija tehnologija laserskog skeniranja terena korištenjem ILRIS-3D skenera kanadske tvrtke *Optech*. Karakteristike takvog skenera u potpunosti zadovoljavaju (čak i premašuju) sve zahtjeve po pitanju preciznosti i brzine skeniranja.

*Optech* ILRIS 3D skener može se pohvaliti širinom svoje primjene. Ono po čemu se razlikuje od ostalih jest modularnost i upotreba lasera klase 1. Takav je laser u potpunosti siguran za ljudsko oko pri svim načinima rada te ima najveći dinamički raspon dometa, pa tako omogućuje prikupljanje prostornih podataka od 3 m do

1500 m. U osnovnoj izvedbi doomet mu iznosi približno 800m dok se upotrebom hardverskog dodatka ER (*enhanced range*) doomet može povećati i do 40%. Ta ga mogućnost svrstava u terestričke skenere najvećeg dometa.



Slika 1. Optech ILRIS postavljen na lokaciji

Kod njegove primjene na konkretnom zadatku skeniranja dijela Velikog Kornata do izražaja je došla i njegova otpornost na ekstremne meteorološke i terenske uvjete. Robusna i kvalitetna hardverska izvedba omogućuje realizaciju projekata i pri najekstremnijim vremenskim uvjetima.



Slika 2. GPS bazna stanica


Zbog specifičnosti i važnosti zadatka terenska je priprema zahtijevala višestruko osiguranje kod odabira geodetske opreme. Uz laserski skener i pripadajuću

opremu korištena su i dva dvofrekvencijska GPS/GLONASS prijavnika iz *Topcon Hiper* serije. Za precizno određivanje koordinata karakterističnih točaka korištena je GPS RTK metoda (kinematika u stvarnom vremenu). Iako je GPRS vezom za prijem korekcijskih parametara bila dostupna permanentna stanica u Zadru, istovremeno je postavljena i bazna stanica na obali uvale Šipnate. Korištena je službena točka geodetske osnove (P16).

## 2.1. Prikupljeni podaci


Obzirom na težak teren postupak snimanja je bio usporen, no rezultati su ipak zadivljujući – tijekom jednog dana na terenu snimljeno je područje površine 50ha, pri čemu je izmjereno više od 20 milijuna točaka. Korišteno je šest stajališta – točaka na koje je postavljen skener.

Slika 3 prikazuje kompletni 3D model snimljenih podataka – posebno su označene točke stajališta na kojima je postavljan skener. Skener obavlja panoramsko snimanje u 360°, a obzirom da su za precizno georeferenciranje potrebne bar tri koordinate, na slici prikazano područje je potpuno georeferencirano i snimljeno.



Slika 3. Kompletni 3D model i stajališta

Velika gustoća izmjerenih točaka omogućila je vjerodostojno modeliranje i najmanjih prepoznatljivih objekata u prostoru. Cjelokupni je model u konačnici prezentiran u jedinstvenom apsolutnom HDKS koordinatnom sustavu. Preciznost mjerenja najbolje je vidljiva pri usporedbi sa fotografijom predmetne lokacije, kao što prikazuje slika 4.



Slika 4. Predmetna lokacija – vizualna usporedba modela i fotografije

## 2.2. Prilagodba podataka

Podaci dobiveni mjerenjem uključuju lokalne koordinate ( $x, y, z$ ) obzirom na aktualno stajalište skenera. Da bi se ti "sirovi podaci" pretvorili u 3D model područja potrebno je kao predradnje provesti osnovni postupak poravnavanja i georeferenciranja.

Obzirom da je više neovisnih znanstvenih disciplina izrazilo potrebu za podacima prikupljenim 3D laserskim skeniranjem, sama je obrada zahtijevala različit tijek i završnu prilagodbu izlaznog formata. U konačnici se 3D model pokazao kao višenamjenski referentni model za više neovisnih istraživanja [1].

