Sustav za automatsku detekciju meteora

Vida, Denis

Master's thesis / Diplomski rad

2016

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:200:163867

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

Repository / Repozitorij:

Faculty of Electrical Engineering, Computer Science and Information Technology Osijek

zir.nsk.hr

Image not found or type unknown

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA

Sveučilišni studij

SUSTAV ZA AUTOMATSKU DETEKCIJU METEORA

Diplomski rad

Denis Vida

Osijek, 2016.

SADRŽAJ

1. UVOD 1
1.1. Zadatak diplomskog rada 2
1.2. Uvod u meteorsku znanost 3
1.3. Tehnike promatranja meteora 7
2. POSTOJEĆA PROGRAMSKA RJEŠENJA ZA VIDEO-PROMATRANJE METEORA 9
2.1. SonotaCo UFOcapture 9
2.2. MetRec 10
2.3. MeteorScan 12
3. HRVATSKA METEORSKA MREŽA 14
3.1. Programska rješenja korištena unutar HMM-a 15
3.2. Znanstveni uspjesi HMM-a 16
3.3. Križevački meteorit 16
3.4. Korištenje minijaturnih računala za svrhu snimanja meteora 18
4. PREGLED RAZVIJENOG PROGRAMSKOG RJEŠENJA 20
5. KOMPRIMIRANJE SNIMAKA S METEORSKE KAMERE 22
5.1. Problemi komprimiranih snimaka 23
6. POSTUPAK DETEKCIJE VATRENIH KUGLI 25
6.1. Binarizacija slike 25
6.2. *Subsampling* binarizirane snimke 26
6.3. Postupak detekcije vatrenih kugli na 3D oblaku točaka 27
7. POSTUPAK DETEKCIJE METEORA 28
7.1. Predobradba snimke meteora 28
7.2. Kernel-based Hough Transform 31
7.3. Detekcija linija na slici 33
7.4. Provjera vremenske propagacije detektiranih linija 34
7.5. Određivanje centroida meteora 35

7.6. Rezultati postupka detekcije meteora 36
8. POSTUPAK DETEKCIJE ZVIJEZDA 39
8.1. Rezultati postupka detekcije zvijezda 40
9. PROCEDURE ASTROMETRIJE I FOTOMETRIJE 42
9.1. Astrometrija 42
9.2. Fotometrija 45
9.3. Rezultati astrometrije i fotometrije 45
10. ZAKLJUČAK 46
LITERATURA 47
SAŽETAK 52
ABSTARCT 52
ŽIVOTOPIS 53
PRILOG 1 – PSEUDO KOD ALGORITMA ZA PRONALAZAK DUŽINA U 3D OBLAKU TOČAKA 54
Ulazni parametri algoritma 55

1. UVOD

U posljednjih nekoliko godina promatranje meteora automatiziranim sustavima postala je široka praksa, te mreže takvih sustava postaju sveprisutne u mnogim zemljama diljem svijeta [1]. Do prije svega 10 godina mogućnosti privatnog posjedovanja sustava za promatranje meteora bile su uvelike ograničene, te su takva rješenja često bila izvan financijskih mogućnosti astronoma amatera. Veće meteorske mreže postojale su u sklopu projekta većih profesionalnih institucija, te se tim područjem na profesionalnoj razini bavio mali broj ljudi. Među amaterima, vizualna promatranja (okom) su još uvijek bila vodeći način promatranja meteora, te su se predviđanja aktivnosti meteorskih potoka uvelike bazirala na toj vrsti promatranja [2].

Zadatak koji je tehnologija trebala riješiti bio je automatizirati nadzor cijeloga neba tijekom svih noći u godini, što je zahtijevalo iznimnu osjetljivost instrumenata i visoku pouzdanost takvoga sustava. Prvi sustavi za sistematski nadzor bili su fotografske prirode i pojavili su se 50-ih godina 20. stoljeća [3]. Video tehnika promatranja uvedena je početkom 1990-ih, no ondašnji sustavi zahtijevali su skupe fotomultiplikatore i velike količine filma za snimanje podataka [4]. Svi navedeni sustavi zahtijevali su mnogo održavanja i stručno osoblje koje je bilo obučeno za upravljanje takvim sustavima.

Revolucija u području događa se krajem 1990-ih pojavom pouzdanih CCD kamera koje su davale digitalni signal lako obradiv računalom [5]. U vremenu oko prijelaza u novo tisućljeće nastaju i prve amaterske meteorske mreže koje koriste CCD kamere i snimaju video tehnikom. No i dalje cijena pojedinih komponenti sustava, koji sada uključuje i snažno računalo, sprječava daljnji razvoj većih meteorskih mreža od strane amatera.

Šire korištenje CCD kamera za svrhe sigurnosti na javnim mjestima i privatnim domovima znatno spušta cijenu takvih kamera. 2006. godine na zvjezdarnici u Puli provode se prvi testovi jeftinih nadzornih kamera za svrhu snimanja meteora [6], te iznimni početni rezultati dovode do stvaranja Hrvatske meteorske mreže 2007. godine koja se bavi nadzorom događaja na nebu iznad Hrvatske, prvenstveno meteora. Prepoznavši mogućnost da astronomi amateri posjeduju sustave za promatranje meteora, stvaraju se nove nacionale meteorske mreže diljem svijeta.

Paralelno s razvojem novih meteorskih mreža, dolazi do velikog napretka u tehnologiji pametnih telefona. Zahvaljujući njihovim sve većim mogućnostima, i znatnim pojeftinjenjem minijaturnih računalnih komponenti koje se ugrađuju u njih, dolazi do razvoja minijaturnih računala. 2012.

godine pojavljuje se Raspberry Pi - računalo upotrebljivih karakteristika za cijenu od svega 35 USD [7].

Nedugo zatim pojavljuje se ideja za korištenjem takvog računala u sustavima za automatsko promatranje meteora. Testiranja mogućnosti Raspberry Pi računala za snimanje video signala uspješno su obavljena, no zamijećen je nedostatak programskih rješenja za automatsko snimanje meteora koja bi radila na takvim računalima. 2015. godine izrađeno je jednostavno programsko rješenje za snimanje meteora i detekciju vatrenih kugli [8], no sustav je bio daleko od gotovog.

Ovaj rad se bavi nastavkom spomenutog rada, tj. razvojem programskog rješenja automatskog sustava za promatranje meteora koji koristi jeftinu nadzornu CCD kameru te minijaturno računalo Raspberry Pi 2. Razvijeni sustav po prvi puta obuhvaća kompletne procedure za snimanje, detekciju vatrenih kugli, detekciju meteora te kompletnu obradu i kalibraciju dobivenih podataka.

Ovaj rad daje uvod u meteorsku znanost, te u poglavlju 2 opisuje postojeća programska rješenja za automatsku detekciju meteora. U poglavlju 3 predstavljena je Hrvatska meteorska mreža, tehnologija koju koristi, te njeni uspjesi. Poglavlje 4 daje pregled razvijenog programskog rješenja i definira zahtjeve koje mora zadovoljavati. U 5. poglavlju opisuje se metoda kompresije snimki meteora i problemi koji proizlaze iz nje. Poglavlje 6 daje opis postupka detekcije vatrenih kugli, a poglavlje 7 prikazuje razvijeni postupak detekcije meteora. U poglavlju 8 daje se pregled rada razvijenog algoritma za detekciju zvijezda na komprimiranim snimkama. Konačno, poglavlje 9 opisuje korištene procedure astrometrije i fotometrije.

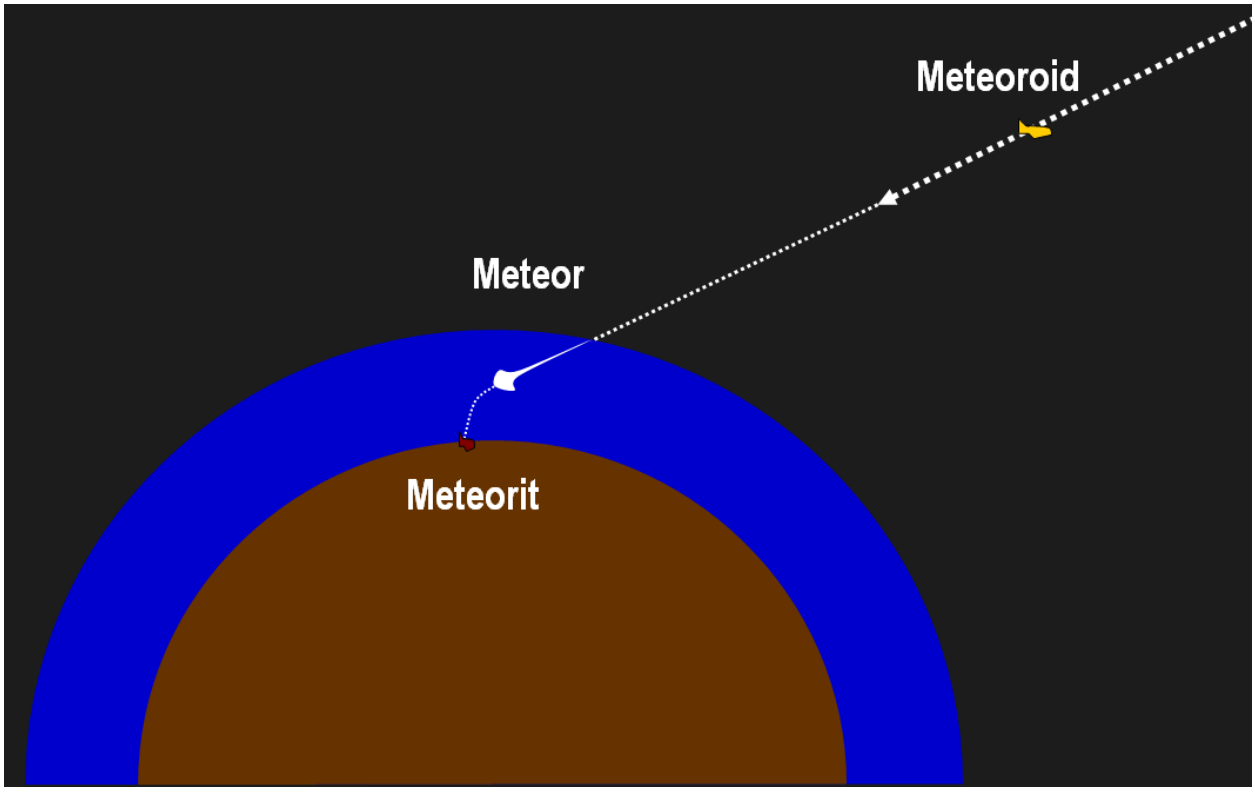
1.1. Zadatak diplomskog rada

Zadatak ovog diplomskog rada jest razviti programsko rješenje za dohvaćanje i kompresiju video signala s kamere namijenjene snimanju meteora, detekciju vrlo svijetlih meteora (vatrenih kugli) te detekciju meteora normalnoga sjaja. Također, zadatak je implementirati metode za kalibraciju kamere te astrometriju i fotometriju na temelju snimljenih podataka.

1.2. Uvod u meteorsku znanost

Iako je termin „meteor“ dio razgovornog jezika, radi lakšeg razumijevanja termina korištenih u ovome radu potrebno ga je detaljnije definirati, kao i ostale termine korištene u meteorskoj znanosti.

Po novom prijedlogu komisije Međunarodne astronomske unije [9], termin „meteor“ definiran je kao svjetlost i cjelokupni fenomen (toplina, udar i ionizacija) koja nastaje pri ulasku krutog tijela iz svemira u plinovitu atmosferu. Meteori sjajniji od -4. apsolutne magnitude zovu se „vatrene kugle“ ili „bolidi“. Nadalje, „meteoroid“ jest kruto tijelo veličine između 30 μm i 1 m koje se kreće ili dolazi iz međuplanetarnog prostora. „Meteorit“ je svako kruto tijelo koje je preživjelo fazu meteora u plinovitoj atmosferi bez da je u potpunosti isparilo. Slika 1.1 prikazuje vizualizaciju spomenutih termina.



Slika 1.1 Prikaz meteoroida, meteora i meteorita u odnosu na Zemlju i njenu atmosferu

Iako se često pri govoru o meteorima i meteoritima podrazumijeva da se radi o okružju Zemlje i njene atmosfere, postoje zabilježene snimke i pronalasci na drugim planetima. Kao primjer može se dati meteorit Lebanon kojeg je pronašao rover Curiosity na Marsu [10], te snimka meteora u Marsovoj atmosferi s rovera Spirit 2004. godine [11].

Meteoroidi najčešće nastaju pri bliskom prolasku kometa Suncu, tj. oni su kruti ostatak kometova repa. Također mogu nastati kao ostaci pri sudaru ili raspadu asteroida [2]. Potrebno je napomenuti da meteoriti isključivo dolaze od asteroida zbog njihovog čvršćeg sastava, dok svi meteoroidi kometarnog porijekla zbog svoje poroznosti u potpunosti isparavaju prolaskom kroz atmosferu [1]. Asteroidi su često čvrste površine i homogenog kamenog sastava, dok su jezgre kometa nehomogena mješavina leda, kamenja, prašine i zaleđenih plinova kao što su ugljični dioksid, ugljični monoksid, metan i amonijak [18]. Pri približavanju Suncu i povećanju površinske temperature, kometi postaju aktivni te razvijaju rep čestica koji ostaje iza njih. Asteroidi ne postaju aktivni povećanjem temperature, iako se pretpostavlja da postoje asteroidi koji su zapravo „uspavani kometi“ – zbog njihove se relativno stabilizirane orbite više ne približavaju Suncu i ne postaju aktivni. Asteroidi i kometi imaju vrlo važnu razliku u orbitama – asteroidi imaju mali ekscentricitet i nalaze se u određenim pojasevima unutar Sunčevog sustava. Kometi, s druge strane, često imaju vrlo visok ekscentricitet, pa su čak i neke orbite kometa hiperbolične (ekscentricitet veći ili jednak 1) [19] te im putanje često dolaze vrlo blizu Sunca.

Pri preživljavanju materijala kroz atmosferu vrlo je važna brzina i kut pod kojim dolazi. Veća brzina (preko 20 km/s) i velik ulazni kut značajno smanjuju vjerojatnost preživljavanja materijala do tla [1]. Stoga, pošto su kometi na orbitama s većim ekscentricitetom, imaju veće brzine i materijal koji nose je krhkiji, do sada nemamo niti jedan meteorit s potvrđenim kometarnim porijeklom.

Objekt od kojeg su potekli određeni meteoroidi zove se njihovo roditeljsko tijelo. Također se pretpostavlja da postoje meteori s porijeklom iz međuzvjezdanog prostora, no još uvijek ne postoji niti jedna snimka koja bi potvrdila njihovo postojanje. Problem njihovog snimanja predstavljaju velike brzine kojima se kreću, a koje mogu doseći preko 200 km/s [12].

U praksi je vrlo teško odrediti povezanost orbita meteorita ili orbita meteora s kometima i asteroidima. Problem nastaje pri utjecaju gravitacije ostalih objekata u Sunčevu sustavu na orbite samih asteroida i kometa, no i na same meteoroide prije nego dođu u interakciju sa Zemljinom atmosferom. Stoga se provode simulacije evolucije orbita [20], te se tek nad njima provodi analiza povezanosti.

Meteorski pljusak jest fenomen kada se iz jedne prividne točke na nebu (radijant) u ograničenom vremenskom periodu pojavljuje veći broj meteora [2]. Jedan od najpoznatijih meteorskih pljuskova jesu Perzeidi koji dosežu svoju maksimalnu aktivnost oko noći s 12. na 13. kolovoza

svake godine. Meteorski pljuskovi dobivaju imena po zviježđu prividnog radijanta – Perzeidi su stoga dobili ime po zviježđu Perzeja. Slika 1.2 daje grafički prikaz položaja radijanta Perzeida.



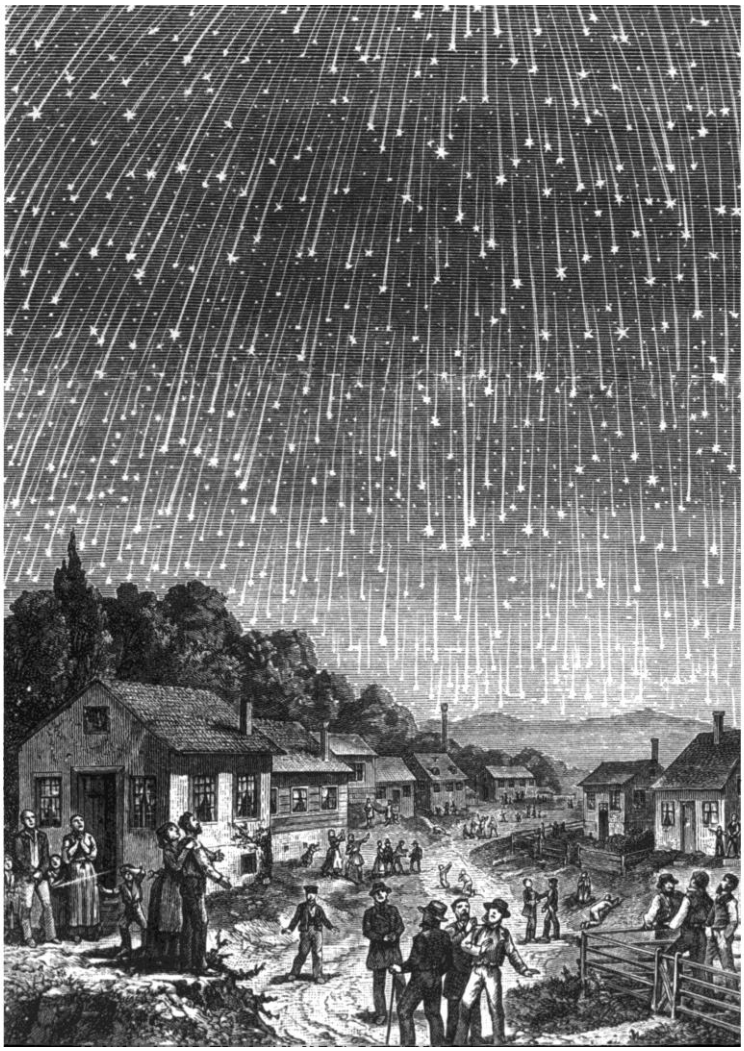
Slika 1.2 Radijant Perzeida i njegov položaj na nebu u odnosu na okolna zviježđa. Izvor: [13]

Meteorski pljuskovi koje vidimo su rezultat sudara meteoroidskog potoka sa Zemljinom atmosferom. Iako se ova dva termina čine sličnima, važno je naglasiti ispravnu kombinaciju pojmova – npr. u službenoj terminologiji ne postoji izraz „meteorski potok“. Meteoroidski potok zapravo označava skup meteoroida u međuzvjezdanom prostoru koji imaju slične orbite i nastali su od istog roditeljskog tijela.

Meteorski pljuskovi su periodični događaji koji se događaju svake godine na približno iste datume, stoga je moguće predvidjeti vrijeme njihovog ponovnog pojavljivanja. Na primjer, meteorski pljusak Orionidi imaju maksimum aktivnosti 21. listopada, Geminidi 14. prosinca, Liridi 22. travnja, itd. [14].

Vrlo jaki meteorski pljuskovi zovu se meteorske oluje te mogu rezultirati s više od 1000 meteora unutar jednoga sata [15]. Najjača meteorska oluja zabilježena je 1833. godine za vrijeme maksimuma aktivnosti meteorskog pljuska Leonida kada je po procjenama viđeno više od 100 000 meteora po satu [16]. Slika 1.3 prikazuje grafiku iz toga razdoblja na kojoj je rekonstruirano viđenje Leonida 1833. godine iz svjedočanstava javnosti. Varijacije u aktivnosti meteorskih pljuskova su često periodične: Leonidi dosežu razinu meteorske oluje svake 33

godine, a zadnja je bila 1998. godine kada je grupa znanstvenika iz Hrvatske na ekspediciji u Mongoliji prva snimila elektrofone zvukove uzrokovane vatrenim kuglama [2].



Slika 1.3 Drvorez koji prikazuje Leonide 1833. Izvor: [17]

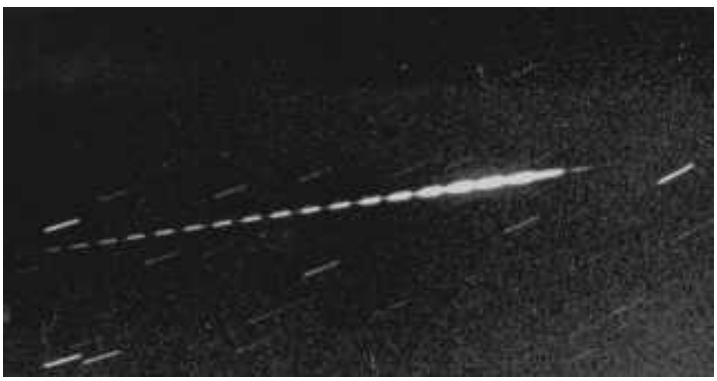
Posljednjih godina broj novootkrivenih meteorskih pljuskova, tj. meteoroidskih potoka (pojmovi su usko vezani), je u znatnom porastu. Ukupan broj orbita meteoroida naglo raste zbog postojanja mnoštva meteorskih mreža te se na bazama orbita vrše analize povezanosti. Uz pomoć algoritama grupiranja određuju se veze među orbitama, te ako se utvrdi statistički značajna povezanost može se tvrditi postojanje novog meteoroidskog potoka. Popisu svih otkrivenih meteorskih pljuskova može se pristupiti na [21].

