

SVEUČILIŠTE U ZAGREBU  
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

DIPLOMSKI RAD br. 694

**DETEKCIJA PRISUTNOSTI VOZILA  
UGRAĐENIM RAČUNALOM**

Igor Lipovac

Zagreb, lipanj, 2014.



## SADRŽAJ

|  |    |
|--|----|
| 1. Uvod .....  | 3  |
| 2. Pregled srodnih radova.....   | 5  |
| 3. Opis sustava za detekciju prisutnosti vozila .....  | 8  |
| 4. Detekcija temeljena na modelu pozadine .....  | 9  |
| 4.1. Metode izgradnje modela pozadine .....  | 10 |
| 4.1.1. Mješavina Gaussovih razdioba (MOG).....   | 12 |
| 4.1.2. Histogram orientacije gradijenta (HOG).....   | 14 |
| 4.1.3. Histogram nijanse (eng. Histogram of Hue, HOH) .....                                      | 18 |
| 4.2. Ostvarivanje prilagodljivosti modela na spore promjene osvjetljenja .....                   | 19 |
| 4.3 Ostvarivanje tolerancije modela na brze promjene osvjetljenja .....                          | 22 |
| 4.4. Omogućavanje obrade u stvarnom vremenu na ugrađenom računalu .....                          | 25 |
| 4.5. Osvrt na važnost odabira početnog modela pozadine .....                                     | 27 |
| 5. Eksperimenti i rezultati.....   | 29 |
| 5.1. Skupovi podataka za ispitivanje i validaciju .....  | 29 |
| 5.2. Optimiranje hiperparametara validacijom.....  | 33 |
| 5.2.1. Ocjena dobrote detekcijskog modela .....  | 33 |
| 5.2.2. Popis i definicija hiperparametara za svaki model pozadine .....                          | 35 |
| 5.3. Prikaz i ocjena ostvarenih rezultata .....  | 39 |
| 5.3.1. Rezultati validacijskih eksperimenata i ispitivanja .....                                 | 39 |
| 5.3.2. Usporedba najboljih detekcijskih modela nakon izvršenih validacijskih eksperimenata ..... | 56 |
| 5.3.3. Neki primjeri uspješnih i neuspješnih detekcija .....                                     | 59 |
| 6. Programska implementacija .....   | 60 |
| 7. Zaključak.....  | 62 |
| 8. Literatura.....   | 64 |

## 1. Uvod

Automatizirana analiza video snimki i fotografija dobivenih pomoću nadzornih kamera je opširno područje koje nalazi nove i sve bitnije primjene u različitim granama industrije i računalne znanosti. Temelji se na tehnikama računalnog vida i obrade slike te iskazuje velik potencijal u području praćenja cestovnog prometa i analize prometne aktivnosti. Cilj analize i praćenja cestovnog prometa je da posluži ljudskim korisnicima kao pomagalo pri dubljoj analizi prometne aktivnosti ili da bude alat u procesu automatizacije samog upravljanja prometom kroz video detektore koji služe za indikaciju prisutnosti automobila na raskrižju i slično. S obzirom na ubrzani razvoj današnjih računala kroz povećanje računske moći i brzine procesora te razvoj tehnika računalnog vida i obrade slike u stvarnom vremenu, nadzorne kamere koje već duže vrijeme imaju primjenu u praćenju prometa sada se mogu iskoristiti kao izvor informacija za automatizirane sustave koji vrše analizu i izvlačenje statističkih i raznih drugih značajki koje ljudskim promatračima daju dodatni uvid u prometnu situaciju prikazanu snimkom.

Postupci detekcije prometnih sudionika, klasifikacija istih (automobil, pješak...) te ekstrakcija različitih statističkih podataka, primjerice OD matrica [referenca] raskrižja, osnovni su zadaci automatizirane analize prometne situacije. Osnovni cilj ovog rada je prikazati izgradnju sustava čija je svrha detekcija prisutnosti prometnih sudionika u urbanom raskrižju. Detekcija prometnih sudionika vrši se u svrhu nekoliko različitih ciljeva od kojih je bitno spomenuti sljedeće: brojanje detektiranih prometnih sudionika, detekcija sudionika u svrhu automatiziranog upravljanja raskrižjem, prepoznavanje registracijskih pločica na detektiranim vozilima te detekcije incidenata i prometnih prekršaja. Na temelju detekcije moguće je daljnjom obradom ostvariti klasifikaciju i praćenje prometnih sudionika te na taj način doći do veoma bitnih podataka koji mogu pomoći u analizi i optimiziranju prometnog toka. Detekcija prisutnosti vozila se u današnjim prometnim sustavima najčešće ostvaruje pomoću induktivnih petlji [20] koje su ugrađene u samu prometnicu. Iako su rezultati detekcije pomoći induktivnih petlji veoma dobri, ostvarenje takvog sustava te sama ugradnja induktivnih petlji

zahtjeva priličnu količinu vremena i finansijskih resursa. Glavna motivacija razvoja sustava za detekciju prisutnosti vozila u raskrižju koji koristi video snimke dobivene nadzornim kamerama je dobiti jeftinu i pouzdanu alternativu induktivnim petljama. Takav sustav morao bi ostvarivati približno jednake, ako ne i bolje, rezultate detekcije od onih što ih daje induktivna petlja, a s finansijske strane bi bio mnogo isplativiji te lakši za ostvariti već iz činjenice da je jednostavnije postaviti kameru nego ugraditi induktivnu petlju u samu prometnicu.

U sljedećim poglavljima prikazan je ostvareni sustav za detekciju prisutnosti vozila u urbanom prometnom raskrižju temeljen na modelu pozadine. Poseban naglasak stavljen je na pregled ostvarenih metoda izgradnje modela pozadine te na validaciju i ocjenu različitih detekcijskih modela na ispitnim skupovima koji se sastoje od snimki stvarnih prometnih situacija u urbanim raskrižjima. Prikazani su problemi do kojih dolazi u ovakovom postupku detekcije na temelju modela pozadine te različiti pristupi za rješavanje tih problema. Također, bitan zahtjev postavljen pred ostvareni sustav je omogućavanje rada te izvršavanje sustava na ugrađenom računalu s ARM procesorom. Opisani su postupci pripreme i prevođenja programa te kratki osvrt na sam rad programa i brzinu izvršavanja na ugrađenom računalu.