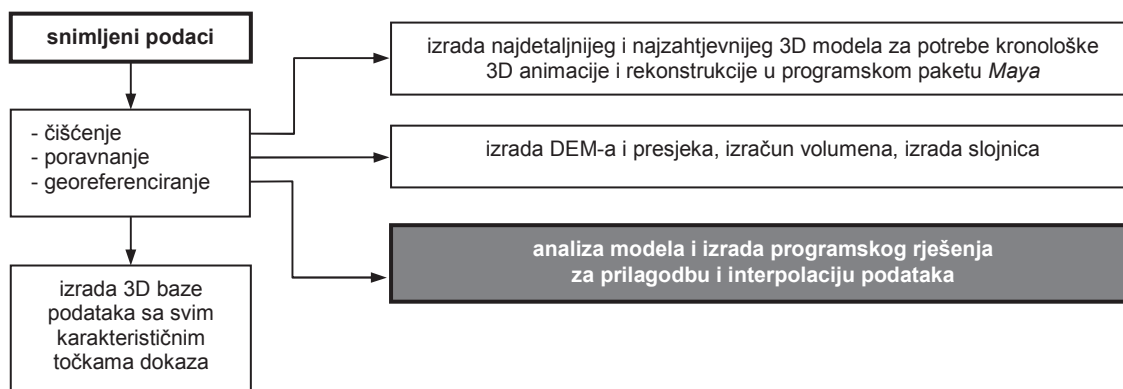
Za potrebe izrade 3D animacije i forenzične rekonstrukcije (veći dio odrađen u programskom paketu *Maya*) izrađen je vrlo detaljan (informacijama najbogatiji i podatkovno najzahtjevniji) 3D model.

Za potrebe geodetskih mjerenja i obrade podaci su dodatno obrađivani kako bi se dobio visinski prikaz u boji (DEM – *Digital Elevation Model*), odredili presjeci, izračunao volumen i definirale slojnice.

U terenskom dijelu prikupljanja podataka, istovremeno sa skeniranjem u apsolutnom koordinatnom sustavu pohranjivale su se i precizne pozicije različitih karakterističnih dokaza i ostalih važnih pozicija. Na cijelom je predmetnom području GPS/GLONASS RTK metodom dodatno određeno i približno sto karakterističnih točaka, što se iskoristilo u daljnjoj obradi i provjeri točnosti georeferenciranja.

Prikupljeni podaci objedinjeni su u bazu podataka – baza uključuje sve podatke o snimljenim točkama, uključujući sve karakteristične točke dokaza. Proučavajući okolinu točaka izmjerenih RTK metodom na spojenom jedinstvenom i georeferenciranom 3D modelu, utvrđeno je da nije bilo odstupanja većeg od 3 cm što govori u prilog visokoj preciznosti laserskog skeniranja.

Naglasak u ovom članku se stavlja na izradu autorskog programskog rješenja za prilagodbu podataka za potrebe simulacije meteoroloških uvjeta, kao što je naznačeno na slici 5.

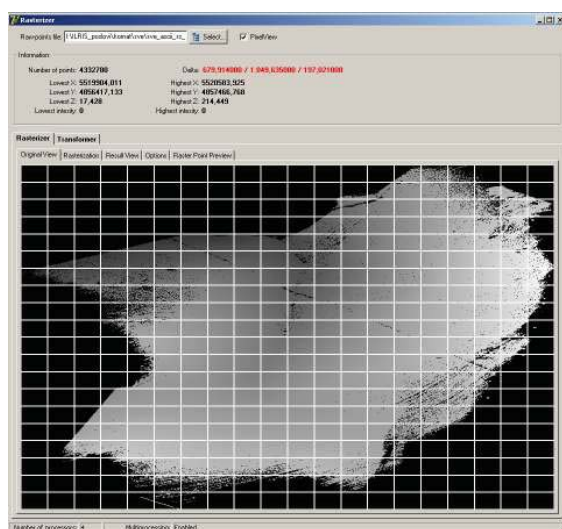


Slika 5. Faze obrade i prilagodbe podataka dobivenih 3D skeniranjem

### 3. ALAT ZA OBRADU I PRILAGODBU PODATAKA

Prema zahtjevima definiranim za simulacijske modele meteoroloških uvjeta – simuliranje strujanja zraka u programskom paketu *Fluent*, bilo je potrebno reducirati veliki broj točaka i interpolirati ih na način da razmak u XY ravnini bude konstantan i iznosi 0.5 m. Nadalje, tu je istu interpoliranu mrežu točaka trebalo zarotirati pod određenim kutom.