1.3. Tehnike promatranja meteora

Sažetak fizikalnih procesa koji se događaju kada meteoroid uđe u atmosferu dan je u [1]**Error! Reference source not found.**, no ovaj rad se bavi snimanjem i detekcijom vizualnih manifestacija interakcija meteoroida s atmosferom – meteora. Meteori se u vizualnom dijelu spektra najčešće opažaju vizualno (okom), fotografski i video tehnikom.

Vizualno promatranje (okom) meteora je najstarija i najjednostavnija metoda. Organizirana skupina ljudi vrši promatranje, pri čemu se bilježi vrijeme pojavljivanja meteora, njegova pripadnost meteorskom pljusku (meteori bez pripadnosti zovu se sporadici) te njegova prividna zvjezdana magnituda („svjetlina“) [2]. No vizualno promatranje je podložno mnogobrojnim problemima, a najveći je ljudski faktor zbog kojeg sva tri parametra koji se prate mogu biti pogrešno zabilježena, što zbog neiskustva ili umora opažača. Pošto je vizualna metoda najstarija, iznimno širok spektar alata za statističku obradu vizualnih rezultata je razvijen, a njihov pregled je dan u [2]. Ova metoda je do nedavno bila i najraširenija zbog nepostojanja alternativnih rješenja, no razvojem tehnologije počele su se uvoditi naprednije metode.

Fotografsko promatranje meteora podrazumijeva korištenje analognih ili digitalnih tehnika fotografije. Pionir u ovome području bio je Zdeněk Ceplecha koji je 1951. godine pri zvjezdarnici Ondřejov u tadašnjoj Čehoslovačkoj razvio sustav od dvije analogne kamere koje su snimale cijelo nebo [3]. S tim sustavom je 1959. po prvi puta instrumentalno snimljen pad meteorita i na temelju snimke izračunata orbita meteoroida i mjesto pada meteorita kod sela Přibram po kojemu je meteorit i nazvan [22]. Danas većina mreža fotografskog tipa koristi digitalne fotoaparate namještene na automatsko okidanje fotografija [23]. Jedan od problema pri fotografskom opažanju meteora jest određivanje brzine meteora. Zbog toga se koristi rotirajući zatvarač koji određenom frekvencijom (npr. 50 Hz) siječe trag meteora na segmente jednakog trajanja. Jedan primjer snimke meteora ovom metodom dan je na slici 1.4.



Slika 1.4 Meteor fotografski snimljen 1997. godine metodom rotirajućeg zatvarača. Izvor: [24]

Način promatranja koji će se u ovome radu razmatrati jest promatranje meteora pomoću videokamere koje je postalo vrlo rašireno u posljednjih 20 godina. Razvojem tehnologije CCD kamera za potrebe sigurnosnih sustava i noćnog nadzora, osjetljivost senzora i cijene kamera postale su prihvatljive za upotrebu u meteorskoj znanosti. Video kamere u trenutnoj upotrebi snimaju manjom rezolucijom nego fotoaparati, rezolucijom od 640×480 pri 30 okvira u sekundi (NTSC format) ili 768×576 pri 25 okvira u sekundi (PAL format). Veće mreže kamera ove vrste postoje u SAD-u, Kanadi, Japanu, Novom Zelandu, Njemačkoj, Češkoj, Slovačkoj, Poljskoj, Francuskoj, Španjolskoj, Rumunjskoj, Mađarskoj, Sloveniji, Nizozemskoj, Belgiji, Velikoj Britaniji i na posljetku u Hrvatskoj, u sklopu Hrvatske meteorske mreže.

Od ostalih metoda promatranja meteora treba spomenuti radio promatranja, radarska promatranja i promatranja radiometrima [1]. U izvanrednim slučajevima, kada dođe do jakih detonacija u atmosferi uslijed raspada meteoroida, čije energije mogu doseći razine nekoliko stotina kilotona TNT-a, njihove posljedice mogu biti zabilježene na seizmografima te vojnim satelitima namijenjenim za nadzor detonacija nuklearnih bombi. Na primjer, energija koju je proizvela vatrena kugla iznad grada Čeljabinska u Rusiji 2013. godine procjenjuje se na 500 kilotona TNT-a [25], što je ~30 puta više od nuklearne bombe detonirane nad Hirošimom 1945. godine.

2. POSTOJEĆA PROGRAMSKA RJEŠENJA ZA VIDEO-PROMATRANJE METEORA

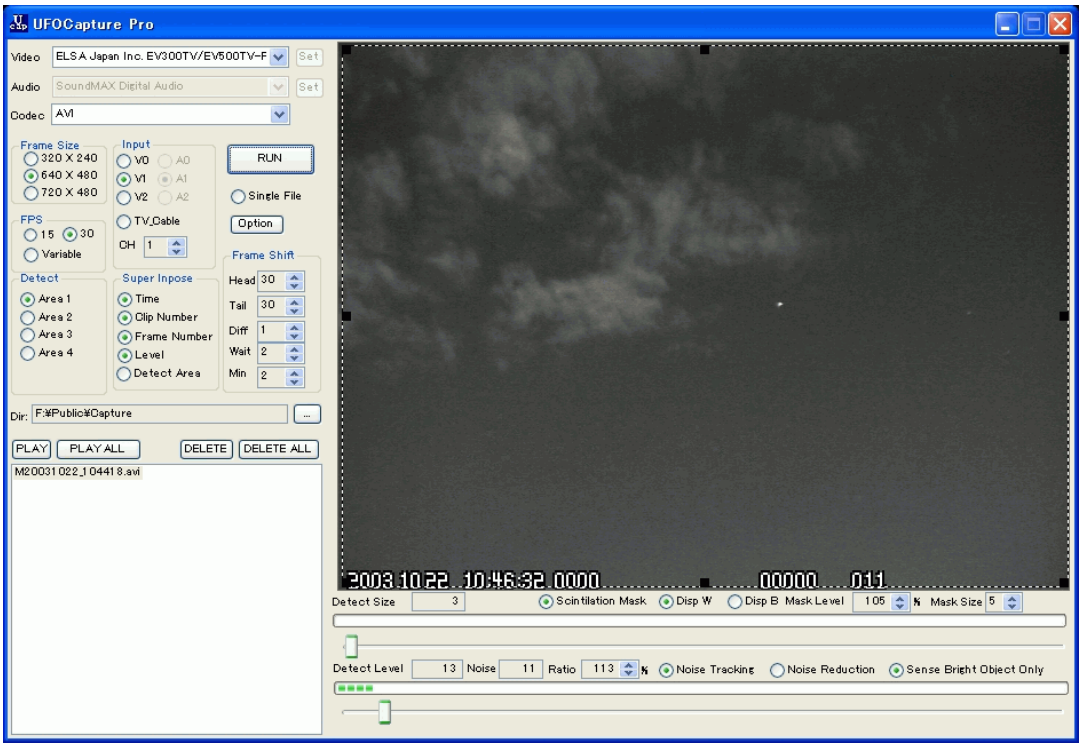
Upotrebom video kamera za promatranje meteora i njihovim spajanjem na osobna računala, pojavila se potreba za odgovarajućim programskim rješenjima za snimanje i detekciju meteora. U ovome poglavlju opisana su 3 najraširenija programska rješenja koja se u današnje vrijeme koriste u meteorskoj znanosti. Uz sama programska rješenja, ukratko su opisani i algoritmi detekcije koje ta programska rješenja koriste. Iako postoji i više programskih rješenja koja se koriste, za svega 3 postoji dovoljno informacija da budu detaljnije opisana te ih je moguće nabaviti i koristiti. Ostala programska rješenja se najčešće koriste u specifičnim primjenama ili zatvorenim grupama, na primjer kao što je ASGARD [34]. U radovima [35] i [36] dani su detalji trenutno korištenih programskih rješenja za detekciju meteora i opisani su algoritmi detekcije koje koriste.

2.1. SonotaCo UFOcapture

Trenutno najkorišteniji programski paket za video-promatranje meteora jest UFOCapture razvijen od strane japanske tvrtke SonotaCo [26]. Unatoč svojem konfuznom imenu, programski paket jest prvenstveno orijentiran na snimanje i detekciju meteora, no također i na snimanje ostalih atmosferskih pojava koji bi mogli biti od interesa astronomima amaterima. UFOCapture predstavlja rješenje koje je razvijeno za potrebe Japanske meteorske mreže, te oko sebe ima razvijeno cjelovito okruženje za obradu i vizualizaciju podataka: UFOanalyzer i UFOorbit. Važno je napomenuti da je UFOcapture komercijalan programski paket (cijene od 19440 JPY, što je oko 1200kn po tečaju iz lipnja 2016. godine), te kao takav jedini na tržištu koji se bavi snimanjem i detekcijom meteora. UFOcapture radi na Windows operacijskim sustavima, može raditi sa širokom paletom kamera i uređaja za digitalizaciju signala (koristi Windows DirectShow sučelje) te je zbog toga vrlo popularan izbor među amaterskom populacijom. Konkretno, uz Japansku meteorsku mrežu koriste ga Slovačka meteorska mreža [27], Bosanska meteorska mreža [28] i Meteorska mreža Ujedinjenog Kraljevstva [29].

Način i metode detekcije meteora koje UFOcapture koristi nisu točno poznate, a njegov programski kôd nije javno dostupan. No iz kratkog opisa rada i mogućih opcija danog u [30], moguće je zaključiti da algoritam u memoriji čuva usrednjenu sliku (*running mean*) na koju je primijenjena konvolucija jezgrom veličine 5×5 (konkretna korištena jezgra nije objašnjena). Od svakog okvira videa se oduzima usrednjena slika kako bi se dobile značajke na slici koje su svjetlije od pozadine. Zatim se tako obrađeni susjedni okviri međusobno oduzimaju kako bi se

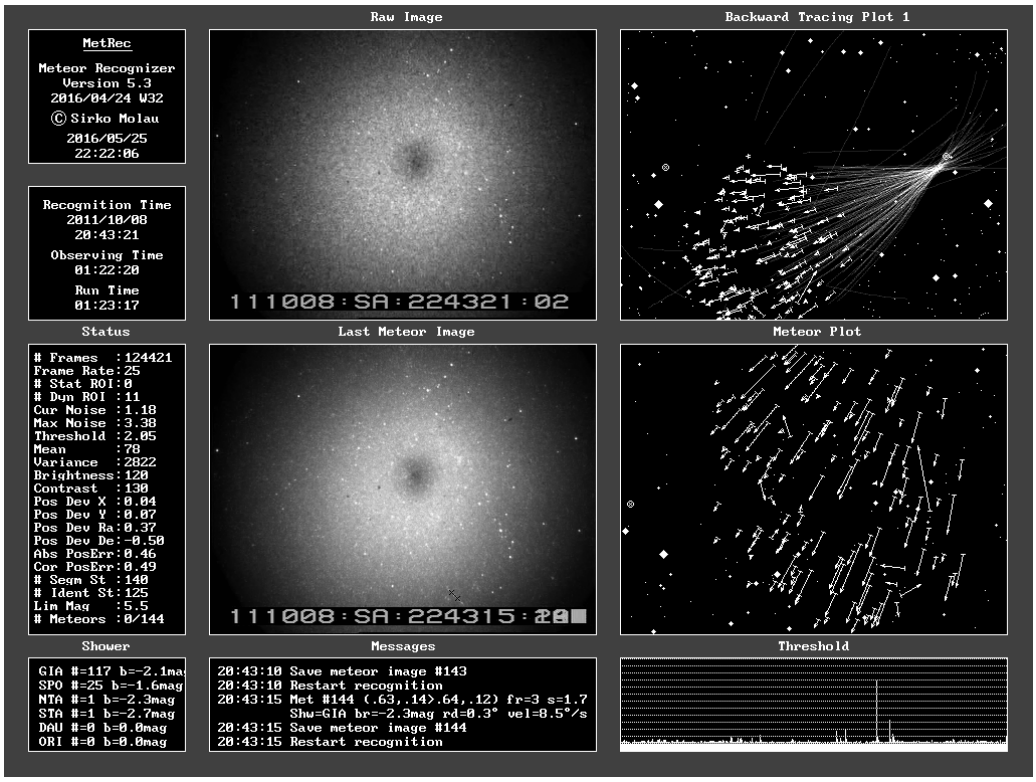
detektiralo kretanje. Razliku okvira algoritam binarizira te detektira pojave koje zadovoljavaju kriterije svjetline, brzine i trajanja. Slika 2.1 prikazuje prozor UFOcapture programa.



Slika 2.1 Izgled UFOcapture programa pri snimanju

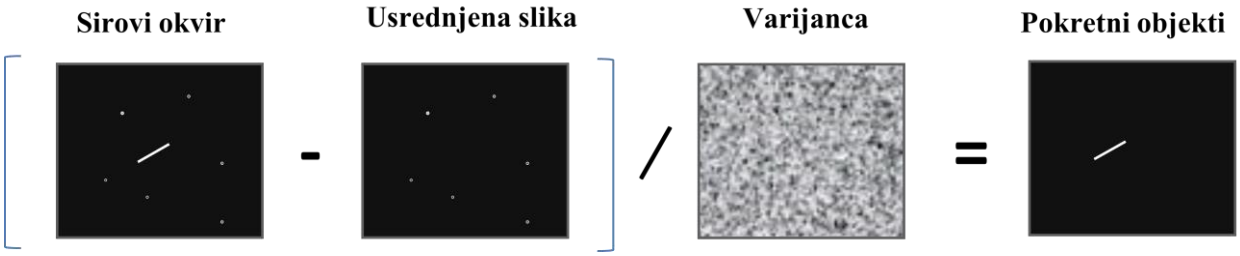
2.2. MetRec

MetRec (*Meteor Recognizer*) je pionirski program za snimanje meteora koji se u prvom izdanju pojavio sredinom 90-ih godina 20. stoljeća te ga je razvio Sirko Molau, njemački astronom amater [31]. MetRec je razvijen za potrebe amatera u Njemačkoj, a od 2004. godine postaje i službeno programsko rješenje korišteno od strane Međunarodne meteorske organizacije [32]. Iako je MetRec u širokoj upotrebi, sa sobom nosi određena ograničenja: radi isključivo s Matrox Meteor video karticama vrlo niske rezolucije od svega 384×288 te je donedavno radio samo na DOS operacijskom sustavu. Trenutno postoje verzije i za Windows XP i Windows 7 operacijske sustave. Slika MetReca dana je na slici 2.2.



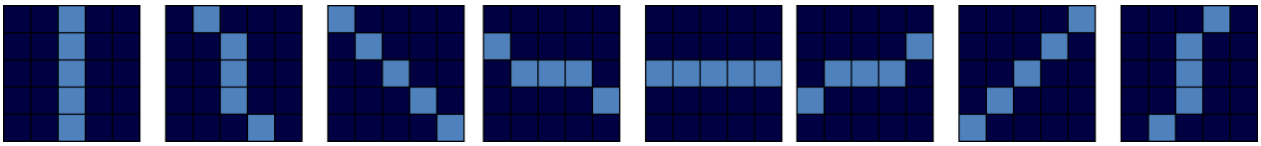
Slika 2.2 MetRec za vrijeme rada

Iako MetRec nije otvorena kôda, način rada algoritma detekcije meteora je poznat, a programski kôd pisan u programskom jeziku C je moguće dobiti na uvid od njegova autora. Algoritam u memoriji drži sliku srednjih vrijednosti prošlih piksela slike, te njihovu varijancu. Zatim od svakog okvira videa oduzima sliku srednjih vrijednosti i obavlja normalizaciju vrijednosti piksela uz pomoć varijance. Ovim postupkom se na okvirima uklanjaju svi statični objekti, te pozadina slike postaje uniformna. Opisana procedura algoritma vizualizirana je na slici 2.3.



Slika 2.3 Predobradba slike u MetRec programu. Izvor: [33]

Nakon što se dobije slika koja sadrži samo pokretne objekte, na njoj se primjenjuje konvolucija s 8 orijentacijskih jezgara dimenzija 5×5 prikazanih na slici 2.4.



Slika 2.4 Orijentacijske jezgre za konvoluciju koje koristi MetRec. Izvor: [33]

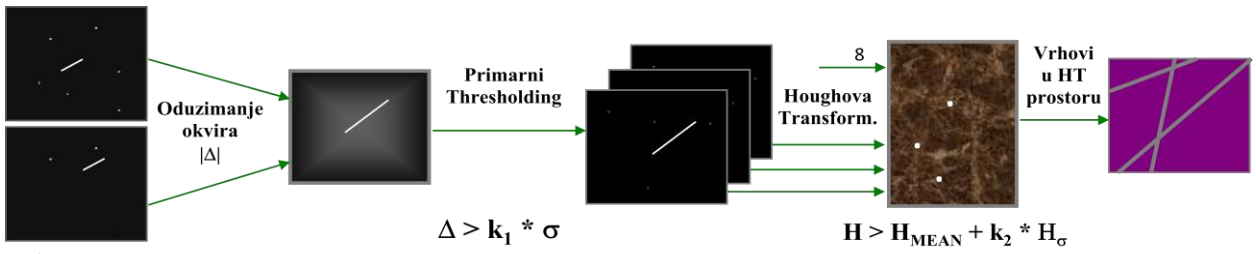
Detekcije dobivene pomoću konvolucije se provjeravaju s obzirom na vremensku propagaciju, tj. slijede li detekcije među okvirima zadanu orijentaciju. Ovaj algoritam ima prilično dobru razinu detekcije meteora (više od 80%), no algoritam također ima veliki broj lažnih detekcija [36].

2.3. MeteorScan

MeteorScan je algoritam za detekciju meteora kojeg je 1996. godine razvio Peter Gural, a trenutno je korišten od strane CAMS projekta SETI instituta, meteorske mreže University of Western Ontario i Hrvatske Meteorske Mreže [36]. Ovaj programski paket se također koristi za misije snimanja meteora iz aviona [37]. MeteorScan ima mogućnost detekcije u stvarnome vremenu, te mogućnost *offline* detekcije na pohranjenim datotekama. Prvotno je razvijen za rad na Mac OS operacijskim sustavima, a zatim je napravljena verzija koja radi na Windows operacijskim sustavima. MeteorScan koristi DirectShow mogućnost na Windows okruženju koja mu omogućuje da koristi bilo koju kameru kao izvor podataka, pod uvjetom da je moguće pronaći odgovarajuće pokretačke programe pod Windowsima. Radi s rezolucijama kamera od 640×480 pri 30 okvira u sekundi i 768×576 pri 25 okvira u sekundi. MeteorScan ima vrlo visoku razinu detekcije meteora od 99% u *offline* načinu rada, što ga čini vrlo upotrebljivim za sve svrhe detekcije meteora u kojima nije kritično stvarno vrijeme.

Rad MeteorScana je najbolje poznat od svih dostupnih programskih rješenja za detekciju meteora zahvaljujući vrlo opširnoj dokumentaciji [38] u kojoj je detaljno obrađena tematika detekcije meteora i dana je teorijska i praktična pozadina korištenog pristupa. Kako bi eliminirao statične objekte sa slike, MeteorScan računa razliku trenutnog video okvira i prošlog video okvira, čime dobiva samo objekte koji su se pojavili na slici u odnosu na prošli okvir. Također se za sliku prati njena tekuća standardna devijacija. Zatim se na slici obavlja binarizacija pri čemu se pikseli koji su značajnije svjetliji od pozadine proglašavaju bijelima, a svi ostali crnim pikselima. Zatim se 8 posljednjih obrađenih video okvira zbrajaju u jednu sliku. Zbrajanjem se postiže da meteori na zbrojenoj slici izgledaju kao linije. Zatim je problem sveden na detekciju linija na slici. U svrhu toga korištena je modifikacija Houghove transformacije [39] pri čemu algoritam ne ispituje sve kombinacije parametara ρ i θ (za detaljno objašnjenje Houghove transformacije pogledati poglavlje 7.2), nego uparuje sve piksele sa svakim i iz njihove

kombinacije (tj. pravca kroz dva piksela) radi estimaciju tih parametara. Ovime je eliminirana rasutost glasova koja inače nastaje u Houghovom prostoru parametara, no žrtvovano je vrijeme jer Houghova transformacija s uparenim pikselima ima složenost $O(N^2)$, za razliku od tradicionalne Houghove transformacije sa složenošću O(N). Zatim je potrebno pronaći vrhove u Houghovom prostoru parametara koji predstavljaju moguće linije na slici. U usporedbi s tradicionalnom Houghovom transformacijom, vrhovi su iznimno dobro lokalizirani i imaju veliku amplitudu. Zatim se obavlja binarizacija u Houghovom prostoru parametara pri čemu se u obzir uzimaju vrhovi amplitude koje su značajno iznad pozadinskog šuma. Zatim se pronađeni vrhovi pretvaraju u pravce u prostoru slike, te se maskiraju svi dijelovi slike osim trake širine nekoliko desetaka piksela oko pravca. Pošto je svakom pikselu detektiranog meteora moguće pridružiti vremensku komponentu, slika se šalje u *Matched filter* algoritam koji pretpostavlja pravac koji propagira u vremenu. Ako je uvjet vremenske propagacije zadovoljen, detekcija se smatra uspješnom.