## 2. Pregled srodnih radova

U posljednje vrijeme analiza prometa i skupljanje statističkih podataka o prometnim situacijama metodama računalnog vida i obrade slike u stvarnom vremenu je sve češći predmet istraživanja te je posebno velik broj radova usredotočen na metode izdvajanja objekata prednjeg plana te modeliranje pozadine. Modeliranje pozadine je ključni korak sustava opisanog u ovom radu te se najčešće ostvaruje konstrukcijom statističkog modela na razini piksela ili nakupine piksela koji na neki način opisuje pozadinu scene. Pikseli ili nakupine piksela koji su značajno različiti od pozadine iskazane modelom smatraju se pikselima prednjeg plana. Metode izgradnje modela pozadine koje su ostvarene i opisane u ovom radu temelje se na:

- mješavini Gaussovih razdioba na razini piksela,
- histogramu orientacije gradijenta na razini kvadratne ćelije ili
- histogramu nijanse na razini kvadratne ćelije.

Posebno popularna metoda izgradnje modela pozadine temeljena na vremenski prilagodljivoj mješavini Gaussovih razdioba opisana je u (Stauffer, 1998) [1], te poboljšana inačica te metode u (Živković, 2004) [2]. Upravo poboljšana inačica opisana u [2] korištena je kao temelj za neke metode opisane u ovom radu. U postupku modeliranja pozadine mješavinom Gaussovih razdioba svaki piksel predstavljen je skupom Gaussovih razdioba, gdje je utjecaj svake razdiobe koja opisuje piksel određen težinskim faktorom. Temelj ove metode je prepostavka da se upravo pozadina najčešće pojavljuje na ulaznim slikama te će razdiobe koje predstavljaju pozadinu imati veći težinski faktor od onih koje će prikazivati prednji plan. Svakom novom slikom osvježavaju se razdiobe za svaki piksel te je ključan parametar stopa učenja modela koja određuje utjecaj nove slike na trenutni model u koraku osvježavanja. Usporedba niza metoda izgradnje modela pozadine dana je u (Cheung, 2004) [4] gdje autori metode modeliranja pozadine dijele u dvije grupe: na ne-rekurzivne u koje spadaju jednostavno oduzimanje uzastopnih slika, linearno prediktivni filteri i neparametarske procjene funkcije gustoće vjerojatnosti za vrijednost piksela; te na rekurzivne u koje svrstava primjerice Kalmanov filter i mješavinu Gaussovih razdioba. Usporedbu pobrojanih metoda autori vrše na

temelju rezultata dobivenih na video sekvencama u kojima su ručno označeni objekti prednjeg plana tako da uspoređuju preciznost i odziv svake metode. U provedenim eksperimentima upravo mješavina Gaussova razdioba daje najbolje rezultate dok je oduzimanje uzastopnih slika polučilo najlošije rezultate. U radu (Brutzer, 2011) [6] je također prikazana usporedba nekoliko metoda za izgradnju modela pozadine, ali naglasak je stavljen na snimke iz nadzornih kamera. Uspoređeno je devet metoda koje pozadinu modeliraju na razini piksela. Posebna značajka ovog rada je u prepoznatim problemima u postupku modeliranja pozadine. Priređen je umjetno stvoren skup za svaku od sljedećih problematičnih situacija:

- postupna promjena osvjetljenja,
- nagla promjena osvjetljenja,
- pokretna pozadina uzrokovana pomicanjem kamere,
- prisutnost objekata prednjeg plana koji su slični pozadini,
- velika količina šuma u slikama i
- inicijalizacija početnog modela u trenutku kada su objekti prednjeg plana prisutni u sceni

te su uspoređeni rezultati koje opisane metode daju na svakom od tih skupova.

Naročito uspješnu metodu modeliranja pozadine i izdvajanja piksela prednjeg plana predložili su Barnich i Van Droogenback u (Barnich, 2009) [7] te je nazvali ViBe. Uspjeh te metode leži u novim predloženim inovacijama poput pohrane povijesti stvarnih vrijednosti piksela umjesto izgradnje statističkog modela, osježavanja piksela slučajnim odabirom te inicijalizacije početnog modela koristeći samo jednu sliku uz pretpostavku da vrijednosti susjednih piksela dijele sličnu vremensku distribuciju. Radovi koji poseban naglasak stavljuju na rješavanje problema koji nastaju postupnom ili naglom promjenom osvjetljenja su (Cheung, 2005) [5], (Batista, 2006) [13] te (Harville, 2002) [14]. [5] želi riješiti problem nagle promjene osvjetljenja za sporo prilagođavajuće modele pozadine te predlaže algoritam u dva koraka koji u prvom koraku gradi prikaz prednjeg plana koristeći sporo prilagođavajući Kalmanov filter te u drugom koraku vrši validaciju svakog pojedinog piksela prednjeg plana pomoću nekog jednostavnog modela pokretnih objekata prednjeg plana. Harville u [14] predlaže postupak koji

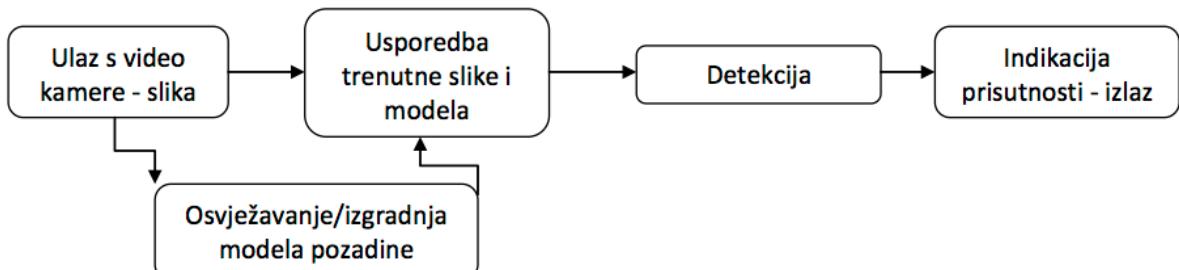
usmjerava razvoj mješavine Gaussovih razdioba tako da uzima podatke iz dijelova sustava na višoj razini, primjerice modula za detekciju i praćenje osoba ili modula za detekciju brzih promjena osvjetljenja, i zatim na temelju tih podataka podešava i poboljšava model pozadine. [13] predlaže algoritam na dvije razine, prva razina bila bi razina piksela, a druga je kvadratna ćelija dimenzija 8 puta 8 piksela. Grade se 3 modela prve razine, dva prilagođena različitim brzinama promjene osvjetljenja te treći kao validacijski model. Modeli na razini ćelije služe za praćenje i označavanje pripadnosti nakupina piksela pojedinom objektu prednjeg plana. (Liao, 2010) [10] pak predlaže rješenje problema s promjenama osvjetljenja i problema pokretne pozadine kroz ostvarivanje modela pozadine pomoću lokalnih binarnih uzoraka [22] invarijantne na skaliranje (Scale invariant local patterns). Također jako zanimljiv rad (Greggio, 2010) [9] se bavi mješavinom Gaussovih razdioba, točnije problemom inicijalizacije i odabira početnog modela te odabira broja razdioba u mješavini te predlaže pohlepni algoritam za učenje početne mješavine Gaussovih razdioba temeljen na modificiranom algoritmu maksimizacije očekivanja kroz izgradnji binarnog stabla odluke.