Ovaj naizgled jednostavan zadatak predstavlja problem u trenutku kada u kratkom vremenskom periodu treba interpolirati vrlo veliku količinu podataka. Postoji više programa za takvu interpolaciju oblaka točaka. Grafički programi već kod ulaznih datoteka od nekoliko milijuna točaka zahtijevaju veliku količinu radne memorije i velike procesorske resurse za izvođenje takvih operacija. Najboljim rješenjem za konkretni slučaj (više od četiri milijuna točaka) se pokazala samostalna implementacija numeričke interpolacije i adaptacije, odnosno razvoj alata *Rasterizer*. Nakon uspješnih testiranja i implementacije traženih funkcija, alat je omogućio realizaciju svih operacija – podaci o točkama su u program uvođeni korištenjem najobičnije tekstualne datoteke, a na isti način su i snimani rezultati.



Slika 6. Sučelje programa *Rasterizer* – plošni prikaz podataka i kvadranti/sektori za obradu

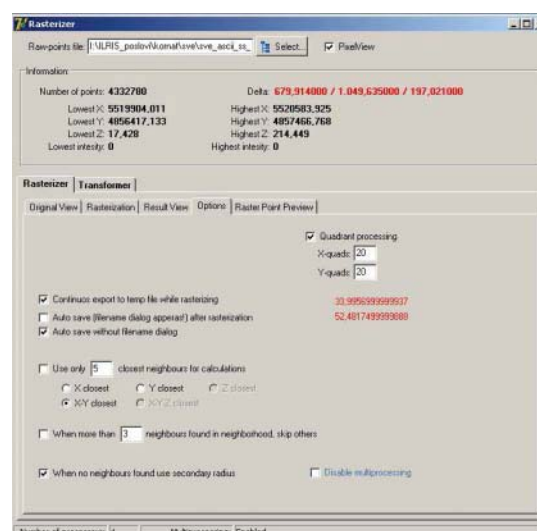
U programskom jeziku Delphi implementirano je programsko rješenje čiji je razvoj prvenstveno bio usmjeren prema jednostavnom i brzom interpoliranju oblaka točaka pod određenim uvjetima. Naknadno su dodane i funkcije reduciranja koordinata, rotiranja XY ravnine za proizvoljne kuteve, uvođenja odabira polja kvadrata (sektorizacija) za brže i paralelno izvođenje pretraživanja okoline, te razne mogućnosti odabira načina i parametara obrade i definiranja veličine okoline za ispitivanje i izračun. Promjenama tih parametara lako je realizirati i neke od već poznatih metoda obrade oblaka točaka kao što su „*smoothing*“, tj. izgladivanje modela povećanjem okoline točaka za interpolaciju, i slično. Upotrijebljen je i kod za iskoristivost više

procesorskih jezgri (JIBU biblioteka), te je u konačnici obrada višemilijunskih skupova točaka upotrebom procesora s dvije ili četiri procesorske jezgre trajala svega nekoliko minuta (drastično i gotovo nevjerojatno poboljšanje performansi u odnosu na prve razvojne inačice kod kojih je vrijeme obrade mjereno u satima).

Za tako velike modele čak i jednostavne radnje, poput zamjene stupaca koordinata, predstavljaju problem u svim programima općih namjena, pa su u razvijano programsko rješenje uključene manipulativne funkcije koje bez problema rješavaju i takve operacije (modul *Transformer*).

Korisničko sučelje alata *Rasterizer* je rudimentarno – osim učitavanja ulaznih modela realiziran je i plošni prikaz modela ( $z$  koordinata, odnosno visina točke, se koristi za definiranje intenziteta boje) – slika 6. U slučaju korištenja sektorizacije za ubrzanje obrade iscrtavaju se i kvadranti po kojima se obavlja obrada. Rezultati obrade se također grafički prikazuju (u realnom vremenu – iscrtavanje ovisno o stanju obrade).