Slika 2.5 Ilustracija rada MeteorScana do otkrivanja linija meteora na slici. Izvor: [33]

Nedostatak MeteorScana je velik broj lažnih detekcija koje se pojavljuju na oblacima, te mnogobrojne detekcije aviona, buba, ptica i ostalih pokretnih pojava. Stoga je za njegovo uspješno korištenje potrebno imati dodatnu proceduru za uklanjanje lažnih detekcija kako bi podaci bili relativno čisti.

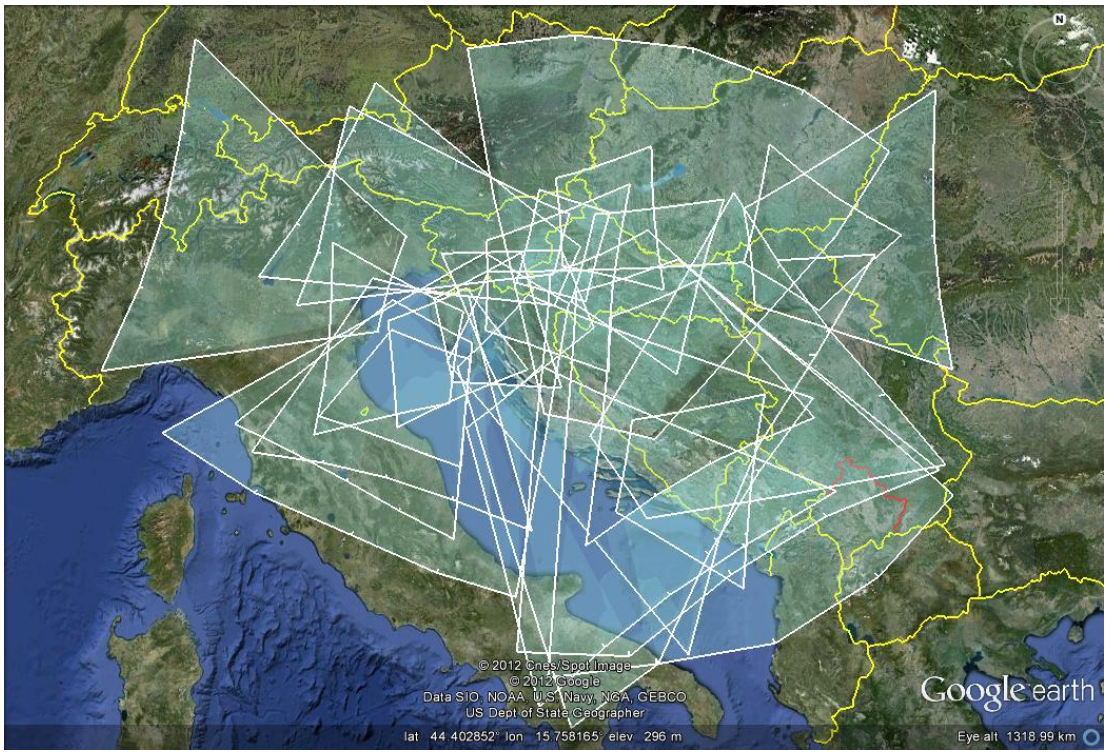
MeteorScan je algoritam koji je u blago modificiranom obliku korišten za potrebe Hrvatske Meteorske mreže od njenih početaka, te je zbog širokog iskustva autora ovog rada s njime, iz njega dobivena i velika inspiracija za razvijenu metodu detekcije meteora u ovome radu.

3. HRVATSKA METEORSKA MREŽA

Prije pokušaja snimanja meteora, najraširenija metoda sakupljanja podataka bilo je vizualno promatranje koje se kao takvo koristi i dan danas. Prva vizualna promatranja na području Republike Hrvatske obavili su astronomi amateri 70-ih godina 20. stoljeća u organizaciji Zagrebačke zvjezdarnice, prema [2]. Iskorak u tehnici prva pokazuje Zvjezdarnica Višnjan početkom 1990-ih te postaje dijelom Europske meteorske mreže, kao prva takva stanica na području Republike Hrvatske. Korištena tehnologija zahtijevala je snimanje videa na trake, što je bilo mukotrpno i neučinkovito, a konkretne rezultate bilo je teško dobiti. Projekt je ubrzo napušten, te se tragalo za novim metodama snimanja.

Razvojem tehnologije CCD senzora dolazi do stvaranja prvih meteorskih mreža koje se temelje na digitalnim videozapisima snimljenim pomoću videokamere i računala. Daljnjim razvojem tehnologije i padom cijena, kamere visoke rezolucije postale su dostupne za korištenje i amaterima. 2006. godine na zvjezdarnici u Puli provode se prva testiranja nadzornih kamera u svrhu snimanja meteora [40]. Rezultati su bili više nego ohrabrujući, te su u noći maksimuma meteorskog roja Geminida snimljena 192 meteora. Godinu dana kasnije osnovana je Hrvatska meteorska mreža (skraćeno HMM). Unutar dvije godine od osnutka potvrđena je robusnost korištene tehnologije te se nastavilo u znanstvenome smjeru [41, 42]. Mreža je zamišljena kao niz stanica raspoređenih na teritoriju Republike Hrvatske, od kojih se svaka sastoji od računala i CCD kamere tipa 1004X s 4 mm F/1.2 objektivom, vidnog polja 64×48 stupnjeva. Takav sustav omogućuje snimanje zvijezda do 4. zvjezdane veličine i meteora do 2. zvjezdane veličine. Za snimanje se koristi EasyCap STK116 USB uređaj ili kartica Winfast VC100XP, koji daju sliku rezolucije 720×576 u slučaju USB uređaja i 768×576 u slučaju kartice [43]. Trenutno je na prostoru republike Hrvatske aktivno oko 20 kamera čija su vidna polja međusobno preklopljena. Glavni cilj meteorske mreže jest snimiti meteor s najmanje dvije stanice što daje mogućnost rekonstrukcije njegove heliocentrične orbite. Pokrivenost neba iznad Hrvatske na 100 km visine kamerama HMM-a 2012. godine dana je na slici 3.1.

Potrebno je napomenuti da Hrvatska meteorske mreža, u usporedbi s ostalim mrežama sličnoga tipa, koristi iznimno jeftinu opremu za snimanje. Prosječna cijena jedne meteorske stanice uključujući računalo iznosi oko 400 EUR, dok ostale mreže istu svotu izdvajaju samo za kameru, ne uključujući računalo i objektiv. Trend jest nastaviti smanjivanje cijene pojedinih stanica uz stalno praćenje tehnologije i unaprjeđivanje tehničkih karakteristika stanica.



Slika 3.1 Pokrivenost neba iznad Hrvatske i okolnih zemalja na visini od 100 km 2012. godine

3.1. Programska rješenja korištena unutar HMM-a

Primarno programsko rješenje koje se koristi unutar HMM-a za snimanje i detekciju meteora je program FTP_CaptureAndDetect koji je ljuska za izvođenje MeteorScan algoritma. FTP_CaptureAndDetect je izvorno namijenjen korištenju u meteorskoj mreži *Cameras for Allsky Meteor Surveillance* (CAMS) SETI instituta, no rješenje je prilagođeno za potrebe Hrvatske meteorske mreže. Važno je napomenuti da HMM koristi FTP_CaptureAndDetect samo za snimanje i detekciju meteora, a proces kalibracije podataka (astrometrija i fotometrija) se odrađuje programskim rješenjima vlastite izrade. Detaljan opis programskog rješenja kojeg koristi Hrvatska meteorska mreža za interakciju s FTP_CaptureAndDetect programom, kalibraciju podataka te manipuliranje podacima od strane individualnih stanica mreže dani su u [44].

Iako je programsko rješenje koje upravlja FTP_CaptureAndDetectom pisano u Pythonu i otvorenog je kôda, te je kao takvo lako prenosivo na druge platforme, sam FTP_CaptureAndDetect jest zatvorenog kôda i pisan je za Windows operacijske sustave. Zbog navedenih ograničenja nije bilo moguće imati meteorsku stanicu pod bilo kojim Linux operativnim sustavom. Također niti jedno danas komercijalno ili bilo kako dostupno rješenje ne radi pod Linuxom. Jedini sustav koji radi pod Debian distribucijom Linuxa jest jedan od

nedostupnih – ASGARD, koji koriste University of Western Ontario, University of Saskatchewan i Meteoroid Environment Office u NASA Marshall Spaceflight centru [34].

3.2. Znanstveni uspjesi HMM-a

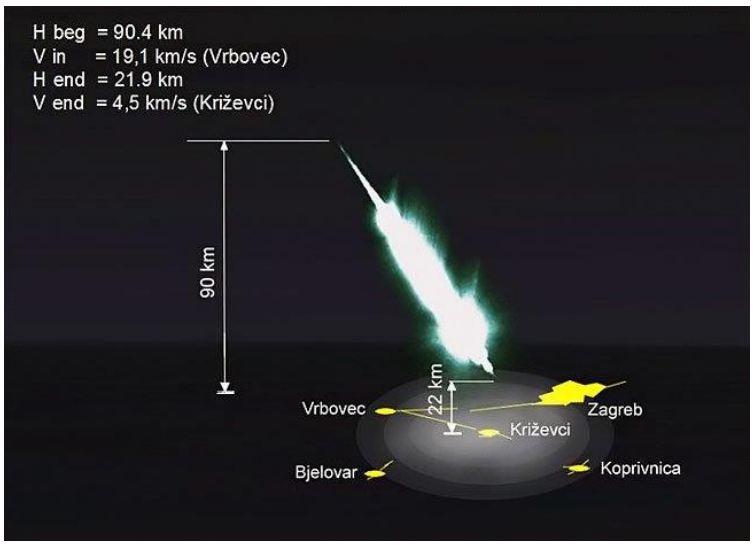
Do današnjeg dana HMM je otkrio i prijavio komisiji Međunarodne astronomske unije (IAU), koja je središnje mjesto za sakupljanje podataka o meteorskim pljuskovima, 111 potencijalnih novih meteorskih potoka [45]. Trenutni popis [46] svih meteorskih potoka, uključujući i novootkrivene, sadrži oko 800 potoka. Dakle 14% svih otkrivenih potoka se pripisuje Hrvatskoj meteorskoj mreži.

Uz ova otkrića, objavljeno je preko 50 znanstvenih članaka i doprinosa na međunarodnim konferencijama. Popis objavljenih publikacija i publikacije u PDF formatu dostupne su na stranicama HMM-a [47].

HMM trenutno surađuje s nekoliko svjetski poznatih institucija koje se bave ovim područjem astronomije ili koriste znanstvene podatke iz njega, kao što su to Europska svemirska agencija (ESA), NASA i SETI institut.

3.3. Križevački meteorit

U noći s 4. na 5. veljače 2011. godine, oko 23:30 sati po UTC vremenu, kamerama HMM-a zabilježen je vrlo sjajan meteor. Iz asteroidnog pojasa koji se nalazi na stazi između Marsa i Jupitera, Zemlji se približilo svemirsko tijelo mase 90 kilograma pri brzini koja se procjenjuje na 19.1 kilometara u sekundi i uletjelo u Zemljinu atmosferu. Na slici 3.2 dan je prikaz pojave meteora s pripadajućim podacima o brzini i visini.



Slika 3.2 Prikaz meteora iznad Križevaca u noći s 4. na 5. veljače 2011. godine

Kinetička energija koja se tom prilikom oslobodila bila je toliko velika da je ovo svemirsko tijelo za vrijeme spuštanja kroz atmosferu s 10 km/s usporilo na 4.5 km/s u svega jednoj sekundi, što je prouzročilo spektakularne svjetlosne efekte na noćnome nebu. Nakon detaljne analize i proračuna, utvrđeno je da je otprilike 3 kilograma meteoritskog materijala palo na polja oko Križevaca [48]. Nakon višesatne potrage, pronađen je fragment mase 291 grama, prikazan na slici 3.3. Za ostatak ukupne ulazne mase pretpostavlja se da je fragmentirala u puno malih fragmenata (reda veličine jednog grama), te ih je na danom terenu bilo vrlo teško pronaći. Također je obavljena analiza fragmentacije vatrene kugle koja je prouzročila meteorit, analizirane su sve dostupne snimke vatrene kugle i je napravljen fragmentacijski model. Meteorit je nazvan „Križevci“ i spada u 10 najbolje dokumentiranih padova meteorita na svijetu [49].

Analizom provedenom na sveučilištu Manchester pomoću rendgenske tomografije zaključeno je da meteorit pripada skupini kamenih meteorita (hondrit, tip H6 s preko 30% udjela željeza).



Slika 3.3 Najveći i jedini pronađeni fragment Križevačkog meteorita

Ovaj događaj pokazao je zrelost tehnologije koja se koristi u Hrvatskoj meteorskoj mreži i sposobnost Mreže u pronalaženju meteorita, što spada u najzahtjevnije postupke u meteorskoj znanosti. Ovime je HMM stao bok uz bok inozemnim stručnjacima te se potvrdio kao meteorska mreža profesionalnih kompetencija. Križevački meteorit se ubraja u tek nekolicinu meteorita koji imaju utvrđenu orbitu, tj. pronađeni su iz same pojave uz pomoć proračuna, za razliku od većine koji bivaju pronađeni sasvim slučajno kao interesantne stijene, a tek se kasnijom analizom utvrdi da su meteoriti.

3.4. Korištenje minijaturnih računala za svrhu snimanja meteora

Uobičajeni sustav meteorske stanice se sastoji od kamere, digitalizatora, te računala. Cijene dovoljno osjetljivih kamera koje mogu biti korištene za snimke meteora su posljednjih godina pale ispod 50 USD [53], cijene digitalizatora se također kreću oko nekoliko desetaka američkih dolara, no glavna cjenovna komponenta jest osobno računalo. S druge strane, na tržištu se 2012. godine pojavljuje Raspberry Pi [7], minijaturno računalo veličine dlana i cijene od svega 35 USD.

Prvu ideju za snimanje meteora pomoću minijaturnog računala tipa Raspberry Pi unutar Hrvatske meteorske mreže dobiva Dario Zubović 2014. godine, tada riječki srednjoškolac i astronom amater. U isto vrijeme autor ovog rada pronalazi video [50] organizacije American Meteor Society u kojem se može vidjeti prototip *all-sky* sustava za snimanje meteora koji koristi Raspberry Pi računalo. Nakon kontaktiranja Mikea Hankeya, autora spomenutog videa, saznajemo da se radi o isključivo hardverskoj platformi, te da su pokušaji korištenja postojećih programskih rješenja za snimanje meteora bili neuspješni.

Kao što je navedeno u prethodnim poglavljima, sva trenutno dostupna rješenja rade isključivo na Windows operacijskim sustavima, no Raspberry Pi računalo radi isključivo s Linux distribucijama. Također, daljnji problem jest što Raspberry Pi koristi ARM procesorsku arhitekturu, stoga nije moguće koristiti niti jedno programsko rješenje koje je prevedeno na strojni jezik na Windows operacijskom sustavu, niti na x86 arhitekturama procesora. Korištenje Raspberry Pi računala stoga zahtjeva posjedovanje cijelog izvornog kôda programa koji mora biti preveden u strojni jezik na samom Raspberry Pi računalu.

Zbog svih navedenih ograničenja i nepostojanja programa za snimanje i detekciju meteora s dostupnim izvornim kôdom, početkom 2015. godine Dario Zubović provodi prva testiranja te uspješno sprema sirovi video signal s kamere Sony Effio 673 koristeći digitalizator EasyCap UTV007 u memoriju Raspberry Pi-ja. No pored same operacije snimanja, procesorska moć Raspberry Pi računala nije bila dovoljna za bilo kakve kompleksnije operacije.

Nedugo potom pojavljuje se nova inačica Raspberry Pi računala, Raspberry Pi 2 [51] koje ima višestruko jaču procesorsku moć (4 jezgre na 900 MHz) i dvostruko više radne memorije (1 GB), te se autor ovoga rada uključuje u daljnji razvoj programskog rješenja.

U lipnju 2015. se razvija algoritam za kompresiju snimaka i uspješno se testira. Algoritam je obavljao snimanje signala s kamere na jednoj jezgri, a kompresiju na drugoj. Pošto su na

raspolaganju ostale 2 neiskorištene jezgre, odlučuje se implementirati i algoritme za detekciju vatrenih kugli i meteora. U srpnju je implementiran algoritam za detekciju vatrenih kugli, te je uspješno testiran za vrijeme meteorskog pljuska Perzeida u kolovozu 2015. godine. Rad koji je napravljen do toga trenutka prezentiran je na Međunarodnoj meteorskoj konferenciji u mjestu Mistelbach u Austriji [8]. Toga trenutka ukupna cijena korištenih komponenti u predstavljenom sustavu procijenjena je na 150 USD, čime je prezentirani sustav bio najjeftinije rješenje ikada predstavljeno s takvim mogućnostima.

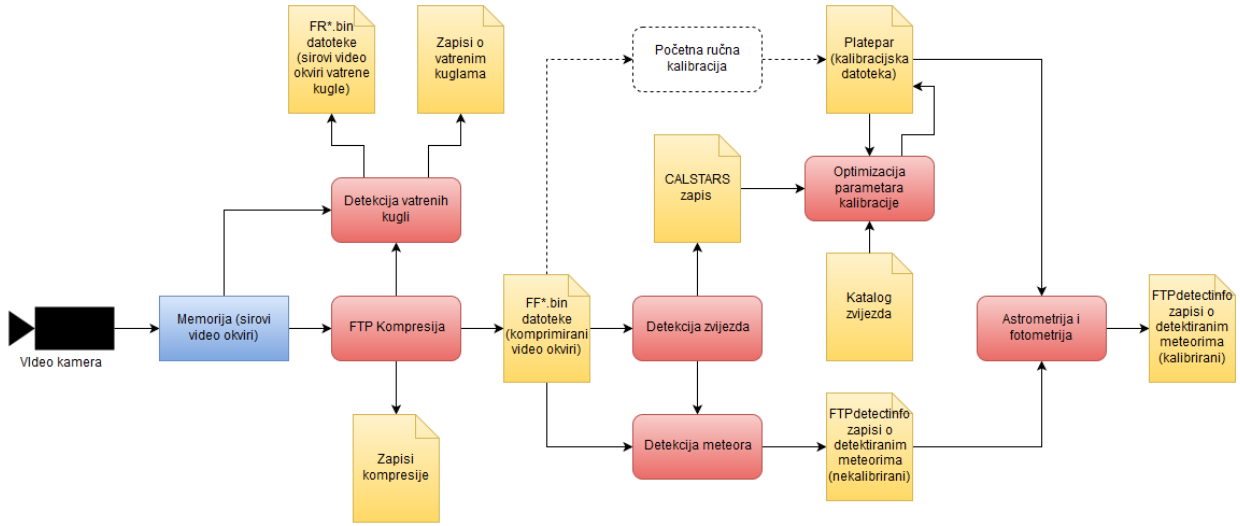
Do veljače 2016. godine sve razvijene procedure su uvelike optimizirane, bolje dokumentirane i testirane, a sami algoritmi za kompresiju snimaka meteora i detekciju vatrenih kugli u detalje su opisani u [52].

Do lipnja 2016. godine završeni su i algoritmi za detekciju meteora, detekciju zvijezda na slikama, te kalibraciju podataka. U ovome radu se stoga opisuju svi razvijeni algoritmi i rezultati njihova testiranja.

4. PREGLED RAZVIJENOG PROGRAMSKOG RJEŠENJA

Programsko rješenje je izrađeno u programskom jeziku Python, dok su zahtjevniji algoritmi pisani u C++-u. Također, u dijelovima zahtjevnijih algoritama korištena je Python biblioteka pod nazivom Cython koja omogućava automatsko prevođenje Python kôda u C, čime se značajno dobiva na brzini izvođenja kôda.

Blokovski dijagram razvijenog programskog rješenja dan je na slici 4.1.



Slika 4.1 Blokovski dijagram razvijenog rješenja za automatsku detekciju meteora

Sirovi video okviri s digitalizatora se privremeno spremaju u memoriju računala, a zatim se komprimiraju u CAMS FTP format [54], o kojem će biti govora u sljedećem poglavlju. Iako ova metoda kompresije uspješno očuva meteore do srednje razine svjetline, do problema dolazi kod vrlo sjajnih meteora i vatrenih kugli pri čemu se javljaju kompresijski artefakti.