Posebno zanimljiv članak koji dijeli istu osnovnu motivaciju kao i ovaj rad je (Kim, 2013) [8]. U njemu je opisan sustav čiji je cilj zamijeniti induktivne petlje s tehnikama računalnog vida i obrade slike dobivene kamerama postavljenim na raskrižjima prometnica. Autori opisuju sustav koji koristi Intelov Viewmont procesor posebno namijenjen analizi videa te im on pomaže u ostvarenju jako dobrih rezultata i veliku brzinu obrade pojedine slike videa. Podaci o Viewmont procesoru nisu dostupni na Intelovim stranicama, pronalazimo ih samo u spomenutom članku.

Dva rada koji se bave detekcijom vozila na noćnim snimkama, (Zhou, 2012) [12] i (Shao-Ping, 2014) [11], predstavljaju algoritam temeljen na izdvajanju, uparivanju i praćenju prednjih svjetala automobila [12] te algoritam zasnovan na SIFT značajkama i pojačavanju MILBoost (Multi Instance Boost) [11].

### 3. Opis sustava za detekciju prisutnosti vozila

Sustav detekcije prisutnosti vozila u urbanom raskrižju ulaz prima kao snimku dobivenu video kamerom koja je postavljena na povišenom mjestu u blizini raskrižja, primjerice na stupu s prometnim svjetlima. Slika dobivena na taj način prikazuje područje nekoliko prometnih traka. Na početku rada sustava korisnik mora ručno definirati pozicije virtualnih petlji. Virtualne petlje su regije interesa na ulaznoj slici na temelju kojih se vrši postupak izgradnje modela pozadine te unutar kojih se vrši detekcija vozila. Korisnik mora pozicionirati virtualne petlje unutar granica promatranih prometnih traka na taj način da iste prekrivaju površinu koju može zauzeti vozilo na samoj snimci. To bi značilo da prostor ograđen petljom ne bi trebao zauzimati površinu veću od same površine vozila, niti prelaziti granice prometnih traka te na taj način zauzimati površinu koju može zauzeti neko vozilo koje se kreće susjednom prometnom trakom. Izlaz sustava je indikacija prisutnosti ili izostanka vozila unutar svake definirane virtualne petlje. Takav izlaz se zatim može proslijediti nekom drugom sustavu koji predstavlja sljedeći korak u procesu automatiziranog upravljanja raskrižjem, primjerice sustavu koji se bavi inteligentnim upravljanjem prometnim svjetlima.



**Slika 1.:** Koraci u radu sustava za detekciju prisutnosti vozila. Prvi korak je dobivanje slike iz video kamere. Na temelju dobivene slike vrši se izgradnja i osvježavanje modela pozadine. Ista slika se uspoređuje s trenutnim modelom pozadine. Na temelju te usporedbe vrši se detekcija prisutnosti vozila te konačno sustav daje odgovor je li vozilo prisutno unutar promatrane virtualne petlje

## 4. Detekcija temeljena na modelu pozadine

Ključni korak rada sustava je izgradnja modela pozadine. Na temelju usporedbe modela pozadine i trenutne slike izdvajamo objekte prednjeg plana na slici. Pozadina je u eksperimentima predstavljena sljedećim modelima:

- mješavina Gaussovih razdioba na razini piksela,
- histogram orientacije gradijenta na razini ćelije dimenzija 8 puta 8 piksela,
- histogram nijanse na razini kvadratne ćelije dimenzija 8 puta 8 piksela.

U procesu izgradnje modela pozadine pojavljuje se nekoliko karakterističnih problema. Model se mora dovoljno brzo prilagođavati kako bi reagirao na spore promjene osvjetljenja, a s druge strane ta brzina prilagođavanja ne bi smjela biti takva da u reprezentaciju pozadine mogu ući automobili koji čekaju promjenu svjetla na semaforu. Također, poželjno svojstvo modela pozadine bi bila otpornost na nagle promjene osvjetljenja, primjerice trenutak uključivanja gradske rasvjete.

U poglavlju 4.1. predstavljen je koncept jednostupanjskog modela, jednostupanjskog modela s odgomom te dvostupanjskog modela pozadine te su opisane sve ostvarene metode izgradnje modela pozadine. Prilagodljivost modela na spore promjene osvjetljenja te rješavanje problema automobila koji su duže vrijeme statični te s vremenom postaju dio pozadine pokušali smo ostvariti ispravnim odabirom stope učenja modela, vremenskim odgađanjem modela te izgradnjom dvostupanjskog modela pozadine te je taj dio objašnjen u poglavlju 4.2.. Ostvarivanje tolerancije modela na brze promjene osvjetljenja je tema poglavlja 4.3. te se u njemu se daje osvrt na metodu modeliranja pozadine pomoću histograma orientacije gradijenta te na postupak gradnje modela na temelju teksturne slike koju izdvajamo iz trenutne slike postupkom opisanim u nastavku istog poglavlja. Poglavlje 4.4. naglasak stavlja na postupke koji omogućavaju obradu u stvarnom vremenu na ugrađenom računalu te daje uvid i usporedbu performansi svake metode na stolnom i ugrađenom računalu. Konačno, poglavlje 4.5 daje osvrt na važnost odabira početnog modela u postupku izgradnje modela pozadine.