Postavke i parametre koji utječu na izvođenje postavljaju se direktno kroz korisničko sučelje (slika 7).



Slika 7. *Rasterizer* – podešavanje postavki

#### 3.1. Postupak obrade


Obzirom na strukturu ulaznih podataka osnovna obrada se provodi u tri koraka.

Prilikom učitavanja podataka obavlja se primarna analiza i određuju rubovi područja – temeljem toga moguće je odrediti, sukladno definiranim početnim uvjetima, pozicije budućih interpoliranih točaka. Ukoliko se koristi modul za manipulaciju i transformaciju podataka (zamjena stupaca, "pomak" podataka o koordinatama i slično), većina operacija se provodi u prvom koraku obrade.

U drugom koraku obavlja se (ukoliko je definirano postavkama programa) sektorizacija snimljenih točaka – raspodjela i grupiranje točaka po kvadrantima kako bi se u završnom koraku obrade procesiranje raspodijelilo (paralelna obrada). Ovisno o definiranim uvjetima za određivanje okoline (kvadratna ili kružna okolina proizvoljnih dimenzija) prilikom raspodjele točaka

uključene su i rubne točke susjednih sektora (preklapanje). U istom koraku se određuje izlazni raster, odnosno raspored traženih rezultatnih točaka – nad njima se također provodi sektorizacija kako bi se u završnoj fazi dodatno ubrzala obrada i eliminirala nepotrebna pretraživanja.

Tijekom razvoja programskog rješenja, algoritmi za sektorizaciju su drastično ubrzani – u prvoj inačici, selekciji i određivanju pripadnosti točaka kvadrantima je prethodilo definiranje kvadranta i potom standardno pretraživanje skupa točaka i raspoređivanje u ciljane kvadrate. To rješenje se pokazalo zadovoljavajućim i njegovim korištenjem je izveden glavni dio projekta – no, složenost izvođenja tog postupka je ovisila o veličini skupa ulaznih točaka ( $N_U$ ), veličini skupa rezultatnih točaka ( $N_I$ , očekivani broj točaka u rasteru), te broju kvadranta korištenih u obradi,  $S$ . Složenost izvođenja mogla bi se zapisati kao  $o(N_U+N_I) \cdot S$ , s tim da kad su  $N_U$  i  $N_I$  usporedivi možemo govoriti o očekivanoj složenosti  $O(N \cdot S)$ , gdje  $N$  označava veličinu skupa analiziranih točaka – u konkretnom slučaju, nekoliko milijuna točaka. Daljnjim razvojem algoritma, ta "slabost" je eliminirana implementacijom novog rješenja po kojem je složenost postupka sektorizacije svedena na  $O(N)$ , odnosno eliminira je direktna ovisnost o broju kvadranta. U drugoj inačici algoritma za sektorizaciju preskočeno je pretraživanje definiranih kvadranta jer je iskorišteno svojstvo njihove pravokutnosti i mogućnost direktnog određivanja ciljanog kvadranta temeljem koordinata analizirane točke i ostalih poznatih parametara (koordinate rubova snimljenog područja, broj i raspored kvadranta).




Slika 8. Rezultanti raster (obrađeno) bez rotacije

Utjecaj složenosti algoritma sektorizacije na manjim testiranim snimkama nije značajan, te oba algoritma na takvim modelima daju rezultate u podjednakom vremenu. Međutim, u stvarnim slučajevima, kao što je kompletna snimka analiziranog područja, uz korištenje velikog broja sektora radi brže rasterizacije, uočava se drastično poboljšanje rezultata, što će biti dodatno naznačeno u odjeljku s rezultatima.

U završnom koraku obrade, obzirom na mogućnost neovisne obrade pojedinih sektora, definiraju se odvojeni procesi i provodi neovisna rasterizacija za svaki pojedini sektor/kvadrant. Pod pojmom rasterizacije smatra se postupak određivanja (interpolacije) traženih parametara za definirane točke u rezultatnom rasteru. Sam algoritam određivanja rezultatne vrijednosti (visine, intenziteta...) svodi se na različite modele proračuna i usrednjavanje ovisno o okolini.