Pošto uslijed pojave artefakata kompresije dolazi do gubitka informacije o točnom položaju vatrene kugle, razvijen je detektor vatrenih kugli koji se izvršava u stvarnome vremenu te sprema sirove video okvire iz memorije računala (dok se još nisu obrisali) u trajnu memoriju. Ovo je moguće jer vatrene kugle imaju nekoliko redova veličine veći omjer signala i šuma od meteora srednje razine sjaja te zbog toga algoritam za detekciju vatrenih kugli može biti jednostavniji i brži. Tamniji meteori mogu biti detektirani u naknadnoj obradbi zahtjevnijim metodama pošto oni u većini slučajeva ne pate od kompresijskih artefakata.

Kako bi ovaj sustav detekcije bio kompetitivan s postojećim rješenjima, pored detekcije vatrenih kugli, potrebna je mogućnost detekcije tamnijih meteora. Pošto je procesorska moć Rapsberry Pi 2 računala ograničena, algoritam za detekciju mora biti brz, razumno robustan i dovoljno

osjetljiv kako bi detektirao meteore koje ne detektira algoritam za detekciju vatrenih kugli. Kako bismo kvantificirali točno vrijeme koje algoritam smije potrošiti za detekciju, izračunat ćemo najduže srednje vrijeme koje algoritam smije potrošiti po jednoj komprimiranoj datoteci.

Kako bi se iskoristila potpuna moć Raspberry Pi 2 računala, sve 4 njegove jezgre su iskorištene. Nit koja izvršava snimanje video signala ima najveći prioritet i mora se izvršavati u stvarnome vremenu, stoga je jedna cijela jezgra posvećena tome zadatku. Dvije jezgre posvećene su kompresiji video okvira i detekciji vatrenih kugli u stvarnome vremenu. Procedura kompresije i detekcije vatrenih kugli je serijska, tj. podaci iz kompresije koriste se za detekciju, stoga svaka od dvije jezgre izvršava jednak proces koji objedinjuje obje radnje. Podaci se naizmjenično šalju u različite jezgre, čime se udvostručuje ukupno dostupno vrijeme za obradu. Preostala jezgra izvršava detekciju zvijezda i meteora na slici. Kada završi snimanje, tj. svane zora, sve 4 jezgre izvršavaju detekciju zvijezda i meteora na snimkama snimljenim tijekom noći. Konačno, kada procedure detekcije završe, izvršavaju se procedure astrometrijske i fotometrijske kalibracije.

S definiranom vremenskom alokacijom jezgara, ukupno dostupno vrijeme za procedure detekcije može biti izračunato. Najduža noć u godini na zemljopisnoj širini 50° sjeverno traje oko 16 sati, što daje 5625 FF datoteka (komprimiranih snimki) pri 25 okvira u sekundi i 256 okvira po datoteci. Stoga prema vremenskoj alokaciji jezgara, 16 sati je slobodno na 1 jezgri, dok je preostalih 8 sati slobodno na sve 4 jezgre. Ukupno vrijeme za izvršavanje procedura detekcije je stoga 48 sati (ne računajući procedure kalibracije i sistemskih funkcija). Na temelju danih informacija je moguće izračunati najduže srednje vrijeme koje algoritam može potrošiti za obradu pojedine datoteke, te ono iznosi oko 30 sekundi. Nadalje, ako uzmemo u obzir da je Raspberry Pi 2 barem red veličine sporiji od današnjih računala normalne veličine, najduže srednje vrijeme izvršavanja procedura detekcije na njima ne smije trajati duže od 3 sekunde. Pošto je ovo vrijeme vrlo kratko, algoritam se treba potruditi smanjiti broj analiziranih datoteka što je više moguće, po mogućnosti prije pokretanja vremenski zahtjevnih procedura.

Izvorni kôd razvijenog programskog rješenja je u potpunosti dostupan na repozitoriju kôda GitHub, na sljedećoj Internetskoj adresi: https://github.com/CroatianMeteorNetwork/RMS/

5. KOMPRIMIRANJE SNIMAKA S METEORSKE KAMERE

Ako uzmemo u obzir da se svaka stanica Hrvatske meteorske mreže sastoji od video kamere, digitalizatora i računala, sasvim je prirodno pretpostaviti da kao primarni format snimanja treba koristiti jedan od video formata. No pristup problemu kompresije je različit od neastronomskih primjena. Korištenjem kakvih *lossy* kompresija riskirao bi se gubitak na prostornoj rezoluciji. Ako razmotrimo da je jedna kamera prosječne rezolucije od 768×576 piksela i vidnog polja 64×48 stupnjeva, lako dobijemo lučnu razlučivost u horizontalnom smjeru:

$$\theta_x = \frac{64^\circ}{768\,px} \cdot 60' = 5'/px \tag{5-1}$$

Te također jednaku u vertikalnom smjeru:

$$\theta_y = \frac{48^\circ}{576\,px} \cdot 60' = 5'/px \tag{5-2}$$

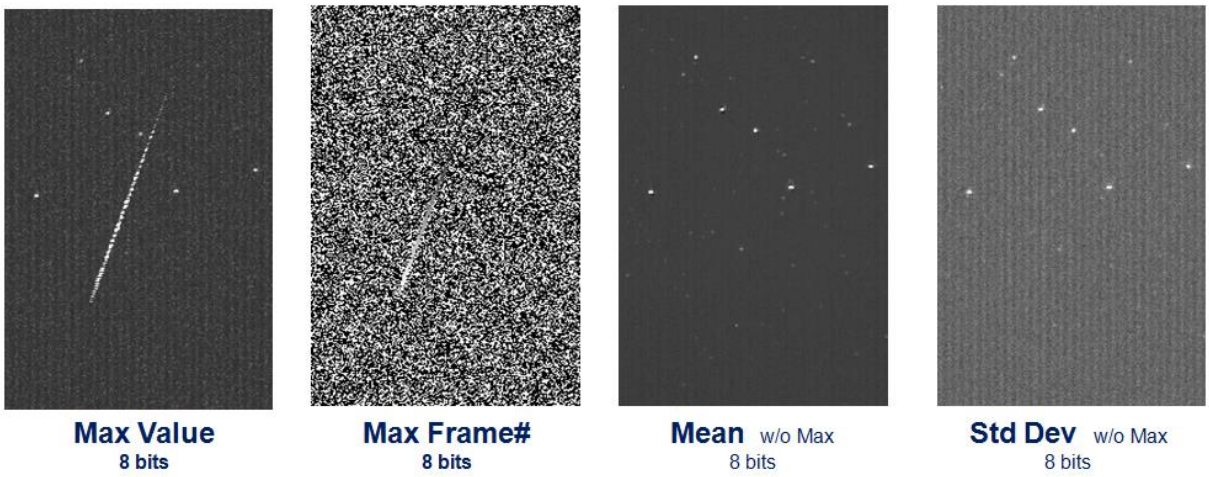
Svaki piksel na slici odgovara 5 lučnih minuta rezolucije na nebu. Ako uzmemo u obzir da je prosječna visina meteora oko 100 kilometara [2], lako dobijemo koliko jedan iznosi na toj udaljenosti:

$$d = \tan\frac{5'}{60'/^\circ} \cdot 10^5 m \approx 150\,m \tag{5-3}$$

Jedan piksel na 100 kilometara udaljenosti uz danu lučnu razlučivost od 5' po pikselu daje otprilike 150 metara, što znači da svaki piksel mora biti očuvan ako se hoće postići što veća prostorna preciznost. Razmotrimo količinu podataka koja bi bila potrebna da se sačuva video dane rezolucije u sirovom formatu pri 25 okvira u sekundi i tijekom prosječne noći snimanja od 12 sati. Dolazimo do veličine oko 450 GB, što znači da bi vrlo lako napunili najveći trenutno dostupan čvrsti disk na tržištu za svega dva tjedna.

U tu svrhu Mark Vornhusen osmislio je za svoj program Skypatrol, a Peter Gural je unaprijedio, *Maximum temporal pixel* [40] metodu kompresije video-promatranja meteora. Naziv unaprijeđene metode je *Four-frame Temporal Pixel* (FTP) [54]. Glavna pretpostavka ove metode jest da je meteor vrlo vjerojatno najsjajniji događaj na nebu unutar kraćeg perioda. Stoga nije potrebno sačuvati sve informacije o svakom pikselu unutar danog perioda, nego samo u kojem je vremenu zabilježena najsjajnija vrijednost svakoga piksela. Zbog jednostavnosti i kompatibilnosti, sve slike pohranjene su u modificirani 8-bitni BMP format s 4 kanala: kanal s maksimalnom vrijednosti piksela (*maxpixel*), kanal s informacijom o vremenu pojavljivanja maksimalne vrijednosti piksela (*maxframe*), kanal sa srednjim vrijednostima piksela (*avepixel*) te

kanal sa standardnom devijacijom (*stdpixel*). Srednja vrijednost se računa s oduzetom vrijednosti maksimalnih vrijednosti piksela, no i dalje se dijeli s 256, zbog brzine izvođenja. Slika 5.1 prikazuje primjer svakog od četiri kanala.



Slika 5.1 Prikaz svakog pojedinog kanala CAMS FTP kompresijskog formata. Izvor: [33]

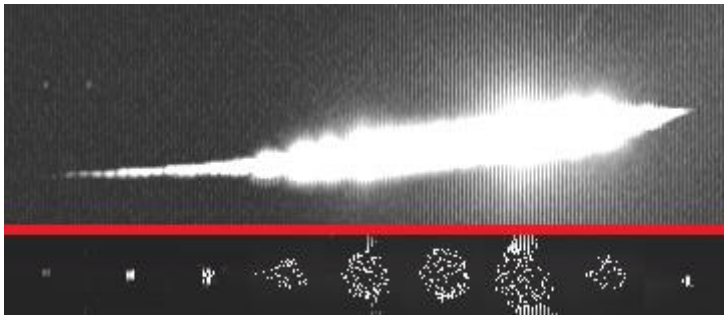
Svaka komprimirana slika sadrži 256 (8 bita) razina intenziteta sive boje, te obuhvaća vremenski period od 256 okvira, što pri PAL formatu daje vremenski raspon od 10.24 sekunde. Kompresijski omjer je 1:64 jer je efektivno 256 okvira sažeto u samo 4. U ovome radu će se nadalje za jedan blok od 256 okvira koristiti termin „snimka“. Iz takve komprimirane snimke moguće je lako rekonstruirati izvorni video meteora. Ovakav način kompresije omogućava da se veličina podataka snimanja u noći prosječnog trajanja smanji na svega 7 GB, što predstavlja prihvatljivu varijantu za spremanje na malo računalo s trajnom memorijom od 64 GB.

Konačno, ovako komprimirana snimka se sprema u binarnu datoteku koja se naziva FF datoteka (*Four-frame temporal pixel File*), te će se nadalje u radu na komprimiranu snimku referirati na taj način.

5.1. Problemi komprimiranih snimaka

Raspon svjetline meteora je vrlo velik, stoga se i oni različito manifestiraju na komprimiranim snimkama. Meteori mogu biti vrlo tamni, svega na pragu osjetljivosti kamere, a na drugom kraju spektra se nalaze vrlo sjajni meteori, tj. vatrene kugle koje mogu saturirati cijelo vidno polje kamere. Upravo te vatrene kugle predstavljaju najveći problem kod ovakve vrste kompresije – kada na određenom pikselu postoji više jednakih (no vremenski odvojenih) maksimalnih vrijednosti u bloku od 256 okvira, nasumično se odabire jedna od tih vrijednosti i zapisuje se samo njeno vrijeme pojavljivanja.

Slika 5.2 upravo je primjer problema koji susrećemo pri rekonstrukciji videa iz komprimiranih snimaka pri vrlo sjajnim meteorima. Na snimci se nalazi vatrena kugla snimljena iznad Ogulina 21. travnja 2015. godine.



Slika 5.2 Vatrena kugla iznad Ogulina 21. travnja 2015, *maxpixel* slika (gore), te nekoliko rekonstruiranih video okvira (dolje) koji pokazuju kompresijske artefakte

Gornji dio slike (iznad crvene linije) prikazuje maksimalne vrijednosti piksela na snimci. Donji dio slike prikazuje izdvojene okvire koji su rekonstruirani iz snimke. Može se primijetiti da rekonstruirani okviri nisu popunjeni, nego da se oblik same vatrene kugle nazire iz šumovite rekonstrukcije. Problem nastaje pri određivanju centroida vatrene kugle sa svakog rekonstruiranog okvira, a pošto je u prethodnom poglavlju utvrđeno da pogreška od samo jednog piksela može rezultirati velikom prostornom pogreškom, očito je da mora postojati bolji način čuvanja podataka o vatrenim kuglama.

Pošto su vatrene kugle iznimno važne, a ovoj tvrdnji pridonose brojne meteorske mreže posebno namijenjene njihovom snimanju [1], bilo je potrebno razviti rješenje očuvanja nekomprimiranih snimaka vatrenih kugli. Sirove snimke pružaju mnogo bolji uvid u stvarni položaj i svjetlinu vatrene kugle od okvira rekonstruiranog iz komprimiranih snimaka. Ekstrakcija sirovih snimaka vatrenih kugli rađena je u sklopu programa Skypatrol razvijenog oko 2003. godine koji je detektirao vatrene kugle u stvarnom vremenu i izrezivao isječke dimenzija 80×80 piksela iz sirovog videa. Na žalost, izvorni kôd Skypatrol programa nije dostupan. Rad koji opisuje program nikada nije objavljen, niti je program trenutno igdje dostupan za preuzimanje. Jedina inačica kojoj je autor ovoga rada imao pristup dobivena je iz arhiva Hrvatske meteorske mreže.

6. POSTUPAK DETEKCIJE VATRENIH KUGLI

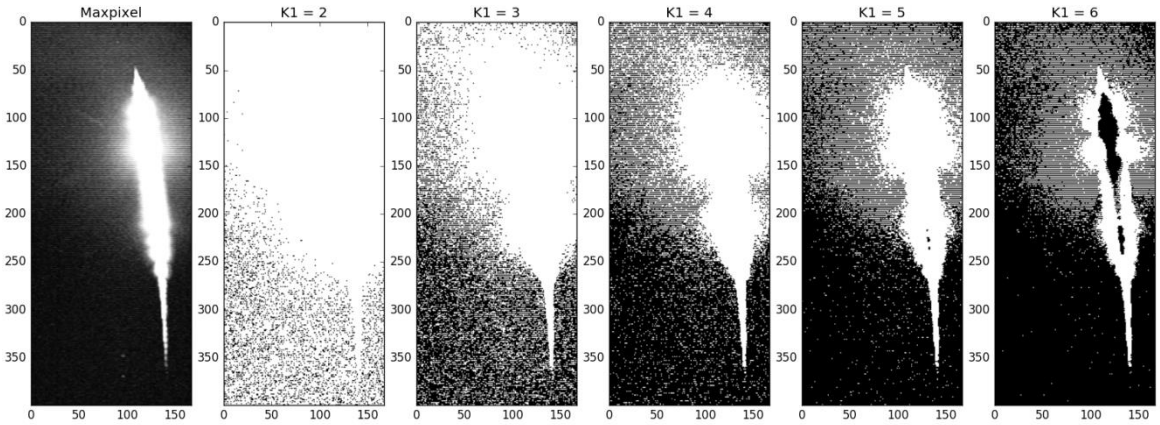
Prva verzija ovoga algoritma predstavljena je u [8], a zatim je unaprijeđeno rješenje detaljno opisano kao dio seminarskog rada za kolegij Robotski vid [52]. Pošto je algoritam već opisivan, u ovome radu će biti dan skraćeni opis.

6.1. Binarizacija slike

Ulazni podaci u detektor vatrenih kugli su FF datoteke i sirovi video okviri. Kako bi se detektirali značajni porasti u svjetlini slike s obzirom na pozadinu, provodi se binarizacija slike operacijom danom u jednadžbi (6-1).

$$T(P_{max}, \bar{P}, \sigma, K_1) = \begin{cases} 1, & (P_{max} > \bar{P} + K_1\,\sigma)\ i\ (P_{max} > 40) \\ 0, & inače \end{cases} \qquad (6\text{-}1)$$

pri čemu je P_{max} slika maksimalnih vrijednost piksela, $\bar{P}$ slika srednjih vrijednost piksela te σ slika standardnih devijacija. S K_1 određuje se koliko standardnih devijacija iznad pozadine maksimalna vrijednost mora biti da se uzme kao dio vatrene kugle. U funkciju je uključen uvjet da vrijednost piksela mora biti najmanje 40, pošto postoje situacije kada su srednja vrijednost i standardna devijacija vrlo male, te bi tamni dijelovi slike bili proglašeni dijelom meteora. Izabrana je vrijednost od $K_1 = 4$ na temelju mnogobrojnih eksperimenata na snimkama vatrenih kugli [52]. Slika 6.1 prikazuje utjecaj različitih vrijednosti parametra K_1 na binarizaciju snimke.



Slika 6.1 Primjena binarizacije s raznim vrijednostima parametra K_1

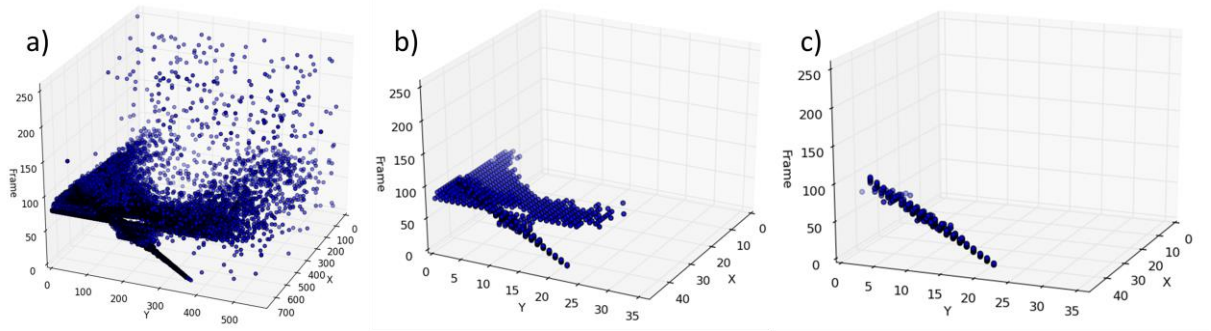
Kao što se može vidjeti s dane slike, vrijednosti K_1 niže od 4 uzrokuju previše bijelih piksela oko vatrene kugle. Vrijednosti iznad 4 uzrokuju pojavu crnih dijelova unutar vatrene kugle – uzrok tome su vrlo visoke vrijednosti standardne devijacije u središtu vatrene kugle. Kada se te visoke vrijednosti pomnože s višom vrijednosti parametra K_1, relacija $\bar{P} + K_1\,\sigma$ može poprimiti vrijednost višu od 255, tj. najveću moguću vrijednost intenziteta 8 bitnih slika, što uzrokuje

tamne dijelove slike. Ako je ipak tako visoka vrijednost parametra K_1 zaista potrebna, moguće je ograničiti vrijednost relacije $\bar{P} + K_1\,\sigma$ na 254 kako bi se dobilo ispravno ponašanje. No pošto bi implementacija tog postupka uzrokovala blago usporenje algoritma, a visoke vrijednosti parametra K_1 nisu korištene, u ovome radu ta mogućnost nije implementirana.

Slijedeći opisanu proceduru, pikseli na slici sada mogu imati jednu od dvije vrijednosti: 1 (bijeli pikseli) ili 0 (crni pikseli).

6.2. *Subsampling* binarizirane snimke

Pošto CAMS FTP format sadrži i informaciju o vremenu pojavljivanja maksimalne vrijednosti za svaki piksel, obrađenu sliku je moguće prikazati kao 3D oblak točaka: X i Y osi predstavljaju osi slike, dok Z osi predstavlja vremensku os. Dobiveni 3D oblak točaka može se vidjeti na slici 6.2, umetak a).



Slika 6.2 Koraci u predobradbi podataka za detekciju vatrenih kugli

Kako bi se dodatno uklonio šum sa slike i dodatno smanjio ukupan broj točaka, provodi se *subsampling*. *Subsampling* je redukcija rezolucije snimke za određeni faktor. No pošto se radi o binariziranoj slici, potrebno je odlučiti kada će određeni reducirani piksel biti proglašen svijetlim, a kada tamnim pikselom. Stoga možemo definirati prozor od N×N piksela na koje će slika biti podijeljena, a ako unutar prozora postoji dovoljan broj svijetlih piksela reducirani piksel na mjestu tog prozora ćemo proglasiti svijetlim.

Kroz oblak točaka se prolazi blokovima veličine 16×16×256. Ako je broj točaka unutar bloka manji od 8, cijeli blok se odbacuje. Ako je broj točaka jednak ili veći od 8, blok se uzima u obzir. Rezultat *subsamplinga* prikazan je na slici 6.2, umetak b). Pošto vatrene kugle mogu imati vrlo sjajne bljeskove (u oblaku točaka prikazane kao ravnine okomite na vremensku os s mnogo točaka), implementiran je algoritam koji ih uklanja. Primjer takva oblaka točaka prikazan je na slici 6.2, umetak b), gdje se može primijetiti ravnina točaka oko vrijednosti 90 na vremenskoj osi. Algoritam pretražuje oblak točaka u potrazi za takvim ravnina, te ih detektira kao okvire koji

imaju barem 10 puta više točaka od medijana broja točaka svih okvira. Slika 6.2, umetak c), prikazuje oblak točaka s uklonjenim bljeskom.