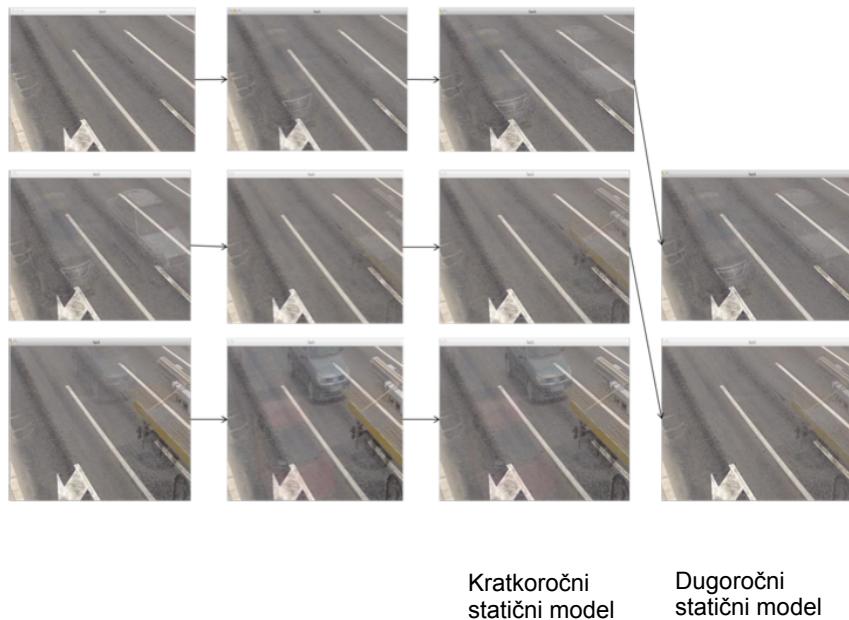
## **4.1. Metode izgradnje modela pozadine**

### **JEDNOSTUPANJSKI MODEL**

Jednostupanjski model pozadine, kao što ime kaže, je model s jednim stupnjem modeliranja. Gradi se jedna reprezentacija pozadine i osvježava se metodom eksponencijalnog pomičnog prosjeka. Ključni parametar je stopa učenja modela koja određuje utjecaj trenutne slike u fazi osvježavanja modela pozadine. Odabir stope učenja uvelike utječe na performanse ovakvog modela te, ovisno o promatranoj sceni, nekada je poželjno imati manju stopu učenja i model koji se sporije prilagođava, a nekada veću stopu učenja i model koji se brzo adaptira trenutnoj situaciji u video snimci.

### **JEDNOSTUPANJSKI MODEL S PERIODIČNOM ODGODOM**

Kako bismo izbjegli problem prelaska u pozadinu automobila koji čeka na semaforu te gubljenje detekcije tog automobila, a opet zadržali dovoljno brzu prilagodljivost modela, uvodi se mehanizam odgode u jednostupanjski model. I dalje se gradi i osvježava jedan tekući model, ali pamtimos kratkoročnu statičnu reprezentaciju modela pozadine koja je upravo tekući model od prije  $N$  slika video snimke tj. koraka osvježavanja pozadine te dugoročnu statičnu reprezentaciju tekućeg modela koja je predstavljena stanjem tekućeg modela od prije  $2N$  slika video snimke. U postupku usporedbe modela pozadine i trenutne ulazne slike koristimo dugoročnu statičnu reprezentaciju modela pozadine te na taj način dobivamo jednostupanjski model s odgodom od  $2N$  koraka osvježavanja. Prvi stupac na Slici 2. prikazuje model pozadine na početku jednog perioda osvježavanja u trajanju  $N$  slika, drugi stupac je na polovici perioda osvježavanja, treći stupac prikazuje model na kraju perioda osvježavanja te stanje koje postaje kratkoročna reprezentacija modela i konačno četvrti stupac prikazuje dugoročnu statičnu reprezentaciju nakon svakih  $2N$  slika.



**Slika 2.: Prikaz stanja kroz 3 perioda izgradnje jednostupanjskog modela s odgodom**

### DVOSTUPANJSKI MODEL S PERIODIČNOM ODGODOM

Dvostupanjski model pozadine uvodimo iz istog razloga kao jednostupanjski model s odgodom. Gradimo model na 2 razine, prva je model pozadine koji osvježavamo svakom novom slikom ulaznog videa. Druga razina je model pozadine kojeg osvježavamo i gradimo na temelju reprezentacije modela prvog stupnja nakon svakih  $N$  slika ulaznog videa. Na taj način vršimo raspršenje i uzorkovanje modela prvog stupnja, a ipak zadržavamo ukupnu dobivenu informaciju. Dodatno uvodimo odgodu u drugi stupanj te je u trenutku  $t$  posljednja slika kojom je osvježen model drugog stupnja upravo reprezentacija modela prvog stupnja od prije 2 perioda osvježavanja, ako je period osvježavanja trajanje obrade  $N$  slika ulaznog videa.

Eksperimenti su pokazali da jednostupanjski model s odgodom te dvostupanjski model pozadine ne daju dovoljno poboljšane rezultate u postupku detekcije, a unose dodatnu vremensku i memorijsku složenost u sam postupak izgradnje modela te su stoga manje prikladni za konačnu implementaciju na ugrađenom računalu.

#### 4.1.1. Mješavina Gaussovih razdioba (MOG)

Postupak modeliranja pozadine mješavinom Gaussovih razdioba izvodi se na razini piksela. Vrijednost intenziteta svakog piksela modeliramo pomoću  $n$  Gaussovih razdioba u mješavini. Mješavina Gaussovih razdioba je probabilistički model koji predstavlja linearnu kombinaciju  $n$  funkcija gustoće vjerojatnosti kojima opisujemo vrijednost intenziteta pojedinog piksela. Funkcija miješane gustoće određena je sljedećim izrazom:

$$p(x) = \sum_{k=1}^n \pi_k p(x|\mu_k, \Sigma_k) \quad (4.1)$$

$$p(x|\mu_k, \Sigma_k) = \frac{1}{(2\pi)^2} \frac{1}{|\Sigma_k|^{1/2}} \exp\left(-\frac{1}{2}(x - \mu_k)^T \Sigma_k^{-1} (x - \mu_k)\right) \quad (4.2)$$

gdje su  $p(x|\mu_k, \Sigma_k)$  normalne razdiobe - komponente mješavine, a  $\pi_k$  težinski koeficijenti pojedine razdiobe u mješavini.

Osnovna pretpostavka modeliranja pozadine mješavinom Gaussovih razdioba je da se upravo pozadina najčešće pojavljuje na ulaznim slikama te će razdiobe koje predstavljaju pozadinu imati veći težinski faktor od onih koje će prikazivati prednji plan. U programskom ostvarenju sustava koristimo već pripremljenu funkciju za modeliranje pozadine mješavinom Gaussovih razdioba koja je implementacija algoritma opisanog u [2], koji je poboljšanje postupka opisanog u [1], te se nalazi u sklopu OpenCV biblioteke [22]. Osvježavanje modela vrši se računanjem eksponencijalnog pomičnog prosjeka za svaku razdiovu. Svakom novom slikom osvježavaju se razdiobe za svaki piksel te je ključan parametar stopa učenja modela koja određuje utjecaj nove slike na trenutni model u koraku osvježavanja. Broj razdioba u mješavini varira te se kao parametar određuje najveći mogući broj razdioba dok funkcija sama odabire optimalan broj mješavina.