Budući da se ulazni podaci ne mijenjaju tijekom obrade, radi se o idealnom slučaju za primjenu paralelne obrade podataka – obrada je izvedena korištenjem dretvi (*thread*) na jednoprocorskim računalima odnosno korištenjem višeprocorsne obrade na višeprocorskim računalima – paralelna obrada podržana je korištenjem JIBU biblioteke [2] za Delphi programski jezik.



Slika 9. Rezultanti raster (obrađeno) uz rotaciju 13°

Za vrijeme provođenja završne faze obrade, rezultati se pohranjuju u izlaznu datoteku jednostavnog tekstualnog formata, uz istovremeno osvježavanje plošnog prikaza rezultatnog skupa točaka. Primjeri obrađenih rezultata dani su na slikama 8 i 9 – na slici 9 osnovni raster je zarotiran (standardni parametar obrade) u skladu sa zahtjevima simulacijskog sustava.

### 3.2. Parametri obrade

Sam postupak obrade podataka izveden je tako da omogućava definiranje raznih parametara koji utječu na rezultate – algoritmi koji se primjenjuju u obradi definirane parametre koriste u drugom i trećem koraku (opisani u prethodnom odjeljku) postupka. Parametri koje je moguće definirati kroz korisničko sučelje su:

- veličina rastera u XY ravnini
- sektorizacija - broj sektora (horizontalno i vertikalno u mjerenom području)
- kut zakretanja rezultatnog rastera
- oblik okoline pretraživanja (kvadrat, krug)
- dimenzija primarne okoline pretraživanja
- dimenzija sekundarne okoline pretraživanja
- uvjeti određivanja rezultatne vrijednosti
- alternativni algoritam sektorizacije

Prvi korak postupka obrade uključuje dohvata originalnih podataka i osnovnu analizu ulaznih točaka – određuje se veličina ulaznog područja i raspon snimljenih vrijednosti. Kombiniranjem ulaznih informacija i parametara obrade, program nakon dohvata podataka može odrediti očekivani broj i točne pozicije rezultatnih točaka (raster u XY ravnini – na poziciju točaka moguće je utjecati veličinom rastera (udaljenost izlaznih točaka) kao i kutem rotacije rezultatnog rastera).

Drugi korak uključuje provođenje sektorizacije – osim određivanja kvadranta, sve ulazne i sve očekivane rezultatne točke se raspoređuju po kvadrantima kako bi se kako bi se pripremila izvedba paralelne obrade, bez naknadnog pretraživanja originalnih podataka. Kao što je u prethodnom odjeljku opisano, implementirana su dva algoritma za sektorizaciju – jedan baziran na detaljnom i sporom pretraživanju, a drugi na direktnom određivanju kvadranta temeljem koordinata točke.

Reimplementacijom algoritma, kako će biti prikazano u odjeljku s rezultatima, brzina obrade se dodatno povećala i za kompletnu projektnu snimku je potrebno manje od minutu vremena na dvoprocorskom računalu za obradu za koju je u samom izvedbenom dijelu projekta trebalo više minuta na četveroprocorskom sustavu.

Završna faza postupka uključuje provođenje analize okoline za svaku točku (uz mogućnost paralelne izvedbe po sektorima). Ovisno o parametrima koji definiraju način određivanja rezultatne vrijednosti za ciljane točke, provode se različiti postupci – moguće je usrednjavanje na razini cijele okoline, usrednjavanje korištenjem  $N$  najbližih točaka i sl. Ukoliko u originalnim podacima postoji vrijednost snimljena za poziciju izlazne točke, istu je moguće direktno preuzeti ili (opcija) ipak provesti postupak usrednjavanja. Isto tako, jedan od parametara obrade jest i mogućnost korištenja dvije okoline pretraživanja – primarne (uže područje) i sekundarne (šire područje), pri čemu se sekundarna okolina koristi samo u slučajevima kad u primarnoj ne postoji dovoljno ili nema uopće pronađenih susjednih točaka.