6.3. Postupak detekcije vatrenih kugli na 3D oblaku točaka

Nakon opisanog postupka predobradbe rezultata na slici 6.2, umetak c), očito je da su vatrene kugle predstavljene kao dužine u 3D oblaku točaka. Stoga je razvijen novi algoritam za detekciju dužina te je implementiran koristeći Cython biblioteku.

Prvo, točke se sortiraju po okvirima na kojima se nalaze, tj. kronološki. Zatim algoritam uparuje svaku točku sa svakom i aproksimira pravac kroz njih. Oko svakog aproksimiranog pravca se određuje broj točaka u njegovoj okolini. Okolina je definirana kao valjak fiksnog polumjera u čijoj sredini se nalazi aproksimirani pravac. Algoritam vrednuje pravac po broju točaka unutar valjka i njihovoj udaljenosti od pravca i računa njihovu težinsku sumu. Što je točka bliže pravcu, algoritam ju vrednuje većom vrijednosti. Nadalje, ako algoritam naiđe na veći prekid u koncentraciji točaka, rješenje se odbacuje jer je cilj pronaći kompaktnu dužinu. Dužina s najvećom kumulativnom vrijednosti se odabire, točke od kojih je sadržana se uklanjaju iz oblaka točaka i algoritam radi rekurzivno sve dok ne pronađe sve zadovoljavajuće linije u oblaku točaka. Pseudo kôd algoritma dan je u prilogu 1.

Algoritam za detekciju dužina ima vremensku kompleksnost $O(N^3)$ u najgorem slučaju, te pošto postoje ograničenja na vremensko izvođenje algoritma, maksimalan broj točaka koje se šalju u algoritam ograničen je na 1000. Ako originalni broj točaka sadrži više točaka od tog broja, 1000 točaka se odabire nasumično. Po principu rada, razvijeni algoritam je sličan RANSAC algoritmu [55], iako novi algoritam sadrži nekoliko ključnih razlika koje mu omogućuju potragu na ograničenim dužinama, za razliku od neograničenih pravaca. Kada je vatrena kugla locirana u oblaku točaka, poznat je točan raspon video okvira na kojima se nalazi. Stoga algoritam te video okvire iz privremene sprema u trajnu memoriju za naknadnu ručnu obradu.

Izvedba detektora vatrenih kugli ocjenjena je na temelju stotinjak snimaka vatrenih kugli iz arhiva Hrvatske meteorske mreže. Raspon svjetlina uspješno detektiranih vatrenih kugli je od onih koji saturiraju pola slike, do meteora nulte zvjezdane magnitude svjetline. Nakon analize rezultata zaključeno je da je detektor vatrenih kugli dovoljno robustan i pogodan za svoju svrhu korištenja.

7. POSTUPAK DETEKCIJE METEORA

Kako bi se smanjilo ukupno vrijeme izvršavanja algoritma, postupak detekcije zvijezda na slici (opisan u poglavlju 8) se izvršava prije detekcije meteora. Ako je broj detektiranih zvijezda nizak, što znači da nebo nije vedro, postupak detekcije meteora se neće izvršavati. Kada je nebo vedro, postupak obrade slike uključuje i detekciju meteora.

Postupak detekcije meteora se sastoji od predobradbe pri čemu se izdvajaju meteori sa slike i slika se priprema za postupak detekcije linija. Pošto je korišteni algoritam detekcije linija specifičan po tome što zahtjeva da su sve linije na slici vrlo tanke, postupak predobradbe sadrži procedure za stanjivanje linija.

Potom se slika šalje u algoritam za detekciju linija pod nazivnom *Kernel-based Hough Transform* [58] koji pronalazi linije na slici.

Konačno, algoritam provjerava propagira li detektirana linija kroz vrijeme te izračunava centroid i mjerenje intenziteta sjaja točke meteora na svakome okviru.

7.1. Predobradba snimke meteora

Pošto CAMS format kompresije sprema maksimalne i prosječne vrijednosti svakog piksela sa slike unutar bloka od 256 video okvira, i njihovu standardnu devijaciju, moguće je binarizirati sliku tako da se pronađu događaji na slici svjetliji od pozadine. Binarizacija se provodi funkcijom (7-1).

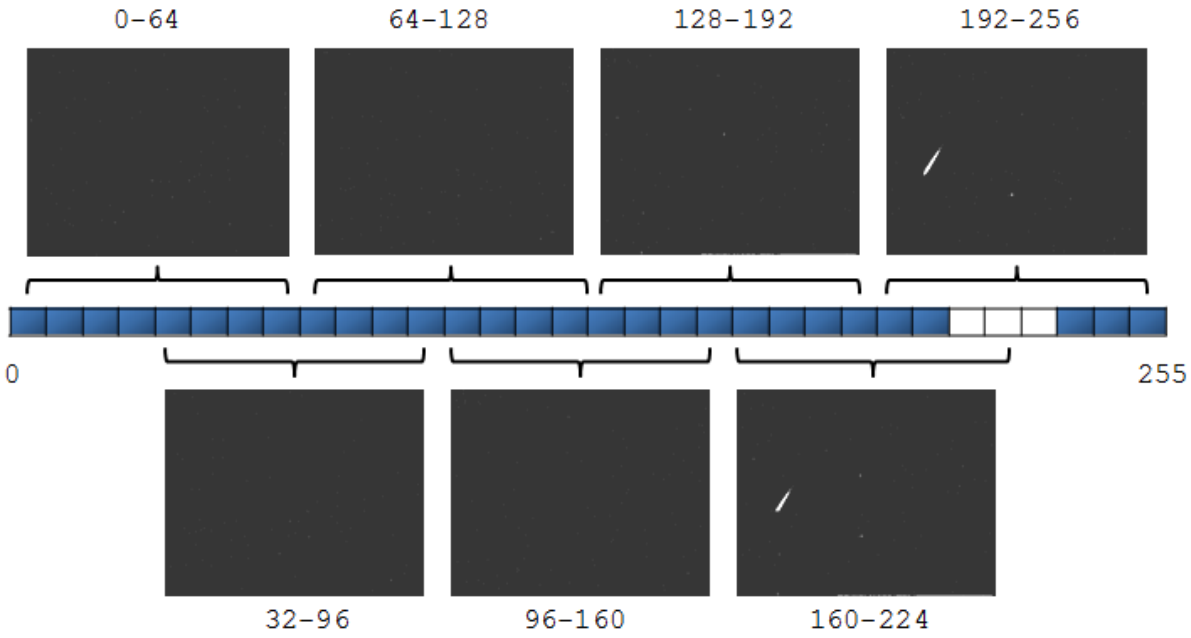
$$T(P_{max}, \bar{P}, \sigma, K_1, J_1) = \begin{cases} 1, & P_{max} > \bar{P} + K_1\,\sigma + J_1 \\ 0, & inače \end{cases} \tag{7-1}$$

pri čemu je P_{max} slika maksimalne vrijednosti piksela, $\bar{P}$ slika srednje vrijednosti piksela te σ slika standardnih devijacija. K_1 je težinski faktor kojim određujemo koliko standardnih devijacija iznad pozadine maksimalna vrijednost mora biti da se uzme kao dio meteora, a J_1 je apsolutni faktor koji dodaje ukupnom pragu svjetline minimalnu pozadinsku svjetlinu. Kombinacija faktora $K_1 = 1.7$ i $J_1 = 9$ pokazala se optimalnom za diskriminaciju meteora od pozadinskog šuma.

Nakon što je slika binarizirana, algoritam provjerava omjer između broja svijetlih piksela na slici (imaju vrijednost 1 nakon binarizacije) i ukupnog broja piksela slike. Ako binarizirani pikseli zauzimaju više od 5% ukupnog broja, snimka se odbacuje. Razlog ove operacije jest slučaj kada Mjesec obasjava rubove oblaka što može prouzročiti mnogo svijetlih piksela na slici, te značajno

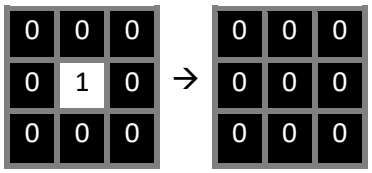
usporiti procedure za detekciju meteora. Ovime se gube meteori koji se nalaze između oblaka, no smatramo da je to prihvatljiv kompromis s obzirom na velika ograničenja na dostupnu računalnu moć.

Pošto jedna komprimirana snimka sadrži informacije s 256 video okvira, moguće je rekonstruirati svaki od njih iz snimke. Kako bi se smanjila razina šuma, cijeli blok od 256 okvira se ne analizira istovremeno, nego se rekonstruira samo segment od 64 okvira iz FF datoteke. Početni okvir svakog segmenta se pomiče za 32 okvira, čime se dobiva 7 takvih segmenata koji pokrivaju raspone: 1-64, 32-96, 64-128, 96-160, 128-192, 160-224 i 192-256. Segmenti se preklapaju u vremenu kako bi se izbjeglo „curenje“ meteora koji pokrivaju više segmenata. Spomenuti segmenti nisu skup cijelih 64 nezavisnih okvira, nego se radi o jednoj slici koja sadrži maksimalne vrijednosti piksela koji su se dogodili u rasponu od spomenutih 64 okvira. Slika 7.1 prikazuje opisanu proceduru i pojedine rekonstruirane segmente.



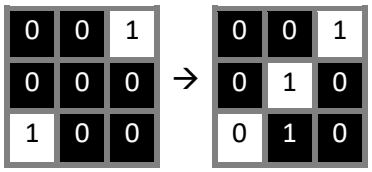
Slika 7.1 Rekonstruirani segmenti okvira. Meteor se pojavljuje u rasponu od 211. do 228. okvira.

Na pojedinim rekonstruiranom segmentima provodi se nekoliko slikovnih morfoloških operacija [56]. Prvo se provodi morfološka operacija čišćenja, tj. uklanjanje izoliranih piksela. Izolirani pikseli su oni pikseli kojima su svih 8 najbližih susjeda tamni pikseli. Ova operacija uklanja većinu šuma na slici. Slika 7.2 ilustrira opisanu operaciju.



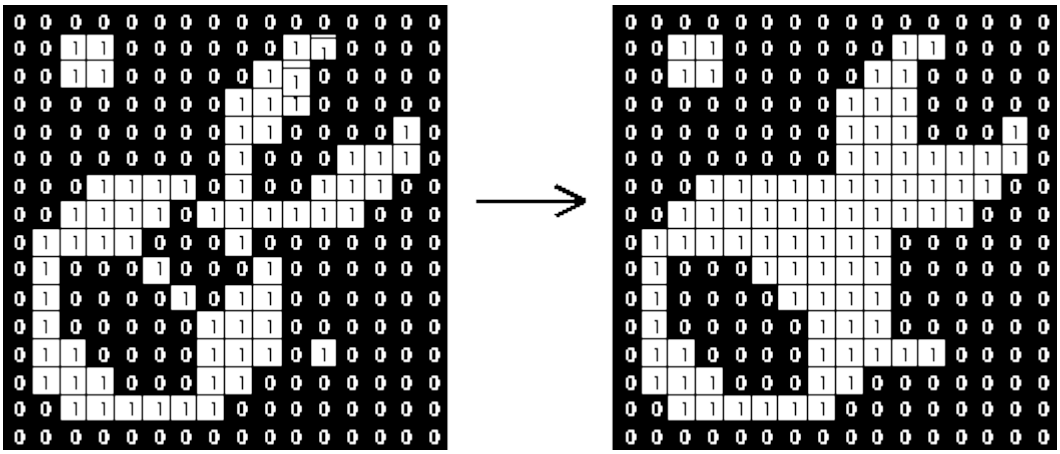
Slika 7.2 Morfološko čišćenje

Zatim se izvršava morfološka operacija premošćivanja – ova operacija spaja piksele na suprotnim stranama u prozoru veličine 3×3 piksela. Pomoću opisane operacije sve spajaju sve prekinute linije na slici. Slika 7.3 ilustrira opisanu operaciju za 1 od 4 mogućih orijentacija piksela unutar prozora veličine 3×3.



Slika 7.3 Morfološka operacija premošćivanja

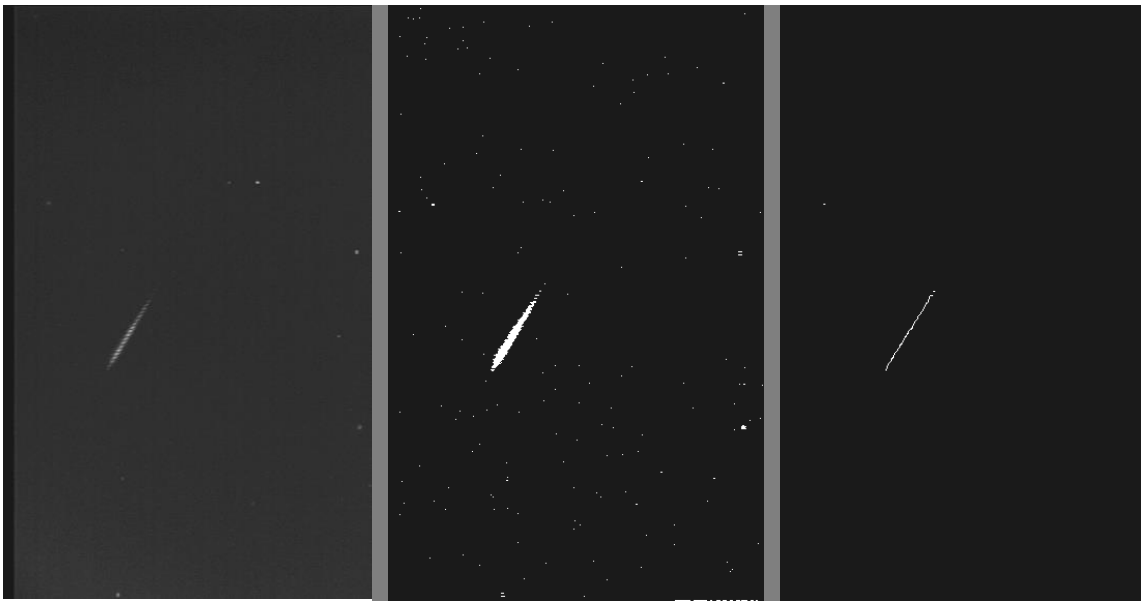
Nadalje, morfološka operacija zatvaranja se primjenjuje na slici. Morfološka operacija zatvaranja se sastoji od 2 individualne morfološke operacije: dilacija nakon koje slijedi erozija, koristeći isti strukturni element. Operacija zatvaranja se koristi kako bi se popunila tamna područja na slici koja se nalaze unutar svijetlih područja. Djelovanje ove operacije prikazano je na slici 7.4. Ovom operacijom se postiže popunjavanje rupa u binariziranom meteoru koje su ostale tamne zbog mogućih kompresijskih artefakata ili efekata kamere i digitalizatora.



Slika 7.4 Djelovanje morfološke operacije zatvaranja. Izvor: [57]

Kako bi se snimka pripremila za detektiranje linija, sve potencijalne linije moraju biti što je moguće tanje. Stoga se koristi Zhang-Suen [59] algoritam za stanjivanje koji obavlja skeletonizaciju slike, tj. stanjuje sve meteore na slici u vrlo tanke linije.

Konačno, morfološko čišćenje se opet provodi kako bi se uklonio sav šum sa slike preostao nakon stanjivanja. Sada je slika spremna za izvođenje algoritma za detekciju linija. Slika 7.5 prikazuje primjer procesa predobradbe snimke meteora. Lijeva slika prikazuje sliku meteora (*maxpixel*), slika u sredini prikazuje meteor nakon binarizacije, te slika desno prikazuje meteor nakon cijelog postupka predobradbe.



Slika 7.5 Originalna slika meteora (lijevo), binarizirana slika (sredina), slika nakon predobradbe (desno)

7.2. Kernel-based Hough Transform

Opisani postupak predobradbe snimke implementiran je zbog vrlo specifičnog načina rada odabranog algoritma za detekciju linija. Nakon perioda eksperimentiranja s raznim rješenjima za detekciju linija, odlučeno je koristiti *Kernel-based Hough Transform* (skraćeno KHT) [58] zbog njegove velike brzine izvođenja i performansi koje su nužne za implementaciju na Raspberry Pi 2 računalu. Autori KHT-a odlučili su kôd algoritma dati na slobodno korištenje što je omogućilo njegovo lako korištenje i za potrebe ovoga rada. Algoritam je implementiran u C++-u, a za njega je napisano Python sučelje koje omogućuje transparentno korištenje algoritma unutar cjelokupnog postupka detekcije meteora.

KHT se razlikuje od klasične implementacije Houghove transformacije [39] u tome što algoritam prije traženja linija obavlja traženje grupa približno kolinearnih značajki na slici, te za svaku grupu koristi orijentiranu eliptičnu jezgru pomoću koje se probabilistički glasa u Houghovom prostoru.

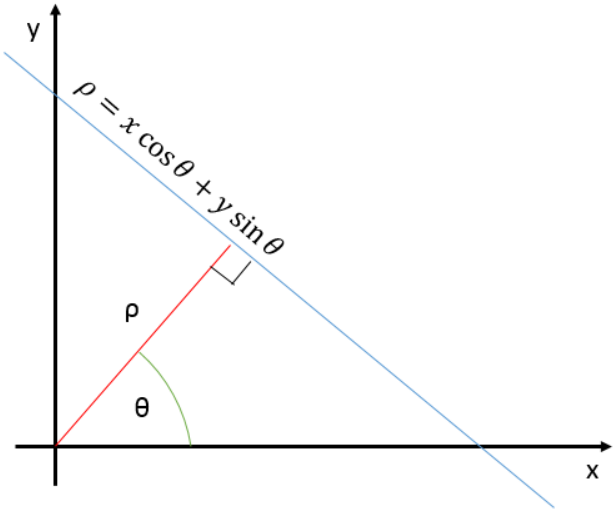
Kako bi objasnili što je Houghov prostor, potrebno je razmisliti o načinu parametrizacije pravca. Ako pravac predstavimo jednadžbom (7-2), pri čemu je m nagib pravca, a b odsječak na y-osi, vertikalne pravce ne bi bilo moguće zapisati u tome obliku jer je njihova jednadžba oblika $x = a$, gdje je a odsječak na x-osi.

$$y = mx + b \tag{7-2}$$

Nadalje, vrlo strmi pravci bi imali vrlo velik nagib i odsječak na y-osi, što može stvarati probleme pri zapisivanju u računalnu memoriju, tj. morala bi se koristiti polja većih dimenzija ili bitno smanjene rezolucije. Zbog navedenih problema, pravac se parametrizira pomoću parametara ρ i θ, pri čemu je pravac definiran jednadžbom (7-3) prvi puta korištenom u [39].

$$\rho = x\cos\theta + y\sin\theta \tag{7-3}$$

Parametar ρ predstavlja udaljenost od ishodišta koordinatnog sustava do najbliže točke pravca ishodištu, dok θ predstavlja kut između x-osi i linije koja spaja ishodište sa spomenutom najbližom točkom. Slika 7.5 ilustrira opisanu parametrizaciju.



Slika 7.6 Ilustracija parametrizacije pravca pomoću parametara ρ i θ

Važno je napomenuti da ishodište koordinatnog sustava može biti proizvoljno – na slikama se najčešće radi o gornjem lijevom kutu ili sredini slike. Nadalje, ako je slika dimenzija N×M i ishodište koordinatnog sustava je smješteno u sredinu slike, tada parametar ρ ima raspon vrijednosti $\left[-\frac{\sqrt{N^2+M^2}}{2}, \frac{\sqrt{N^2+M^2}}{2}\right]$, dok parametar θ ima raspon $[0°, 180°]$. Pošto se radi o računalnoj implementaciji algoritma, potrebno je izabrati korak diskretizacije δ pomoću kojega se diskretizira raspon parametara. Houghov prostor jest onda akumulatorska matrica dimenzija $\left\lceil\frac{\sqrt{N^2+M^2}}{\delta}\right\rceil \times \left\lceil\frac{180}{\delta}\right\rceil$. Algoritam zatim inkrementira vrijednost u akumulatorskoj matrici na položaju $\left(\left\lceil\frac{\rho}{\delta}\right\rceil, \left\lceil\frac{\theta}{\delta}\right\rceil\right)$ za svaki hipotetski pravac sa slike danih parametara ρ i θ. Unaprijeđena metoda generiranja glasova jest centralna ideja KHT-a, te autor preporuča čitanje originalnog rada [58] za bolje razumijevanje samog procesa glasovanja. Za grupe značajki sa slike koje su dobro orijentirane i nisu rasute, glasovi u Houghovom prostoru bivaju vrlo koncentrirani. Ovime

postupkom se eliminira glavni problem uobičajene implementacije Houghove transformacije, a to je velika rasutost glasova u Houghovom prostoru zbog čega je katkad teško identificirati prave maksimume u njemu, tj. dominantne linije na slici.

Poslije procesa glasovanja, algoritam odabire najdominantnije maksimume u Houghovom prostoru parametara (tj. pravce u Kartezijevom koordinatnom sustavu), te vraća njihov popis.