Osvježavanje mješavine Gaussovih razdioba i odabir razdiobe koja prikazuje pozadinu vrši se na sljedeći način, za svaki piksel promatrane slike:

- Provjerimo pripada li vrijednost promatranog piksela nekoj od trenutnih razdioba u mješavini. Ukoliko ne pripada niti jednoj razdiobi, zamijenimo distribuciju s najmanjim težinskim koeficijentom novom distribucijom koja za srednju vrijednost ima vrijednost promatranog piksela, visoku varijancu te postavimo nizak težinski koeficijent
- Zatim osvježimo težinske koeficijente, prikazana je formula za osvježavanje razdiobe  $k$  u koraku  $t$ , vrijednost  $M$  za razdiobu  $k$  iznosi 1 ukoliko promatrani piksel pripada razdiobi, 0 ako ne pripada:

$$\pi_{k,t} = (1 - \alpha)\pi_{k,t-1} + \alpha(M_k) \quad (4.3)$$

- Sljedeći korak je osvježavanje srednje vrijednosti i varijance razdioba kojima pripada trenutni piksel:

$$\mu_t = (1 - \rho)\mu_{t-1} + \rho X_t \quad (4.4)$$

$$\sigma_t^2 = (1 - \rho)\sigma_{t-1}^2 + \rho(X_t - \mu_t)^T(X_t - \mu_t) \quad (4.5)$$

- Stopa učenja u formulama za osvježavanje iznad definirana je kao umnožak stope učenja modela i iznosa funkcije gustoće pojedine razdiobe te prikazana sljedećim izrazom:

$$\rho = \alpha p(X_t | \mu_k, \Sigma_k) \quad (4.6)$$

- Konačno, razdiobe rangiramo ovisno o iznosu njihovog težinskog koeficijenta te one s najvećim koeficijentom predstavljaju pozadinu.

#### 4.1.2. Histogram orijentacije gradijenta (HOG)

Histogram orijentacije gradijenta je deskriptor značajki često korišten u računalnom vidu i obradi slike u svrhu detekcije objekata. Temelji se na prebrojavanju smjerova gradijenta intenziteta piksela u lokaliziranim manjim dijelovima slike. Takvo prebrojavanje daje histogram za svaku ćeliju te se kombinacija histograma svih ćelija u slici predstavlja kao HOG deskriptor.

Prvi korak u dobivanju HOG deskriptora je izračun vrijednosti gradijenata slike. Vrijednosti gradijenata slike dobivamo konvolucijom izvorne slike i Sobelovog filtera. Sobelov filter koristi dvije 3 puta 3 jezgre za konvoluciju, jednu za horizontalno smjer, drugu za vertikalni. Ako izvornu sliku označimo sa  $I$ ,  $G_x$  i  $G_y$  prikazuju slike s izračunatim vrijednostima gradijenta:

$$G_x = \begin{pmatrix} -1 & 0 & 1 \\ -2 & 0 & 1 \\ -1 & 0 & 1 \end{pmatrix} * I \quad G_y = \begin{pmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{pmatrix} * I \quad (4.7, 4.8)$$

U svakoj točki slike možemo izračunati amplitudu gradijenta  $M$  na sljedeći način:

$$M = \sqrt{G_x^2 + G_y^2} \quad (4.9)$$

Orijentaciju gradijenta u istoj točki dobijemo sljedećom formulom:

$$\Theta = \text{atan2}(G_x, G_y) \quad (4.10)$$

Postoji nekoliko načina izračuna samog histograma uz dobivene orijentacije gradijenata. Potrebno je odabratи broj mogućih smjerova gradijenta. Svaki od tih mogućih smjerova predstavlja jedan odjeljak (eng. *bin*) orijentacije i pokriva određeni raspon stupnjeva kuta orijentacije. Jednostavan način izračuna histograma je u svaki odjeljak pohraniti broj gradijenata koji su svojom orijentacijom pripali tom odjeljku. Drugi, efikasniji način je za svaki odjeljak pohraniti sumu svih amplituda gradijenata koji su svojom orijentacijom pripali tom

odjeljku. Takav način koriste Dalal i Triggs u svom radu [15]. Kada dobijemo histogram za svaku ćeliju, same ćelije grupiramo u veće jedinice - blokove. Histogrami ćelija unutar jednog bloka čine vektor značajki tog bloka te se taj vektor zatim normalizira u svrhu ostvarenja invarijantnosti na lokalne varijacije u osvjetljenju, kontrastu boja te pojavu sjene. Dodatno poboljšanje performansi se postiže preklapanjem blokova tako da svaka ćelija pridonosi konačnom deskriptoru više puta. Ako je  $v$  nenormalizirani vektor značajki, normaliziramo ga pomoću nekim od sljedećih izraza:

$$\text{L2-norma: } \frac{v}{\sqrt{\|v\|_2^2 + e^2}} \quad (4.11)$$

$$\text{L1-norma: } \frac{v}{\|v\|_1 + e} \quad (4.12)$$

$$\text{L1-sqrt norma: } \sqrt{\frac{v}{\|v\|_1 + e}} \quad (4.13)$$

Modeliranja pozadine značajkama histograma orijentacije gradijenta konačno radimo tako da da ulaznu sliku na temelju koje gradimo model pozadine podijelimo na više dijelova tj. ćelija unutar kojih se prati smjer gradijenata intenziteta piksela te se na temelju toga gradi histogram koji se zatim koristi kao značajka pri izgradnji modela pozadine te pri detekciji. Ulaznu sliku dijelimo na određeni broj preklapajućih ćelija dimenzija 8 puta 8 piksela. Raspon histograma je od 0 do 180 stupnjeva podijeljeno na 9 odjeljaka orijentacije. To znači da za svaku ćeliju imamo 9 elemenata u histogramu. Za svaku ulaznu sliku računamo deskriptor histograma orijentacije gradijenta i na temelju toga gradimo model pozadine pomoću izračunavanja pomicnog prosjeka po postupku koji je predložen u [3]. Određuje se funkcija gustoće vjerojatnosti za svaku ćeliju koristeći posljednjih  $n$  slika. Svaki odjeljak unutar pojedine delije predstavljen je srednjom

vrijednošću i varijancom ( $\mu_t, \varsigma_t^2$ ). Osvježavanje modela u koraku  $t$  za ćeliju  $i$  vrši se na sljedeći način:

$$\mu_t = \rho f_i + (1-\rho)\mu_{t-1} \quad (4.14)$$

$$\varsigma_t^2 = \rho d^2 + (1-\rho)\varsigma_{t-1}^2 \quad (4.15)$$

$$d = |f_i - \mu_t| \quad (4.16)$$

gdje je  $f$  normalizirani iznos deskriptora za određeni odjeljak promatrane ćelije  $i$ , a  $\rho$  stopa učenja modela.