#### 4. REZULTATI PRILAGODBE

Rezultati dobiveni razvijenim programom predstavljaju ulazne podatke za simulacijske algoritme vezane uz analizu meteoroloških uvjeta koji se izvode u simulacijskom sustavu *Fluent*. Obzirom da su dobiveni rezultati provjereni u praksi (usporedbom s originalnim podacima i analizom odstupanja, usporedbom s rezultatima dobivenim bez sektorizacije i paralelne obrade) i da je potvrđena njihova ispravnost, ne ulazi se u kvalitativnu analizu samih rezultata već se tablično prikazuju rezultati mjerenja izvođenja implementiranih algoritama kako bi se ukazalo na prednosti paralelne obrade i zadovoljavajuću brzinu obrade. Uz tablice su navedeni fiksni parametri -  $N_U$  sadrži broj ulaznih točaka (točke originalne snimke terena),  $N_I$  očekivani broj izlaznih točaka (rezultatni raster),  $C$  veličinu ulazne (tekstualne) datoteke, a  $T_A$  prosječno vrijeme potrebno za učitavanje i određivanje rubova područja (trajanje prvog koraka obrade). U stupcu  $S$  dan je ulazni parametar – broj sektora (horizontalni i vertikalni – stvarne dimenzije

samog sektora, naravno, ovisno o dimenziji analiziranog područja). Stupci  $N$  i  $T$  prikazuju rezultate obrade –  $N$  daje broj rezultatnih točaka (primijetiti da je taj broj u pravilu manji od  $N_I$  – kod stvarnih mjerenja rubovi područja nisu pravilni, pa program određene točke eliminira iz rezultata jer u njihovoj okolini ne pronalazi snimljene točke), a  $T$  vrijeme potrebno za obradu i generiranje rezultatnog rastera.

Kut zakretanja rastera nema značajan utjecaj na vrijeme obrade obzirom da se u prvoj fazi obrade generiraju pozicije rezultatnih točaka sukladno dimenziji snimke i definiranom kutu zakretanja.

Broj izlaznih točaka ( $N_I$ ), direktno je ovisan o snimci – program određuje broj točaka temeljem definiranih parametara obrade – veličini rastera u XY ravnini (udaljenost rezultatnih točaka), te je jasno da je broj točaka veći ukoliko je snimljeno područje veće, odnosno ukoliko je raster manji (manja udaljenost točaka)... Konačni broj rezultatnih točaka ( $N$ ) je u pravilu manji od  $N_I$ , osim u slučajevima kad su snimke homogene i rubovi snimljenih područja pravilni. Također, treba primijetiti da algoritmi uz različit broj sektora vraćaju različit broj konačnih točaka – uzrok leži u rubovima kvadranta. Bez obzira na to, odstupanja u broju rezultatnih točaka su ispod 1%.

Tablica 1. Rezultati obrade kompletne snimke

$$N_U = 4.332.780 \quad N_I = 2.852.541$$


$$C = 141.899 \text{ kB} \quad T_A = 9.3 \text{ s}$$

| $N$     | $S$             | $T$ (min) |
|---------|-----------------|-----------|
| 1265082 | 400 (20×20)     | 12:30     |
| 1265345 | 900 (30×30)     | 05:29     |
| 1265324 | 1600 (40×40)    | 03:20     |
| 1264981 | 3600 (60×60)    | 01:44     |
| 1264360 | 6400 (80×80)    | 01:15     |
| 1265210 | 10000 (100×100) | 01:00     |

\*Intel T4300, 4GB RAM

Rezultati u tablici 1 dobiveni su ubrzanom algoritmom sektorizacije (složenost  $O(N_U)$ ) i ukazuju na sve prednosti korištenja kvadranta i paralelne obrade podataka. Daljnjim povećanjem broja kvadranta, na istom testnom računalu brzina obrade je još povećana i postignut je neki limit prema kom konvergiraju svi testirani slučajevi ( $S$  120, 140, 200 i 300), odnosno minimalno trajanje obrade 00:44 (44 sekunde). Očito je da nije moguće bolje iskorištenje dostupne procesorske moći.