7.3. Detekcija linija na slici

Nakon predobradbe objašnjene u prethodnom poglavlju, slika se šalje u KHT algoritam koji nakon izvršavanja vraća popis identificiranih linija sa slike. Podsjetimo, svaka predobrađena slika koja se šalje u algoritam jest zapravo segment od 64 okvira. Nakon obrade svih 7 segmenata algoritam stvara ukupni popis pronađenih linija na slici. Pošto je moguće da algoritam detektira jednu liniju više puta na istoj slici ili na različitim segmentima, potrebno je objediniti slične linije. Kao mjera sličnosti među linijama korištena je Fréchetova udaljenost [60] kojom se računa najveća udaljenost među točkama koje su uzrokovane s linije. Svaka linija se uzorkuje s 10 točaka, te se računa Fréchetova udaljenost s ostalim prisutnim linijama. Eksperimentalno je određeno da kada dvije linije imaju Frécheovu udaljenost manju od 50 piksela može se reći da su dovoljno slične kako bi bile objedinjene.

Objedinjavanje linija se radi na način da se njihovi parametri ρ i θ preračunaju u Kartezijev koordinatni sustav pomoću izraza (7-4) i (7-5), izračuna se srednja vrijednost po pojedinim osima, te se usrednjeni parametri vrate u Hough prostor parametara pomoću izraza (7-6) i (7-7).

$$x = \rho \cos\theta \tag{7-4}$$

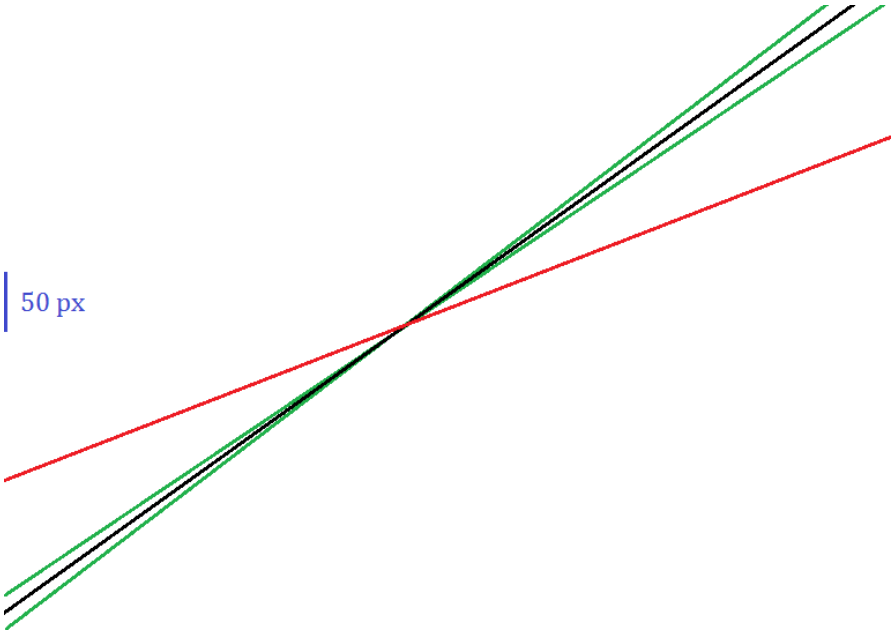
$$y = \rho \sin\theta \tag{7-5}$$

$$\rho = \sqrt{\bar{x}^2 + \bar{y}^2} \tag{7-6}$$

$$\theta = atan2(\bar{y}, \bar{x}) \tag{7-7}$$

Za vrijeme objedinjavanja, točni raspon video okvira na kojem su se pojedine linije pojavile i dalje se prati. Na primjer, ako su objedinjene dvije linije, prva iz segmenta 64-128, a druga iz segmenta 96-160, objedinjena linija imat će raspon video okvira od 64 do 160. Pomoću ovoga postupka zna se približno vrijeme pojavljivanja svake linije. Na slici 7.7 dan je prikaz rada algoritma za objedinjavanje linija. Zelene linije objedinjene su u crnu zbog njihove velike sličnosti, dok je crvena linija previše različita od ostalih kako bi bila objedinjena. Plavom bojom

označena je udaljenost od 50 piksela na slici – ako je najveća udaljenost među točkama linija manja od 50 piksela, linije će biti objedinjene, kao što je vidljivo na slici 7.7.



Slika 7.7 Prikaz rada algoritma za objedinjavanje sličnih linija

U ovome trenutku algoritam u memoriji drži popis svih pronađenih linija na snimci te njihovo približno vrijeme pojavljivanja. Ako je popis prazan, algoritam prekida proces detekcije i zaključuje da na slici nema meteora. Ako popis ipak sadrži barem jednu liniju, algoritam nastavlja s potvrđivanjem detekcije.

7.4. Provjera vremenske propagacije detektiranih linija

Kako bi se utvrdilo da je detektirana linija zaista meteor, potrebno je provjeriti propagira li kroz vrijeme. Pošto je približno vrijeme pojavljivanja meteora poznato poslije detekcije linija, ta činjenica se koristi kako bi se rekonstruirao segment video okvira danog raspona. Zatim se cijela slika maskira u crno osim trake debljine 50 piksela oko detektirane linije kako bi se izdvojio samo potencijalni meteor sa slike i uklonili ostali istovremeni događaji. Pošto korišteni CAMS FTP kompresijski format sadrži informacije o vremenu maksimalne vrijednosti svakog piksela sa slike, moguće je svakom pikselu u traci dati vremensku komponentu. Zatim se stvara 3D oblak točaka iz danih podataka, a meteor bi trebao biti kompaktna dužina u njemu. Ovo je identični problem koji se susreće pri detekciji vatrenih kugli te se stoga koristi i isti algoritam za detekciju dužina u 3D oblaku točaka, iako s promijenjenim parametrima detekcije kako bi se detektirale manje dužine. Maksimalni broj točaka koje algoritam prima ograničen je na 600, a ako je u oblaku točaka više od toga broja, 600 točaka biva nasumično odabrano.

Nakon izvršenja detekcije, algoritam za sve pronađene dužine definira točan vremenski trenutak (tj. okvir) početka i kraja, te njihove početne i krajnje točke na slici. Važno je napomenuti da algoritam odbacuje sve detekcije kraće od 4 okvira (0.16 sekundi pri 25 okvira u sekundi) zbog vrlo velikog broja tako kratkih događaja pri oblačnome vremenu. Ovo također znači da se ne detektiraju vrlo kratki meteori, no ovo ograničenje može u budućnosti biti ublaženo ako se poveća dostupna računalna moć za izvođenje algoritma.

U ovome trenutku detektirane linije s potvrđenom vremenskom propagacijom pružaju do sada najbolju informaciju o pravom sadržaju snimke. Pošto je moguće da je jedan te isti meteor detektiran nekoliko puta zbog pristupa s vremenskim segmentima, te vjerojatnosti da detektirane linije nisu bile dovoljno slične da se objedine u prošloj proceduri objedinjavanja, provodi se još jedan postupak traženja i spajanja sličnih linija. No u ovome trenutku posjedujemo informaciju i o vremenskoj dimenziji linije.

U postupku traženja sličnih linija, svaka pronađena linija se uspoređuje sa svakom. Neka je početna točka prve dužine trojka (X_{11}, Y_{11}, Z_{11}), a krajnja (X_{12}, Y_{12}, Z_{12}). Neka je početna točka druge dužine trojka (X_{21}, Y_{21}, Z_{21}), a krajnja (X_{22}, Y_{22}, Z_{22}). Prva dužina se može prikazati vektorom $\overrightarrow{\mathbf{v_1}} = (X_{12} - X_{11})\hat{\imath} + (Y_{12} - Y_{11})\hat{\jmath} + (Z_{12} - Z_{11})\hat{k}$, a druga dužina vektorom $\overrightarrow{\mathbf{v_2}} = (X_{22} - X_{21})\hat{\imath} + (Y_{22} - Y_{21})\hat{\jmath} + (Z_{22} - Z_{21})\hat{k}$. Nadalje, moguće je definirati vektor $\overrightarrow{\mathbf{v_3}}$ kojemu je početna točka jednaka početnoj točki prve, a krajnja točka jednaka krajnjoj točci druge dužine, $\overrightarrow{\mathbf{v_3}} = (X_{22} - X_{11})\hat{\imath} + (Y_{22} - Y_{11})\hat{\jmath} + (Z_{22} - Z_{11})\hat{k}$. Kako bi se provjerilo da su prva i druga dužina slične, moguće je izračunati kut između vektora $\overrightarrow{\mathbf{v_1}}$ i $\overrightarrow{\mathbf{v_3}}$, te kut između vektora $\overrightarrow{\mathbf{v_2}}$ *i* $\overrightarrow{\mathbf{v_3}}$ pomoću relacije (7-8).

$$\varphi = atan2(|\overrightarrow{\mathbf{v_A}} \times \overrightarrow{\mathbf{v_B}}|, \overrightarrow{\mathbf{v_A}} \cdot \overrightarrow{\mathbf{v_B}}) \qquad (7\text{-}8)$$

Ova dva kuta daju indikaciju o kolinearnosti dvije dužine - algoritam utvrđuje da su dvije dužine kolinearne ako su oba kuta ispod 20°. Zatim se vrši provjera postoji li preklapanje u okvirima. Ako postoji, uzima se najveći raspon okvira (prvi početak i zadnji kraj obje dužine), a X i Y koordinate se uzimaju od prve linije.

7.5. Određivanje centroida meteora

Nakon što je poznat točan raspon okvira i točan položaj meteora na slici, obavlja se rekonstrukcija pojedinačnog video okvira u rasponu okvira. Za svaki okvir uzima se samo traka širine 50 piksela oko linije meteora. Zatim se na svakom pojedinom okviru računa težinski centroid detekcije, pri čemu svjetliji pikseli imaju veću težinu. Koriste se relacije (7-9) za

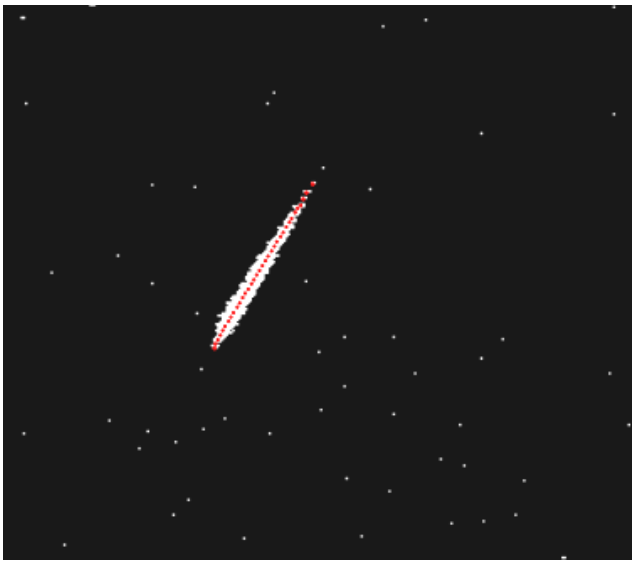
horizontalnu komponentu centroida i (7-10) za vertikalnu komponentu centroida. Relacije su preuzete iz [61, str. 218], iako uz malu prilagodbu.

$$\bar{x} = \frac{\sum x_i P_i}{\sum P_i} \tag{7-9}$$

$$\bar{y} = \frac{\sum y_i P_i}{\sum P_i} \tag{7-10}$$

Parametar x_i predstavlja horizontalnu koordinatu, y_i vertikalnu koordinatu, a P_i intenzitet danog piksela. Pošto korištena video kamera koristi *interlacing*, prije procesa centroidiranja razdvajaju se parni i neparni redovi okvira na polu-okvire, te se izračunavanje centroida provodi odvojeno na svakome. Ovime se postiže dvostruka vremenska rezolucija od 50 okvira u sekundi (za PAL format). Također se zapisuje i intenzitet svakog centroida kao suma svih intenziteta piksela na pojedinom polu-okviru. Zatim se obavlja filtriranje centroida tako što se odbacuju svi koji značajno odstupaju od pravca kroz centroide određenog linearnom regresijom.

Slika 7.8 prikazuje označene centroide meteora sa slike 7.5. Rezultati detekcije ispisuju se u CAMS-kompatibilni format pod nazivom FTPdetectinfo kojega je moguće koristiti za daljnju obradu podataka koristeći CAMS procedure [54].



Slika 7.8 Detektirani meteor s označenim centroidima

7.6. Rezultati postupka detekcije meteora

Kvaliteta izvedbe algoritma za detekciju meteora ocjenjena je na oko 100 pažljivo odabranih snimki meteora. Cilj je bio imati kvalitetan uzorak meteora različitog sjaja, duljine trajanja i brzine kako bi se procijenila uspješnost detekcije algoritma. Parametri algoritma su namještani dokle god svi meteori iz uzorka nisu uspješno detektirani.

Nadalje, postupak detekcije testiran je na 5 cjelovitih noći promatranja od kojih je svaka sadržavala preko 3000 pojedinih snimaka. Tipovi noći izabrani su da budu reprezentativni uzorak noći koje se može susresti tijekom cijele godine:

1. vedra noć bez mjesečine s nekoliko meteora,
2. oblačna noć s mjesečinom s malim brojem meteora,
3. noć s brzo putujućim oblacima osvjetljenih mjesečinom,
4. kišna noć u gradu (prisutno svjetlosno onečišćenje) s vidljivim padajućim kapljicama kiše,
5. oblačna i olujna noć s prisustvom munja.

Cilj ovih podataka bio je testirati robusnost algoritma i otpornost na lažne detekcije. Rezultati su uspoređeni s onima dobivenim programskim rješenjem MeteorScan koje se koristi kao dio CAMS procesa obrade podataka [54] u programskom rješenju FTP_CaptureAndDetect verzije 1.6. Rezultati usporedbe dani su u tablici 7.1.

Tablica 7.1 Usporedba detekcije meteora razvijenim rješenjem i CAMS detektora

Tip	Oznaka noći	Broj snimki	Ukupno vrijeme obrade	Vrijeme po snimci	Detekcije meteora		Lažne detekcije	
					Novi detektor	CAMS	Novi detektor	CAMS
1	VIB_20160419	3211	29390 s	9.15 s	14	11	53	18
2	OSE_20160417	3269	7770 s	2.37 s	0	2	9	61
3	VID_20160417	3263	37100 s	11.36 s	0	0	1679	304
4	OSO_20160419	3233	9430 s	2.91 s	2	4	36	2941
5	OSE_20160501	2950	2590 s	0.87 s	0	0	0	318
				UKUPNO	16	17	1777	3642

U usporedbi s CAMS detektorom, ukupan broj lažnih detekcija je značajno manji. Otkriveno je da je uzrok tome uvjet da se postupak detekcije ne izvodi ako na slici nema dovoljan broj zvijezda, stoga se eliminira većina lažnih detekcija na oblacima. S druge strane, postupak detekcije stvara mnogo lažnih detekcija kada su na dijelu slike prisutni brzo putujući oblaci, a drugi dio je vedar. Stoga algoritam po broju nađenih zvijezda zaključi da je nebo dovoljno vedro i nastavlja s postupkom detekcije. Ovaj problem biti će riješen u budućim inačicama programskog rješenja uvođenjem postupka za uklanjanje detekcija na oblacima.

Ukupan broj detektiranih meteora bio je manji. Nakon pažljive usporedbe, utvrđeno je da su detekcije koje nedostaju one kraće od 4 video okvira i meteori među oblacima, koje novi postupak detekcije automatski odbacuje. S druge strane, tijekom vedre noći novi postupak detekcije ponaša se slično kao CAMS detektor. Prave razlike ne mogu se utvrditi bez puno detaljnije analize, no važno je napomenuti da je novi postupak detekcije u nekoliko slučajeva detektirao više meteora nego CAMS detektor (barem na testiranim podacima i parametrima koje koristi Hrvatska meteorska mreža). Nadalje, na svim testiranim podacima algoritam nije prešao maksimalno srednje vrijeme detekcije po snimci. Maksimalno srednje vrijeme trajanja detekcije po snimci za korištene podatke na Raspberry Pi 2 računalu bilo je 11.5 sekundi, uključujući postupak detekcije zvijezda i postupak detekcije meteora, što je unutar vremenskog ograničenja od 30 sekundi po snimci.

Iako je novi postupak detekcije imao sličan broj detektiranih meteora kao i CAMS detektor, daljnje analize detekcije su potrebne. No sudeći po ovim prvim rezultatima, može se zaključiti da je razvijeni postupak detekcije meteora prihvatljivo rješenje za astronome amatere koji koriste minijaturna računala kao glavni računalni pokretač svojih meteorskih stanica. Prostor za poboljšanja postoji i nada je da će u budućim inačicama programskog rješenja biti implementiran bolji algoritam detekcije meteora. Dobar kandidat postoji u novom algoritmu predstavljenom u [62].

Pošto je sustav zamišljen kao potpuno automatizirano rješenje, ručno potvrđivanje i filtriranje detekcije meteora nije dio postupka obrade. Lažne detekcije biti će odbačene za vrijeme izračuna orbita meteora jer lažne detekcije neće tvoriti ostvarive orbite s detekcijama s drugih stanica. Usprkos tome, ručno pregledavanje i potvrđivanje detekcija meteora moguće je koristeći postojeća rješenja koja su kompatibilna s CAMS formatom podataka, npr. CMN_binViewer [63].

8. POSTUPAK DETEKCIJE ZVIJEZDA

Kako bi se obavila kalibracija intrinzičnih i ekstrinzičnih parametara video kamere te dobila baza za astrometrijsko rješenje, potrebno je detektirati zvijezde prisutne na svakoj snimci. Stoga je razvijen novi algoritam za detekciju zvijezda na datotekama CAMS FTP formata. Algoritam uzima sliku sa srednjim vrijednostima piksela (*avepixel*) te računa srednju vrijednost cijele slike. Kako bi se brzo provjerilo treba li algoritam nastaviti s radom, izračunata srednja vrijednost se uspoređuje sa zadanim pragom svjetline. Ako je srednja vrijednost slike veća od zadanog praga, slika se odbacuje kao presvijetla, tj. snimljena za vrijeme dana ili oblačnog vremena (ako su oblaci osvjetljeni javnom rasvjetom). Ako je srednja vrijednost ispod praga, algoritam nastavlja s radom.

Zatim algoritam na sliku primjenjuje funkciju inverznog hiperboličnog sinusa na svaki piksel slike. Ova funkcija pojačava srednje intenzitete slike što pomaže zvijezdama na slici da se istaknu od pozadine. Slika se zatim normalizira na standardni 8 bitni raspon od 0 do 255.

Nakon toga, algoritam na sliku primjenjuje maksimum i minimum filtere [64]. Maksimum filter je operacija koja sa zadanom veličinom jezgre prelazi svaki piksel slike, te njegovu vrijednost zamjenjuje najvećom vrijednosti unutar susjedstva definiranog veličinom jezgre. Minimum filter je slična operacija koja vrijednost razmatranog piksela zamjenjuje najmanjom vrijednosti iz susjedstva. Algoritam koristi veličinu jezgre 10×10. Prvo se primijeni maksimum filter, a zatim se primjeni minimum filter na kopiju slike stvorenu prije primjene maksimum filtera. Razlika između dvije stvorene slike se binarizira pragom intenziteta 5. U konačnici, ovo znači da će algoritam pronaći sve točkaste značajke na slici koje su barem 5 razina iznad njihove pozadine. Zatim se sve značajke identificiraju i računa im se centar mase. Ovime postupkom dobiva se popis približnih lokacija kandidata zvijezda na slici.

Kako bi se utvrdilo da je zaista riječ o zvijezdama i bolje se utvrdila njihova pozicija, provodi se regresija funkcije širenja točkastog izvora (engl. *point spread function,* ukratko PSF) [72]. Izabrana funkcija širenja točkastih izvora je dvodimenzionalna Gaussova funkcija – iako ona savršeno ne predstavlja točkaste izvore snimljene kamerom, za svrhe video snimaka meteora gdje ne postoji velika fotometrijska preciznost ona je zadovoljavajuća pretpostavka. Dvodimenzionalna Gaussova funkcija u programskoj implementaciji definirana je jednadžbama od (8-1) do (8-4).

$$a = \frac{cos^2\theta}{2\sigma_x^2} + \frac{sin^2\theta}{2\sigma_y^2} \tag{8-1}$$

$$b = -\frac{sin\,2\theta}{4\sigma_x^2} + \frac{sin\,2\theta}{4\sigma_y^2} \tag{8-2}$$

$$c = \frac{sin^2\theta}{2\sigma_x^2} + \frac{cos^2\theta}{2\sigma_y^2} \tag{8-3}$$

$$f(x,y) = Ae^{-(a(x-x_0)^2 - 2b(x-x_0)(y-y_0) + c(y-y_0)^2)} + B \tag{8-4}$$

Parametar A jest amplituda funkcije, x_0 i y_0 su koordinate položaja središta funkcije, σ_x i σ_y su standardne devijacije po osima, θ je rotacija funkcije, a B je vertikalan odmak amplitude.