Prisutnost objekta u promatranoj ćeliji određujemo na sljedeći način:

$$(I_t - \mu_t)^2 > k \rightarrow \text{detekcija} \quad (4.17)$$

$$(I_t - \mu_t)^2 \leq k \rightarrow \text{pozadina} \quad (4.18)$$

gdje je  $I_t$  trenutni vektor HOG značajki za promatrani ćeliju,  $\mu_t$  vektor srednjih vrijednosti HOG značajki za promatrani ćeliju.

#### UBRZAVANJE IZRAČUNA HOG ZNAČAJKI - INTEGRALNA SLIKА

Kako bismo što efikasnije i brže došli do histograma orientacije gradijenta, HOG deskriptore izračunavamo koristeći integralnu sliku. Postupak izračunavanja integralne slike je brz i učinkovit način izračunavanja sume vrijednosti unutar bilo kojeg pravokutnog isječka same slike. Budući da u izračunavanju HOG deskriptora dijelimo sliku na kvadratne ćelije, integralna slika je idealan postupak za izračun gradijenta unutar pojedine ćelije. Vrijednost u točki  $(x,y)$  integralne slike je zbroj vrijednosti u svim točkama iznad i lijevo od promatrane točke  $(x,y)$ , uključujući tu točku. To prikazujemo sljedećom formulom:

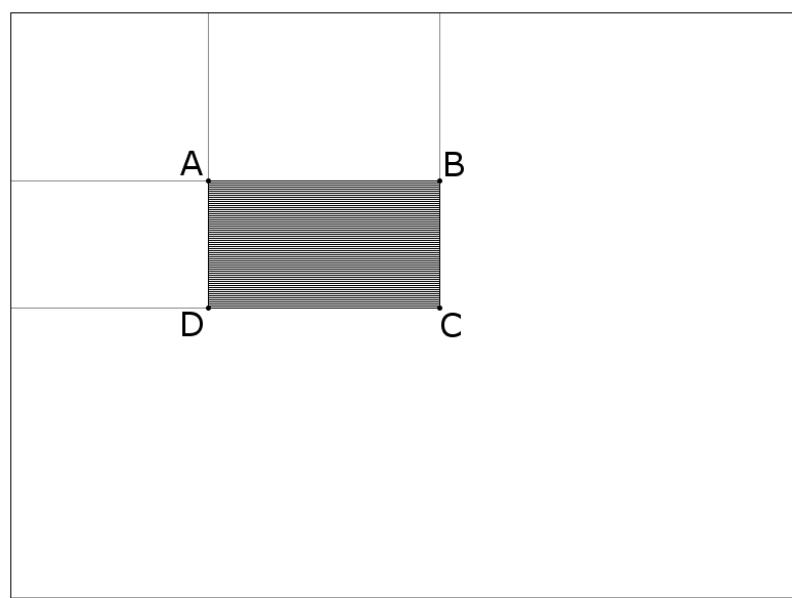
$$I(x, y) = \sum_{\substack{x' \leq x \\ y' \leq y}} i(x', y') \quad (4.19)$$

Cijelu integralnu sliku izračunamo u jednom prolazu kroz izvornu sliku te za svaku poziciju ( $x, y$ ) vrijednost dobijemo na sljedeći način:

$$I(x, y) = i(x, y) + I(x - 1, y) + I(x, y - 1) - I(x - 1, y - 1) \quad (4.20)$$

Konačno, zbroj vrijednosti svakog pravokutni isječka izračunamo u tako što dohvatićemo samo vrijednosti vršnih točaka (Slika 3., točke A, B, C i D) i iskoristimo sljedeću formulu:

$$\sum_{\substack{x0 < x \leq x1 \\ y0 < y \leq y1}} i(x, y) = I(C) + I(A) - I(B) - I(D) \quad (4.21)$$



**Slika 3.: Izračun integralne slike**

#### **4.1.3. Histogram nijanse (eng. *Histogram of Hue*, HOH)**

Postupak se temelji na praćenju nijanse slike. Slika se iz RGB sustava boja prebacuje u HSV sustav. Nijansu predstavlja H komponenta slike - eng. hue. Nijansa je predstavljena u rasponu vrijednosti od 0 do 180. Taj skup vrijednosti diskretiziramo na 15 do 60 mogućih odjeljaka, ovisno o željenoj dužini vektora značajki za pojedinu ćeliju. Baš kao i kod histograma orijentacije gradijenta sliku dijelimo na ćelije dimenzija 8 puta 8 piksela. Za svaku ćeliju pamtimo vektor koji sadrži histogram nijanse diskretiziran na 15 do 60 odjeljaka, ovisno o spomenutom odabiru. Model pozadine, kao kod prošlog postupka, gradimo računajući tekući Gaussovog prosjeka tj. svaku vrijednost u vektoru značajki modeliramo jednom Gaussovom razdiobom koju osvježavamo sa vrijednošću dobivenom iz svake nove ulazne slike na temelju izraza 4.14, 4.15 i 4.16 prikazanih u prošlom odjeljku. Odjeljivanje pozadine i prednjeg plana vršimo također na isti način, no prag je u pravilu nešto manji za ovaj postupak.

Tijekom preliminarnih eksperimenata model temeljen na histogramu nijanse se pokazao najmanje uspješnim te je odlučeno da neće ulaziti u validacijske eksperimente i daljnje ispitivanje. Za budući rad zanimljivo bi bilo složiti model koji će sadržavati značajke dobivene kombinacijom histograma orijentacije gradijenta te histograma nijanse.