Prednost sektorizacije i paralelne obrade vidljiva je i iz grafikona na slici 10. Jasno je uočljiv padajući trend i konvergencija vremena obrade s povećanjem broja sektora kod korištenja ubrzanog algoritma sektorizacije ( $v_2$  na grafikonu). Na istom grafikonu su prikazana i izmjerena vremena obrade uz korištenje prve inačice sektorizacijskog algoritma (sporiji pretraživački algoritam,  $v_1$  na grafikonu) – vidljivo je ubrzanje u odnosu na test s najmanjim brojem kvadranta, no nakon dostizanja nekog graničnog vremena (gotovo 5 minuta za  $80 \times 80$  kvadranta, što je 4 puta slabiji rezultat od bržeg algoritma) javlja se dodatno usporenje.



Slika 10. Brzina obrade i broj kvadrana

Naravno da povećanje broja kvadrana ne može ići u beskonačnost jer osim limitirane procesorske moći postoje i drugi ograničavajući parametri – pozicije i gustoća rezultantnih točaka su precizno definirane (na projektnom primjeru 0.5m horizontalni i vertikalni razmak između točaka), a isto tako su definirane i okoline pretraživanja (0.5m za primarnu okolinu, odnosno 0.8m za sekundarnu). U trenutku kad dimenzije kvadrana postanu usporedive s tim parametrima dolazi do degradacije rezultata i nemogućnosti provođenja kvalitetnog postupka prilagodbe i obrade podataka.

Najbolji rezultat dobiven na testnoj mreži, ostvaren na računalu s višeprocorskim *Intel i5* procesorom i 4GB radne memorije je 27 sekundi za kompletnu obradu (uz 200x200 kvadrana), što je i više nego prihvatljivo.

Analiza utjecaja odnosa postavljenih parametara i veličine obrađivanog područja na brzinu obrade i rezultate se u ovom članku posebno ne obrađuje – cilj članka je iznijeti probleme, te ukratko izložiti prijedlog rješenja, dati kratki opis implementacije i cijeli postupak potkrijepiti rezultatima provjerenim u praksi. Izneseni rezultati zorno prikazuju da je problem prilagodbe podataka riješen na zadovoljavajući način (dovoljno brzo i precizno), a ostali rezultati konkretnog projekta (simulacija meteoroloških uvjeta temeljena na dobivenom modelu) potvrđuju i kvalitetu i ispravnost samog postupka.

## 5. ZAKLJUČAK

Konkretni slučaj primjene najnovijih tehnologija i metoda prikupljanja geodetskih podataka opisan u članku ukazuje na ogromne mogućnosti i prednosti koje takve tehnologije nude. Provedena multidisciplinarna istraživanja baziraju se na snimkama terena i upravo su kvaliteta i preciznost mjerenja omogućile razne analize koje su pomogle u rasvjetljavanju samog događaja.

Za potrebe specifičnih simulacija meteoroloških uvjeta postojala je potreba za prilagodbom snimljenih podataka – obzirom da dostupni profesionalni alati korišteni za obradu snimaka nemaju mogućnosti manipulacije

podacima na način koji se zahtijevao u realizaciji projekta, donesena je odluka o samostalnom razvoju programa kojim su tražene transformacije i prilagodbe realizirane. Pokazalo se da je razvijeno autorsko programsko rješenje, *Rasterizer*, omogućilo brzu i efikasnu obradu podataka, a dodavanjem funkcionalnosti nevezanih uz konkretni projekt, program je dobio na univerzalnosti te se koristi i za druge svrhe.

## 6. LITERATURA

- [1] Novak Z., (2008), "Primjena 3D laserskog skenera i izrada preciznog 3D modela dijela otoka Veliki Kornat", *Zbornik radova 1. Simpozija ovlaštenih inženjera geodezije*, 140-152
- [2] [http://www.codeproject.com/KB/showcase/axon7\\_jib\\_u.aspx](http://www.codeproject.com/KB/showcase/axon7_jib_u.aspx) - JIBU biblioteka

### Kontakti:

mr.sc. Matija Mikac, dipl.ing. elektrotehnike

- Veleučilište u Varaždinu,
- e-mail: matija.mikac@velv.hr

Zlatan Novak, dipl.ing. geodezije

- Geo 3D d.o.o., Varaždin,
- e-mail: zlatan.novak@geo3d.hr