Regresija metodom najmanjih kvadrata (koristeći funkciju optimize.curve_fit iz SciPy biblioteke) vrši se na prozoru veličine 9×9 piksela oko pronađenih mogućih lokacija zvijezda. Pošto se regresija vrši numerički, početni parametri eksperimentalno su procijenjeni tako da prave zvijezde što prije konvergiraju prema rješenju. Stoga ako algoritam ne nađe rješenje unutar ograničenog broja koraka (ograničeno na 150), kandidat se odbacuje. Ovaj postupak se pokazao dobrim načinom za razlikovanje pravih zvijezda od lažnih detekcija. Nadalje, ako je regresija uspješno odrađena, ispituje se matrica kovarijance funkcije. Ako je funkcija previše uska, kandidat se odbacuje kao defekt senzora, tj. rječnikom astronoma, kao *hot pixel*. Kao posljedica regresije, lokacija svake pronađene zvijezde je poznata vrlo precizno, na podpikselnoj razini. Intenzitet svake zvijezde računa se kao volumen ispod dvodimenzionalne Gaussove funkcije, relacijom (8-5).

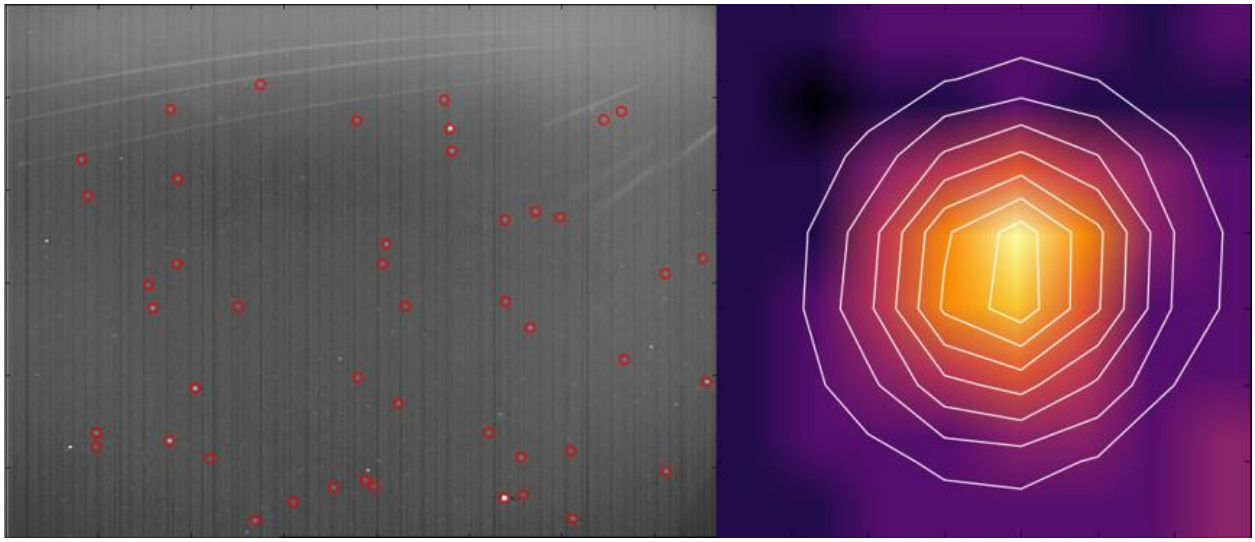
$$V = 2\pi A\sigma_x\sigma_y \tag{8-5}$$

Konačno, pronađene zvijezde se zapisuju u CALSTARS datoteku koja je dio standardnog CAMS formata. Na ovaj je način moguće po potrebi izvršiti kalibraciju podataka koristeći postojeće procedure CAMS obrade podataka.

8.1. Rezultati postupka detekcije zvijezda

Rezultati razvijenog algoritma uspoređeni su s rezultatima CAMS FTP_CalStarExtractor programskog rješenja. Zaključeno je da novo rješenje detektira vrlo malo lažnih detekcija, svega oko 5%, dok FTP_CalStarExtractor često detektira više lažnih detekcija nego zvijezda. Nadalje, novi algoritam ne stvara detekcije tijekom oblačnog vremena, stoga se njegovi rezultati mogu pouzdano koristiti za utvrđivanje vremenskih prilika za vrijeme snimanja.

Kada se usporedi broj detektiranih pravih zvijezda, novi algoritam detektira oko 90% broja zvijezda detektiranih CAMS detektorom. Prosječan broj detektiranih zvijezda po snimci na korištenim podacima bio je oko 30. Pošto je broj snimaka tijekom tjedne noći nekoliko tisuća, ukupan broj detektiranih zvijezda u jednoj noći je u desecima tisuća. Slika 8.1 prikazuje označene detekcije zvijezda na snimci (lijevo), te rezultat regresije Gaussove funkcije kao konture oko jedne zvijezde (desno).



Slika 8.1 Primjer rezultata algoritma za detekciju zvijezda

9. PROCEDURE ASTROMETRIJE I FOTOMETRIJE

9.1. Astrometrija

Astrometrija je postupak određivanja točnih nebeskih koordinata (rektascenzije i deklinacije) iz slikovnih koordinata uz pomoć parametara astrometrijskog rješenja za danu kameru [61].

Za lakši izračun i razumijevanje, astrometrijske transformacije možemo podijeliti u dva koraka:

- Transformacija iz slikovnih koordinata (x, y) u horizontski koordinatni sustav (azimut, visina)
- Transformacija iz horizontskog koordinatnog sustava (azimut, visina) u nebeski ekvatorski koordinatni sustav (rektascenzija, deklinacija)

Za izračun azimuta (*Az*) i visine (*Alt*) iz slikovnih koordinata, potrebno je znati geografski položaj promatrača na Zemlji (geografsku dužinu λ, geografsku širinu φ), referentne nebeske koordinate centra slike (referentnu rektascenziju α_0, referentnu deklinaciju δ_0, referentni satni kut H_0, pozicijski kut ρ). Transformacija se obavlja relacijama (9-1) do (9-14), te se dobiva azimut (*Az*) i visina (*Alt*). Sve jedinice izražene su u radijanima. Dio relacija je preuzet iz programskog paketa PIXY [65], a dio je razrađen Turnerovom metodom [66].

$$r = \sqrt{x^2 + y^2} \tag{9-1}$$

$$\theta = \left(\frac{\pi}{2} - \rho + atan2(y, x)\right) mod\ 2\pi \tag{9-2}$$

$$s_1 = \sin\delta_0 \cos r + \cos\delta_0 \sin r \cos\theta \tag{9-3}$$

$$d_1 = atan2\left(s_1, \sqrt{1 - s_1^2}\right) \tag{9-4}$$

$$s_2 = \frac{\sin\theta \sin r}{\cos d_1} \tag{9-5}$$

$$c_1 = \frac{\cos r - \sin d_1 \sin\delta_0}{\cos d_1 \cos\delta_0} \tag{9-6}$$

$$k = \alpha_0 - (atan2(s_2, c_1)\ mod\ 2\pi) \tag{9-7}$$

$$h = H_0 + \varphi - k \tag{9-8}$$

$$X_0 = -\cos h \cos d_1 \sin\lambda + \sin d_1 \cos\lambda \tag{9-9}$$

$$Y_0 = -\sin h \cos d_1 \tag{9-10}$$

$$Z_0 = \cos h \cos d_1 \cos \lambda + \sin d_1 \sin \lambda \quad (9\text{-}11)$$

$$R = \sqrt{X_0^2 + Y_0^2} \quad (9\text{-}12)$$

$$Az = atan2(Y_0, X_0)\ mod\ 2\pi \quad (9\text{-}13)$$

$$Alt = atan2(Z_0, R) \quad (9\text{-}14)$$

Zatim se dobiveni azimut i visina preračunavaju u rektascenziju α i deklinaciju δ relacijama (9-15) do (9-21). Za ovaj postupak potrebno je znati geografsku dužinu promatrača λ, i točan Julijanski dan vremena promatranja *JD*. Dio korištenih relacija preuzet je iz [67].

$$X_A = -\sin Az \cos Alt \quad (9\text{-}15)$$

$$Y_A = -\cos Az \sin \lambda \cos Alt + \sin Alt \cos \lambda \quad (9\text{-}16)$$

$$HA = atan2(X_A, Y_A) \quad (9\text{-}17)$$

$$T = \frac{JD - 2451545}{36525} \quad (9\text{-}18)$$

$$H_0 = \Big(280.46061837 + 360.98564736629(JD - 2451545) + 0.000387933\mathrm{T}^2 - \frac{T^3}{38710000}\Big)\ mod\ 360 \quad (9\text{-}19)$$

$$\alpha = \Big(\frac{H_0 \pi}{180} + \lambda - HA\Big)\ mod\ 2\pi \quad (9\text{-}20)$$

$$\delta = \sin^{-1}(\sin \lambda \sin Alt + \cos \lambda \cos Alt \cos Az) \quad (9\text{-}21)$$

Iz relacija (9-1) do (9-21) evidentno je da je uz lokaciju na slici, vrijeme pojavljivanja meteora i lokaciju promatrača na Zemlji, potrebno imati i 4 ostala parametra (α_0, δ_0, H_0, ρ). Stoga je cijeli problem astrometrije sveden na estimaciju tih parametara.

Pristup tome problemu u ovome radu se sastoji od 2 koraka:

1. Ručna estimacija parametara na temelju snimke
2. Ugađanje parametara iterativnim metodama

Svi parametri se mogu lako približno estimirati s preciznosti od nekoliko stupnjeva. H_0 je satni kut kojeg je moguće dobiti iz vremena promatranja (npr. vremena snimanja snimke). α_0 i δ_0 se dobivaju tako da se pogleda koja se zviježđa vide na slici, te se na karti neba približno pogleda koje koordinate rektascenzije i deklinacije pripadaju središtu snimke u danom trenutku.

Konačno, pozicijski kut ρ je otklon vertikalne osi slike od nebeskog pola koji se može dobiti tako da se gleda koliko vertikala kroz središte slike odstupa od nebeskog meridijana koji prolazi središtem slike.

Zatim se izvršava automatsko ugađanje parametara. Za taj postupak koristi se informacija o detektiranim zvijezdama sa slike. Iz CALSTARS datoteke, koja sadrži koordinate i intenzitete svih detektiranih zvijezda, nasumično se odabire 100 snimki iz cijele noći koje moraju ukupno sadržavati najmanje 500 zvijezda; broj je odabran prema savjetima iz [68]. Zatim se slikovne koordinate zvijezda uz pomoć početnih parametara pretvore u nebeske koordinate. Kako bi se procijenila kvaliteta parametara, potrebno je usporediti detektirane zvijezde s njihovim kataloškim položajima. Za ovu svrhu korišten je Yale Bright Star katalog [69]. Razvijen je algoritam koji traži najbliže susjede zvijezda na slici među zvijezdama iz kataloga unutar određenog praga udaljenosti. Za sve pronađene parove algoritam računa smjer i udaljenost odstupanja, a zatim odabire medijan obje vrijednosti. Pronađeno odstupanje se primjenjuje na astrometrijske parametre, postupak se ponavlja iterativno dok se ne postigne zadovoljavajuće slaganje u koordinatama, a u svakoj iteraciji se prag udaljenosti smanjuje kako bi se smanjio broj krivih parova. U svakoj iteraciji rješenje se procjenjuje omjerom standardne devijacije i ukupnog broja parova, stoga je cilj algoritma smanjiti vrijednost toga mjera, tj. smanjiti odstupanje i povećati broj parova.

Nakon ugađanja parametara astrometrije, čime je poznat smjer gledanja kamere i parovi zvijezda na slici s onima iz kataloga, potrebno je estimirati distorziju vidnog polja kamere. Optika kamere pati od radijalne distorzije koja je estimirana relacijama (9-22) za x-os i (9-23) za y-os, izvor relacija je [70].

$$f_x(x,y) = x + a_1 + a_2x + a_3y + a_4x^2 + a_5xy + a_6y^2 + a_7x^3 + a_8x^2y + a_9xy^2 + a_{10}y^3 + a_{11}x\sqrt{x^2+y^2} + a_{12}y\sqrt{x^2+y^2} \quad (9\text{-}22)$$

$$f_y(x,y) = y + b_1 + b_2x + b_3y + b_4x^2 + b_5xy + b_6y^2 + b_7x^3 + b_8x^2y + b_9xy^2 + b_{10}y^3 + b_{11}x\sqrt{x^2+y^2} + b_{12}y\sqrt{x^2+y^2} \quad (9\text{-}23)$$

Početni parametri za prvih 10 koeficijenata svake funkcije (a_1 do a_{10} i b_1 do b_{10}) mogu se dobiti uz pomoć programskog paketa PIXY [65], a ostali se mogu postaviti na 0. Automatsko ugađanje parametara vrši se Nelder-Mead SIMPLEX metodom [71]. Koristi se jednaka metoda procjene rješenja kao i za vrijeme ugađanja parametara astrometrije.

9.2. Fotometrija

Fotometrija meteora je metoda kojom se određuje sjaj meteora na snimci u jedinicama prividne zvjezdane magnitude. Kako bi se to postiglo, potrebno je usporediti sjaj meteora sa sjajem zvijezda za koje su poznate kataloške vrijednosti prividnih zvjezdanih magnituda. Na temelju kompletnog astrometrijskog rješenja uparuju se zvijezde sa slike sa zvijezdama iz Yale Bright Star kataloga. Za zvijezde na slici poznat je njihov instrumentalni intenzitet, a za zvijezde iz kataloga poznata je njihova prividna zvjezdana magnituda. Poznata je relacija (9-24) koja povezuje ta dva parametra [61, str. 272].

$$m_1 = -2.5 \log_{10} C_1 + 2.5 \log_{10} C_2 + m_2 \qquad (9\text{-}24)$$

m_1 je prividna zvjezdana magnituda meteora, C_1 je instrumentalni intenzitet meteora, a parametri C_2 i m_2 dobivaju se regresijom relacije (9-24) na spomenute podatke o zvijezdama metodom najmanjih kvadrata.

Važno je napomenuti da je ovaj pristup fotometriji vrlo jednostavan i u obzir ne uzima spektralnu osjetljivost kamere i spektralne karakteristike meteora. Nadalje, ne primjenjuje se korekcija za saturirane piksele na slici što može dovesti do podcjenjivanja pravog intenziteta meteora, pogotovo vatrenih kugli. Ovaj dio algoritma zahtjeva daljnji rad.

9.3. Rezultati astrometrije i fotometrije

Nakon dobivenih astrometrijskih i fotometrijskih parametara, primjenjuje se pretvorba slikovnih koordinata centroida meteora u nebeske koordinate, te pretvorba instrumentalnih intenziteta u prividne zvjezdane magnitude. Rezultati se spremaju u datoteku CAMS FTPdetectinfo formata.

Uspoređujući rezultate kalibracije novom predloženom metodom i postojeće procedure korištene unutar Hrvatske meteorske mreže [43], može se primijetiti da nova metoda ima bolju mogućnost automatskog ugađanja parametara te početni parametri ne trebaju biti toliko precizno određeni kao što zahtjeva stara metoda. Nadalje, ako uspoređujemo dobivene standardne devijacije koje oba rješenja prijavljuju na kraju postupka astrometrijske kalibracije, novo rješenje daje za red veličine manju standardnu devijaciju od stare metode (oko 0.05 piksela u usporedbi s 0.3 piksela za primjer jedne noći). Rezultati kalibracije nove metode su manje konzistentni od rezultata stare metode zbog nasumičnog odabira zvijezda na početku kalibracije pri čemu dobivena standardna devijacija nije jednaka između svakog pokretanja algoritma na istim podacima, no dobivene standardne devijacije su u svim slučajevima manje nego one dobivene starom metodom.

10.ZAKLJUČAK

U sklopu ovoga rada uspješno je razvijen, opisan i testiran sustav za automatsku detekciju meteora koji radi na Raspberry Pi 2 minijaturnom računalu. Kao baza za razumijevanje teorijskih osnova rada dan je teorijski uvod u meteorsku znanost i trenutno stanje u korištenoj tehnologiji za promatranje meteora na svjetskoj razini. Dan je kronološki pregled razvoja opisanog sustava, od ideje do predstavljanja na konferenciji *International Meteor Conference 2016*.

Na razmatranje su dani zahtjevi koje programsko rješenje mora zadovoljavati s obzirom na ograničenje računalne moći Rapsberry Pi 2 računala što je imalo utjecaja na ukupno vrijeme koje je algoritam mogao potrošiti na obradu snimki meteora. Dan je blokovski prikaz razvijenog sustava i pojašnjene su pojedine komponente i njihovo međudjelovanje.

Nadalje, opisana je metoda kompresije snimaka meteora kako bi se smanjilo ukupno zauzeće trajne memorije te je ukazano na probleme koje predložena kompresija uzrokuje. Kako bi se zaobišli kompresijski problemi koji su utjecali na vrlo svijetle meteore i vatrene kugle, razvijen je postupak detekcije vatrenih kugli u stvarnome vremenu koji sprema sirove video okvire vatrene kugle dok su još uvijek prisutni u privremenoj memoriji računala.

Kako bi rješenje imalo veću cjelovitost i iskoristivost, razvijen je postupak detekcije meteora koji koristi metode obrade slike i detekcije linija na slici. Dana je matematička pozadina iza postupka detekcije linija, te su uspoređeni rezultati dobiveni razvijenim rješenjem s rezultatima dobivenim postojećim rješenjima.

Kako bi se podaci o detektiranim meteorima mogli kalibrirati i biti korisni za daljnje znanstvene analize, bilo je potrebno provesti procedure astrometrije i fotometrije. Ove metode zahtijevaju podatke o zvijezdama na snimkama te je stoga razvijen postupak za njihovu detekciju. Postupak detekcije zvijezda uspješno je testiran i zaključeno je da radi dovoljno robusno za potrebe sustava. Konačno, dane su teorijske osnove za astrometrijsku i fotometrijsku kalibraciju te je razvijeno programsko rješenje koje obavlja ugađanje ručno procijenjenih kalibracijskih parametara.

Iako su pojedini dijelovi sustava radili unutar postavljenih zahtjeva, sustav je preostalo testirati u stvarnim uvjetima rada, tj. po noći za vrijeme snimanja meteora. Nadalje, programsko rješenje treba još bolje dokumentirati i učiniti ga pristupačnije korisnicima. Želja je autora da se sustav u budućnosti koristi i dalje razvija od ostalih zaljubljenika u meteorsku astronomiju.

LITERATURA

[1] J. Borovička, P. Spurný, P. Brown, „Small Near-Earth Asteroids as a Source of Meteorites“, Asteroids IV, 2015.

[2] N. Biliškov. „Meteori golim okom“, Sveučilišna knjižara, Zagreb, 2009.

[3] Z. Ceplecha, „Photographic Geminids 1955“, Bulletin of the Astronomical Institutes of Czechoslovakia, vol. 8, p.51, 1957.

[4] S. Molau, „M O V I E - Meteor Observation with VIdeo Equipment“, Proceedings of the International Meteor Conference 1993, p.71, 1994.

[5] S. Molau, M. Nitschke, M. de Lignie, R. L. Hawkes, J. Rendtel, „Video Observations of Meteors: History, Current Status, and Future Prospects“, WGN 25:1, p. 15-20., 1997.

[6] Ž. Andreić, D. Šegon, „Geminids from Croatian Meteor Network video data“, WGN, the Journal of IMO, Vol 36, No. 5, p. 99-104, 2008.

[7] Raspberry Pi – Review, http://www.pcmag.com/article2/0,2817,2407058,00.asp, (17. svibnja 2016.)

[8] D. Zubović, D. Vida, P. Gural, D. Šegon, „Advances in the development of a low-cost video meteor station“. Proceedings of the International Meteor Conference, Mistelbach, Austria, 27-30 August 2015, Eds.: Rault, J.-L.; Roggemans, P., International Meteor Organization, pp. 94-97., 2015.

[9] J. Borovička, „About the definition of meteoroid, asteroid, and related terms“, WGN, the Journal of the IMO 44:2, p. 31-34, 2016.

[10] Meteorit Lebanon na Marsu, http://www.space.com/26533-curiosity-mars-rover-meteorite-photos.html, (17. svibnja 2016.)

[11] F. Selsis, M. T. Lemmon, J. Vaubaillon, J. F. Bell III, „Extraterrestrial meteors: A martian meteor and its parent comet“, Nature, vol 435, p. 581, 2005.

[12] R. J. Weryk, P. Brown, „A Search for Interstellar Meteoroids Using the Canadian Meteor Orbit Radar (CMOR)“, Modern Meteor Science An Interdisciplinary View, Springer, pp 221-227, 2005.

[13] Hrvatski astronomski savez, slika uz vijest „Pogledajte meteorski roj Perzeidi“: http://www.astronomskisavez.hr/index.php/14-vijesti/204-pogledajte-meteorski-roj-perzeidi (22. listopada 2015.)

[14] P. Moore, R. Rees. „Patrick Moore's Data Book of Astronomy“ 2. izdanje, Cambridge University Press, 2011.

[15] P. Jenniskens, „Meteor Showers and their Parent Comets“. Cambridge University Press, 2006.