## 4.2. Ostvarivanje prilagodljivosti modela na spore promjene osvjetljenja

Model pozadine kroz postupak osvježavanja se mora prilagođavati sporim promjenama u globalnom osvjetljenju scene koje nastaju u prijelazima od dnevnih prema noćnim satima i obratno. Ključna stvar u ostvarivanju optimalne prilagodljivosti modela je odabir ispravne stope učenja. Dodatno poboljšanje prilagodljivosti na spore promjene scene pokušali smo dobiti uvođenjem dvostupanjskog modela pozadine. Neovisno o metodi izgradnje modela pozadine, modeli prikazani u ovom radu osvježavaju se izračunom eksponencijalnog pomičnog prosjeka. U ovom poglavlju prikazan je utjecaj svih slika koje ulaze u model pozadine, ovisan o stopi učenja, za jednostupanjski eksponencijalni pomični prosjek te dvostupanjski eksponencijalni pomični prosjek korišten u dvostupanjskom modelu pozadine opisanom u 4.1..

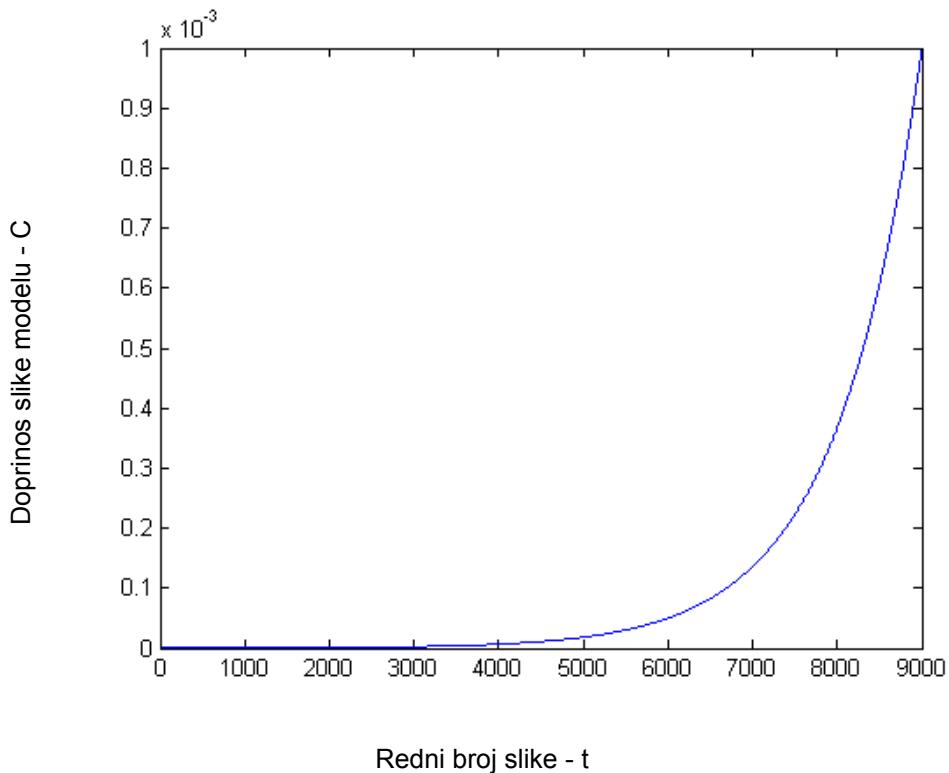
Uzmimo kao primjer osvježavanje srednje vrijednosti Gaussove razdiobe metodom eksponencijalnog pomičnog prosjeka. Srednju vrijednost razdiobe koja prikazuje pojedini piksel u koraku  $t+1$  osvježavamo sljedećim izrazom:

$$\mu_{t+1} = \alpha I_{t+1} + (1 - \alpha) \mu_t \quad (4.22)$$

Označimo doprinos pojedine slike u jednostupanjskom modelu te prvom stupnju dvostupanjskog modela sa  $C$  te doprinos slike u drugom stupnju dvostupanjskog modela s  $D$ . Doprinos slike u koraku  $t+1$ ,  $t$  i  $t-1$  za jednostupanjski eksponencijalni pomični prosjek tada bi iznosio:

$$\begin{aligned} C(t+1) &= \alpha \\ C(t) &= (1 - \alpha)\alpha \\ C(t-1) &= (1 - \alpha)^2\alpha \\ &\dots \end{aligned} \quad (4.23)$$

Graf 1. prikazuje udjele pojedine slike nakon 9000 uzastopnih slika ulaznog videa tj. nakon 9000 koraka osvježavanja modela pozadine. Stopa učenja je postavljena na 0.001.

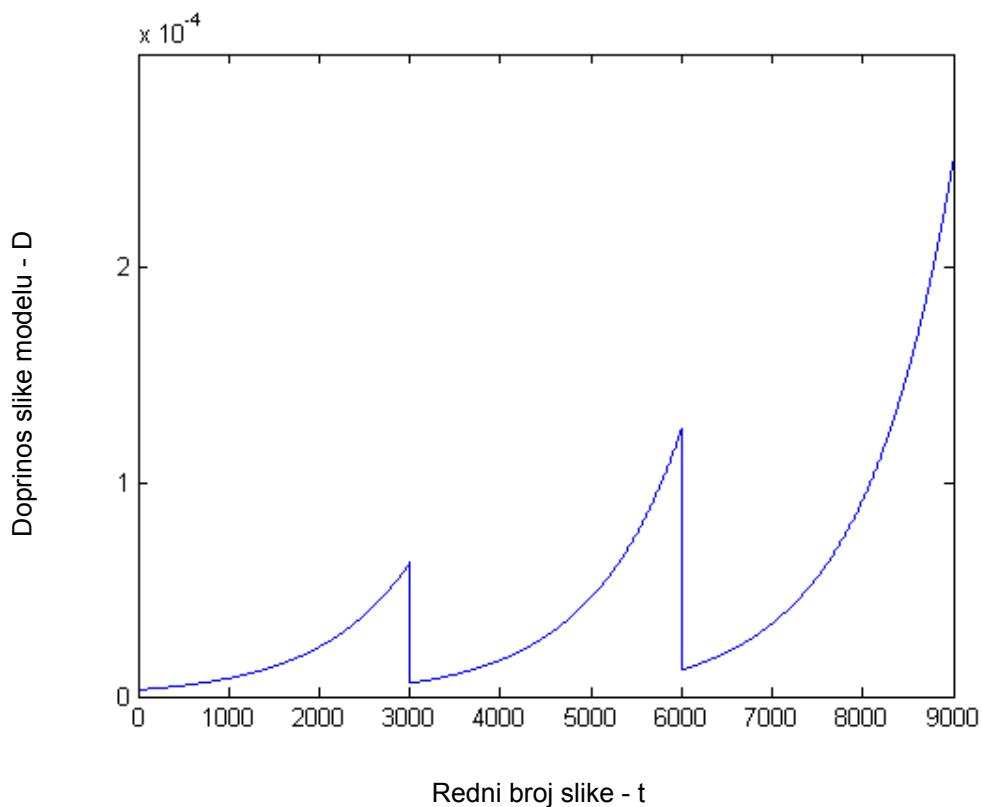


**Graf 1.:** Doprinos svake pojedine slike trenutnom modelu pozadine nakon 9000 koraka osvježavanja, stopa učenja je 0.001