[16] D. J. Asher, „The Leonid meteor storms of 1833 and 1966“. MNRAS Vol. 307 919-924, 1999.

[17] Drvorez Leonidi 1833. godine, http://earthsky.org/todays-image/leonid-meteor-shower-1833, (17. svibnja 2016.)

[18] What Are Asteroids And Comets?, izvor: http://neo.jpl.nasa.gov/faq/#ast (26. listopada 2015.)

[19] Popis kometa s paraboličnim i hiperboličnim orbitama, izvor: https://en.wikipedia.org/wiki/List_of_hyperbolic_comets (26. listopada 2015.)

[20] A. Abedin, P. Spurný, P. Wiegert, P. Pokorný, J. Borovička, P. G. Brown. „On the age and formation mechanism of the core of the Quadrantid meteoroid stream“. Icarus Volume 261, pp. 100–117, 2015.

[21] Službeni popis meteorskih potoka Međunarodne astronomske unije: http://www.ta3.sk/IAUC22DB/MDC2007/Roje/roje_lista.php?corobic_roje=0&sort_roje=0 (17. svibnja 2016.)

[22] Z. Ceplecha, „Multiple fall of Příbram meteorites photographed. 1. Double-station photographs of the fireball and their relations to the found meteorites“. Bulletin of the Astronomical Institutes of Czechoslovakia, 12, 21-47, 1961.

[23] A. Olech, P. Zoladek, M. Wisniewski, Krasnowski M.,M. Kwinta, T. Fajfer, K. Fietkiewicz, D. Dorosz, L. Kowalski, J. Olejnik, K. Mularczyk, and K. Zloczewski. „Polish Fireball Network“. Proceedings of the International Meteor Conference, Oostmalle, Belgium, pp. 53–62, 2006.

[24] Hans Betlem, -10m Leonid fireball. November 17, 1997, izvor: http://dmsweb.home.xs4all.nl/leonids/1997/leo_1997_results.htm (26. listopada 2015.)

[25] P. G. Brown. et al. „A 500-kiloton airburst over Chelyabinsk and an enhanced hazard from small impactors“. Nature 503, 238-241., 2013

[26] SonotaCo: http://sonotaco.com/e_index.html (12. lipnja 2016.)

[27] J. Toth, L. Kornoš, R. Piffl, R., J. Koukal, S. Gajdoš, M. Popek. „Slovak Video Meteor Network - status and results: Lyrids 2009, Geminids 2010, Quadrantids 2011“. Proceedings of the International Meteor Conference, Sibiu, Romania, 15-18 September, 2011 Eds.: Gyssens, M.; and Roggemans, P. International Meteor Organization, ISBN 2978-2-87355-023-3, pp. 82-84, 2011.

[28] N. Mujić, M. Muminović. „First results of Bosnia-Herzegovina Meteor Network (BHMN)“. Proceedings of the International Meteor Conference, Mistelbach, Austria, 27-30 August 2015, Eds.: Rault, J.-L.; Roggemans, P., International Meteor Organization, ISBN 978-2-87355-029-5, pp. 197-202, 2015.

[29] UKMON, https://www.ukmeteornetwork.co.uk/ (12. lipnja 2016.)

[30] UFOcapture opis rada, http://sonotaco.com/soft/UFO2/help/english/1-1.html (12. lipnja 2016.)

[31] MetRec: http://www.metrec.org/ (12. lipnja 2016.)

[32] S. Molau, G. Barentsen. „Status and history of the IMO Video Meteor Network“. The Meteoroids 2013, Proceedings of the Astronomical Conference held at A.M. University, Poznań, Poland, Aug. 26-30, 2013, Eds.: T.J. Jopek, F.J.M. Rietmeijer, J. Watanabe, I.P. Williams, A.M. University Press, 2014, p. 297-305, 2014.

[33] P. Gural. „From MeteorScan to FTP a variety of Meteor Detection Software Packages and Algorithms“, NASA MEO Meteor Video Workshop, PARI, August 3/4, 2011.

[34] ASGARD, http://meteor.uwo.ca/~weryk/asgard/ (12. lipnja 2016.)

[35] P. Gural. „Algorithms and Software for Meteor Detection“, Earth Moon Planet 102, p.p. 269–275, 2007.

[36] S. Molau, P. Gural. „A review of video meteor detection and analysis software“, WGN, 33:1, p.p. 15-20, 2005.

[37] P. Gural, P. Jenniskens. „Leonid Storm Flux Analysis from One Leonid Mac Video AL50R“, Earth, Moon, and Planets, January 1998, Volume 82, Issue 0, pp 221-247, 1998.

[38] P. Gural. „METEORSCAN Documentation and User’s Guide, Version 2.2“, dostupno od strane autora

[39] R. O. Duda, P. E. Hart. „Use of the Hough Transformation to Detect Lines and Curves in Pictures“. Comm. ACM, Vol. 15, pp. 11–15, 1972.

[40] P. Gural, D. Šegon. “A new meteor detection processing approach for observations collected by the Croatian Meteor Network (CMN)”. WGN, Journal of IMO, 37:1, pp. 28–32., 2009.

[41] Ž. Andreić, D. Šegon. “The first year of Croatian Meteor Network”. Proceedings of the International Meteor Conference, Šachtička, Slovakia, September 2008, pp. 16–23., 2010.

[42] Ž. Andreić, K. Korlević, D. Šegon. “The second year of Croatian Meteor Network”. Proceedings of International Meteor Conference, Poreč, September 2009, pp. 26–30., 2010.

[43] D. Vida, F. Novoselnik. “Croatian Meteor Network: data reduction and analysis”. Proceedings of the International Meteor Conference, Armagh, Northern Ireland, 16–19 September 2010, IMO, pp. 96–100., 2011.

[44] D. Vida. „Programsko rješenje unaprjeđenog postupka otkrivanja i video-promatranja meteora“, Elektrotehnički fakultet Osijek, završni rad, 2014.

[45] D. Šegon, P. Gural, Ž. Andreić, I. Skokić, K. Korlević, D. Vida, F. Novoselnik. “New showers from parent body search across several video meteor databases”, WGN, Journal of the International Meteor Organization, vol. 42, no. 2, pp. 57-64., 2014.

[46] Službeni popis meteorskih potoka Međunarodne astronomske unije: http://www.ta3.sk/IAUC22DB/MDC2007/Roje/roje_lista.php?corobic_roje=0&sort_roje=0 (14. lipnja 2016.)

[47] Radovi Hrvatske meteorske mreže: http://cmn.rgn.hr/downloads/downloads.html#papers (14. lipnja 2016.)

[48] D. Šegon, K. Korlević, Ž. Andreić, J. Kac, J. Atanackov, G. Kladnik. “Meteorite-dropping bolide over north Croatia on 4th February 2011”. WGN, Journal of the International Meteor Organization, vol. 39, no. 4, pp. 98-99., 2011.

[49] J. Borovička, P. Spurný, D. Šegon, Ž. Andreić, J. Kac, K. Korlević, J. Atanackov, G. Kladnik, H. Mucke, D. Vida, F. Novoselnik. „The instrumentally recorded fall of the Križevci meteorite, Croatia, February 4, 2011“, Meteoritics & Planetary Science, Vol 50 Issue 7, p.p. 1244-1259, 2015.

[50] American Meteor Society Technology Platform video, Raspberry Pi stanica se vidi na oko 09:40, https://vimeo.com/72551924 (15. lipnja 2016.)

[51] Raspberry Pi 2, https://www.raspberrypi.org/products/raspberry-pi-2-model-b/, (15. lipnja 2016.)

[52] D. Vida. „Unaprijeđeni postupak detekcije meteora na video snimkama“, seminarski rad za kolegij Robotski vid, ETFOS, 2016.

[53] D. Samuels, J. Wray, P. Gural, P. Jenniskens. „Performance of new low cost 1/3" camers for Meteor Surveillance“, Proceedings of the IMC2014, Giron, France, p.p. 66-73, 2014.

[54] Jenniskens P., Gural P. S., Dynneson L., Grigsby B. J., Newman K. E., Borden M., Koop M., Holman D. “CAMS: Cameras for Allsky Meteor Surveillance to establish minor meteor showers”. Icarus, Volume 216, Issue 1, pp. 40-61., 2011.

[55] Fischler M. A., Bolles R. C. "Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography". Comm. of the ACM 24 (6): pp. 381–395., 1981.

[56] Gonzalez R., Woods R. „Digital Image Processing“. Pearson, Third Edition, pp. 627-676., 2008.

[57] Slika: morfološka operacija zatvaranja, http://homepages.inf.ed.ac.uk/rbf/HIPR2/close.htm, (19. lipnja 2016.)

[58] Leandro A. F. Fernandes, Manuel M. Oliveira. „Real-time line detection through an improved Hough transform voting scheme“. Pattern Recognition (PR), Elsevier, 41:1, pp. 299-314., 2008.

[59] T.Y. Zhang, C.Y. Suen, „A Fast Parallel Algorithm for Thinning Digital Patterns“. Communications of the ACM, March 1984, Volume 27, Number 3, pp. 236-239, 1984.

[60] T. Eiter, H. Mannila „Computing discrete Fréchet distance“. Technical Report CD-TR 94/64, Christian Doppler Laboratory for Expert Systems, TU Vienna, Austria, 1994.

[61] R. Berry, J. Burnell. „The Handbook of Astronomical Image Processing“. Willmann-Bell Inc., 2005.

[62] P. Gural. „A Fast Meteor Detection Algorithm“, Proceedings of the IMC2016, Egmond, The Netherlands, u postupku objave, 2016.

[63] D. Vida, D. Šegon, P. S. Gural, G. Martinović, I. Skokić. „CMN_ADAPT and CMN_binViewer software“. Proceedings of the International Meteor Conference, Giron, France, 18-21 September 2014. IMO, pp. 59–63., 2014.

[64] R.M. Haralick, L.G. Shapiro, „Computer and Robot Vision“, Volume I, Addison-Wesley, 1992.

[65] PIXY program, http://www.aerith.net/misao/pixy/index.html, (22. lipnja 2016.)

[66] W. M. Smart, R. M. Green. „Textbook on Spherical Astronomy“, Cambridge University Press, 6th edition, 1977.

[67] J. Meeus. „Astronomical algorithms“. Willmann-Bell, Inc., 2nd Edition, 1999.

[68] D. Šegon. „How many stars are needed for a good camera calibration?“, WGN, The Journal of the IMO, 37:3, pp. 80-83., 2009.

[69] Yale Bright Star Catalog, http://tdc-www.harvard.edu/catalogs/bsc5.html, (22. lipnja 2016.)

[70] D. Vida, D. Zubović, P. Gural, D. Šegon, R. Cupec. „Open-source meteor detection software for low-cost single-board computers“, Proceedings of the IMC2016, Egmond, The Netherlands, u postupku objave, 2016.

[71] J. A. Nelder, R. Mead. „A simplex method for function minimization“. Computer Journal 7, pp. 308–313., 1965.

[72] PSF regresija, http://panisse.lbl.gov/snphot/lec8_vitaliy_PSF_fit.pdf, (7. srpnja 2016.)

SAŽETAK

Ovome radu cilj je riješiti problem velike cijene sustava za video promatranje meteora, što može predstavljati zapreku astronomima amaterima zainteresiranim za meteore da posjeduju takav sustav. Posljednjih godina minijaturna računala (npr. Raspberry Pi) postala su široko dostupna te imaju vrlo široke primjene zbog njihove male cijene. Kako bi se spomenuta računala koristila za primjenu u meteorskoj znanosti, potrebno je programsko rješenje za automatsku detekciju meteora prikladno za primjenu na takvim računalima. U ovome radu dan je detaljan opis novorazvijenog programskog rješenja otvorenog kôda za detekciju vatrenih kugli i meteora koje je dizajnirano za rad na minijaturnim računalima. Nadalje, opisane su pojedine komponente razvijenog sustava koji uključuje snimanje videa i njegovu kompresiju, detekciju vatrenih kugli i meteora, detekciju zvijezda i kalibraciju podataka.

Ključne riječi: meteori, obrada slike, detekcija značajki, otvoreni kôd, minijaturna računala

ABSTARCT

SOFTWARE SOLUTION FOR AUTOMATIC METEOR DETECTION

This work aims to overcome the current price threshold of meteor stations which can sometimes deter meteor enthusiasts from owning one. In recent years small card-sized computers became widely available and are used for numerous applications. To utilize such computers for meteor science, software which can run on them is needed. In this paper we present a detailed description of newly-developed open-source software for fireball and meteor detection optimized for running on low-cost single board computers. Furthermore, an update on the development of automated open-source software which will handle video capture, fireball and meteor detection, astrometry and photometry is given.

Keywords: meteors, image processing, feature detection, open-source, single-board computers

ŽIVOTOPIS

Denis Vida rođen je u Osijeku 21. rujna 1992. godine. Živi u Valpovu na adresi Vijenac Hrvatske Republike 10. Godine 1999. upisuje OŠ Matije Petra Katančića u Valpovu, te nastavlja srednjoškolsko obrazovanje u III. gimnaziji Osijek koju upisuje 2007. godine. Pri završetku srednje škole, dobiva izravan upis na Elektrotehnički Fakultet Osijek 2011. godine. 2014. završava preddiplomski studij računarstva, te iste godine upisuje diplomski studij računarstva na istom fakultetu, gdje trenutno i studira. Od 2009. posjećuje International Meteor Conference (IMC) i do danas na toj konferenciji izlaže ukupno 6 radova. Krajem 2009. godine s grupom članova Astronomskog društva „Anonymus“ pokreće projekt potrage za supernovama u suradnji sa zvjezdarnicom La Sagra u Španjolskoj, pod nazivom „*La Sagra Sky Survey – Supernova Search Project*“ koji pronalazi 19 do sada nepoznatih supernova. Od 2009. godine aktivno sudjeluje u radu Hrvatske meteorske mreže. U više od 40 znanstvenih članaka sudjeluje kao prvi autor ili koautor članka. Od 2008. godine sudjeluje na Višnjanskoj školi astronomije kao učenik, a od 2011. godine kao mentor grupama učenika u području meteorske astronomije. 2015. godine dobiva rektorovu nagradu za rad „Programsko rješenje sustava za pregledavanje i potvrđivanje snimaka meteora“, a 2016. godine dobiva dekanovu nagradu Elektrotehničkog fakulteta Osijek.

PRILOG 1 – PSEUDO KOD ALGORITMA ZA PRONALAZAK DUŽINA U 3D OBLAKU TOČAKA

```
Funkcija TražiLinije(Oblak_točaka, Pronađene_linije){
  Ako je (Duljina(Pronađene_linije) >= Najviše_linija)
    Vrati Pronađene_linije;

  Lista_rezultata = [];
  Za svaku točku T1 iz Oblak_točaka{
    Za svaku točku T2 iz Oblak_točaka{
      Pravac = Pravac koji čine točke T1 i T2;
      Suma_udaljenosti = 0;
      Brojač_točaka = 0;
      Prethodna_T3 = T1;
      Za svaku točku T3 iz Oblak_točaka{
        Ako je (Udaljenost(Pravac, T3) < Ograničenje_udaljenosti){
          Ako je (Udaljenost(Prethodna_T3, T3) > Ograničenje_rupe){
            Ako je (Udaljenost(Prethodna_T3, T2) > Ograničenje_rupe)
              Brojač_točaka = 0;
            Prekini petlju;
           }
         Brojač_točaka++;
         Suma_udaljenosti += Udaljenost(Pravac, T3);
         Prethodna_T3 = T3;
         }
      }
      Ako je (Brojač_točaka < Minimalan_broj_točaka)
        Nova iteracija;

      Prosječna_udaljenost = Suma_udaljenosti / Brojač_točaka;
      Kvaliteta = Brojač_točaka – Težina_udaljenosti * Prosječna_udaljenost;
      Dodaj Pravac u Lista_rezultata;
    }
  }

  Najbolji_pravac = Pravac s najvećom Kvaliteta iz Lista_rezultata;
  Omjer_točaka = Broj točaka u Najbolji_pravac / Broj točaka u Oblak_točaka;
  Oblak_točaka = Oblak_točaka \ Točke(Najbolji_pravac);

  Ako je (Raspon_okvira(Najbolji_pravac) >= Minimalan_raspon_okvira)
    Dodaj Najbolji_pravac u Pronađene_linije;

  Ako je ((Omjer_točaka < Ograničenje_omjera) & (Broj točaka u Oblak_točaka >
10) & NE Vrati_samo_jedan)
    Traži_linije(Oblak_točaka, Pronađene_linije);

  Vrati Pronađene_linije;
}
```

Ulazni parametri algoritma

U tablici P1.1 dane su korištene ulazne vrijednosti za detekciju vatrenih kugli i detekciju meteora u 3D oblaku točaka koji ih sadrže. Nadalje, dan je opis svakog ulaznog parametra.

Tablica P1.1 Ulazni parametri algoritma za traženje dužina za detektor vatrenih kugli i detektor meteora

Ulazni parametar	Detekcija vatrenih kugli	Detekcija meteora
Najviše_linija	5	1
Ograničenje_udaljenosti	70	50
Ograničenje_rupe	140	500
Minimalan_broj_točaka	4	10
Težina_udaljenosti	4	4
Minimalan_raspon_okvira	3	4
Ograničenje_omjera	0.7	0.7
Vrati_samo_jedan	NE	DA

`Oblak_točaka` je skup točaka implementiran kao dvodimenzionalna matrica koja sadrži položaje točaka u oblaku točaka. Matrica je veličine N×3, pri čemu je N broj točaka, a druga dimenzija sadrži 3 koordinate koje opisuju položaj točke u prostoru. Oblak točaka je sortiran po vremenu pojavljivanja određene točke, tj. po rednom broju okvira.

`Pronađene_linije` je lista koja sadrži popis svih dužina koje je algoritam našao. Pri prvom pokretanju algoritma lista je prazna, no pri svakoj sljedećoj rekurziji funkciji se prosljeđuje lista svih do sada pronađenih linija. U konačnici pri posljednjoj rekurziji funkcija vraća sve pronađene dužine.

`Najviše_linija` je broj koji ograničava koliko će algoritam najviše linija naći u oblaku točaka. Ako je ovaj broj visok, postoji mogućnost da na posebno zašumljenom oblaku točaka algoritam nađe mnogo linija. S druge strane ako je nizak, algoritam će možda ispustiti manje dominantne linije.

`Ograničenje_udaljenosti` je broj koji ograničava udaljenost točke od pretpostavljenog pravca. Ovaj parametar se može promatrati kao radijus baze valjka čijim središtem prolazi pretpostavljeni pravac, unutar kojega se broje točke.

`Ograničenje_rupe` je broj koji definira maksimalan razmak između točaka koje čine dužinu. On se koristi za detekciju kraja dužine, te stoga ako je sljedeća točka predaleko od trenutne,

algoritam shvaća da je došao do kraja i prekida daljnju potragu. Ovaj parametar je važno ispravno postaviti jer kvalitetna detekcija uvelike ovisi o njemu. U slučaju da je njegova vrijednost premala, dužine s malim prekidima mogle bi biti detektirane kao više zasebnih dužina. S druge strane, ako je parametar prevelik, algoritam će detektirati dužine s vrlo rasutim točkama.

`Minimalan_broj_točaka` je broj koji određuje koji je najmanji broj točaka koje sadrži dužina, a da bude uzeta kao prihvatljivo rješenje. Ako je broj previše mali, svaki par točaka bi mogao biti uzet kao prihvatljiva linija, no ako je prevelik onda kraće dužine neće biti detektirane.

`Težina_udaljenosti` je broj koji se koristi u izračunu kvalitete dužine i definira s kojom težinom se treba uzeti prosječna udaljenost svih točaka koje čine određenu dužinu. Ako je broj previše mali, neće se ispravno diskriminirati linije s kompaktnijim točkama od onih s raspršenim točkama. U slučaju da je ovaj parametar prevelik, duže i dominantnije linije, potencijalno više raspršene, će izgubiti prednost pred kraćim no kompaktnijim linijama.

`Minimalan_raspon_okvira` je broj koji definira minimalno trajanje detektirane dužine. Pošto je Z os vremenska komponenta, algoritam uzima razliku najveće i najmanje vrijednosti i uspoređuje ju s ovim parametrom.

`Ograničenje_omjera` je broj kojim se provjerava koliki je postotak točaka iz oblaka točaka preostao nakon potrage za linijama. Ovaj parametar se koristi u kombinaciji s fiksnim ograničenjem: u oblaku točaka mora preostati barem 10 točaka koje nisu pridružene niti jednoj dužini. Ako je `Ograničenje_omjera` preveliko, algoritam će pokušati tražiti dužine u podacima koji ih vjerojatno više se sadržavaju, tj. u šumu. Ako je broj premali, postoji mogućnost da će propustiti manje dužine koje mogu predstavljati meteore.

`Vrati_samo_jedan` je logički parametar koji može biti postavljen na istinitu ili neistinitu vrijednost. Ako je vrijednost istinita, algoritam će vratiti samo jednu dužinu, te neće ulaziti u rekurzije. Kada se traži više dužina ovaj je parametar postavljen na neistinitu vrijednost.