Drugi stupanj dvostupanjskog modela gradimo raspršivanjem i odgađanjem prvog stupnja modela. Uvodi se stopa učenja drugog stupnja modela  $\beta$  te izraz koji dobivamo za iznos doprinosa  $D$  pojedine slike u dvostupanjskom modelu pozadine u koraku  $t$ , nakon što je model osvježen s  $N$  slika, glasi:

$$D(t) = \beta(1 - \beta)^{N-t} C(t) \quad (4.24)$$

Graf 2. prikazuje doprinos svake slike u dvostupanjskom modelu uz stopu učenja prvog stupnja koja iznosi 0.001, te stopu učenja drugog stupnja koja je postavljena na 0.5.



**Graf 2.:** Doprinos svake pojedine slike trenutnom dvostupanjskom modelu pozadine nakon 9000 koraka osvježavanja, stopa učenja prvog stupnja je 0.001, stopa učenja drugog stupnja je 0.5

Prostorna složenost dvostupanjskog modela je duplo veća od složenosti jednostupanjskog modela iz činjenice da ustvari gradimo 2 različita modela unutar jednog.

Optimalnu vrijednost stope učenja za oba modela odredili smo u poglavlju eksperimentima i validacijom parametara opisanom u poglavlju 5., također je pokazano da utjecaj raspršivanja i odgađanja u dvostupanjskom modelu nije dovoljno učinkovit da bi ga se smatralo boljim odabirom od jednostupanjskog modela.

### **4.3 Ostvarivanje tolerancije modela na brze promjene osvjetljenja**

Poželjna karakteristika modela pozadine je tolerancija na brze promjene osvjetljenja. Do naglih promjena u osvjetljenju dolazi u situacijama poput zatamnjivanja ceste zbog naglog naoblacenja ili situacije u kojoj vozilo izrazito svjetle boje prolazi cestom te se globalna razina intenziteta podigne i to uzrokuje adaptiranje same kamere smanjenjem otvora za svjetlost. Pokazalo se da je model temeljen na mješavini Gaussovih razdioba prilično netolerantan na takve situacije ukoliko mu je stopa učenja podešena tako da dobro reagira na spore promjene osvjetljenja i na probleme s objektima koji su neko vrijeme statični u sceni (automobili koji čekaju promjenu prometnog svjetla).

#### **HISTOGRAM ORIJENTACIJE GRADIJENTA**

Toleranciju na brze promjene osvjetljenja stoga smo pokušali riješiti izgradnjom modela temeljenog na histogramu orijentacije gradijenta. Model koji koristi histogram orijentacije gradijenta se pokazao kao dobro rješenje budući da u trenutku izračuna HOG deskriptora ćelije dijelimo u blokove unutar kojih se vrši normalizacija ovisno o ukupnoj mjeri intenziteta u pojedinom bloku te na taj način dobivamo veću invarijantnost što se tiče naglih lokalnih promjena u osvjetljenju, kontrastu boja i padanju sjene na cestu u slučaju oblaka koji zaklanja sunce. Također, sama činjenica da se s HOG deskriptorom modelira na temelju gradijenata, a ne intenziteta piksela, povećava otpornost na neke od spomenutih problema.

#### **IZDVAJANJE TEKSTURNE SLIKE**

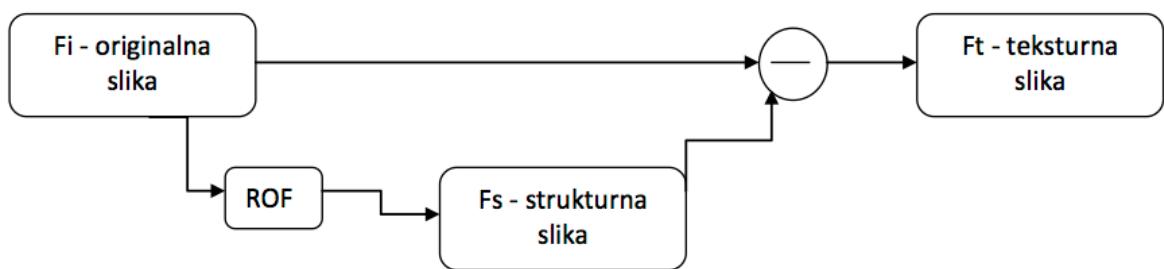
Sljedeći zanimljiv pokušaj rješavanja ovog problema bio je inspiriran radom [17] koji opisuje uklanjanje standardnog aditivnog Gaussovog koje je temeljeno na ROF (po autorima - Rudin, Osher i Fatemi) postupku koji koristi totalnu varijaciju u

postupku regularizacije. Također prikazan je i Chambolleov projekcijski algoritam koji koristi spomenuti ROF postupak za sive slike i slike u boji u svrhu uklanjanja šuma u slikama. Algoritam pretpostavlja da je ulazna slika kombinacija originalne slike i aditivnog šuma:

$$f = u + \eta \quad (4.25)$$

gdje je  $\eta$  šum. Uklanjanjem šuma iz originalne slike dobivamo strukturu originalne slike. Pretpostavka kojom se mi vodimo u postupku izdvajanja teksturne komponente slike je da ćemo oduzimanjem strukturne slike dobivene Chambolle-ROF postupkom iz slike u kojoj nema pretjerano mnogo aditivnog šuma dobiti sliku koja predstavlja samo teksturnu komponentu originalne slike. Takva slika bi mogla biti pogodna za detekciju vozila budući da smo sigurni da vozila imaju drugčiju teksturu od ceste koja bi trebala biti uvijek u pozadini. Na temelju slike koja sadrži samo teksturnu komponentu gradimo model pozadine i u postupku detekcije radimo usporedbu modela pozadine s teksturnom slikom dobivenom iz trenutne ulazne slike. Za izgradnju modela pozadine koristeći teksturnu sliku koristili smo metode temeljene na mješavini Gaussovih razdioba te histograma orientacije gradijenta koje su opisane u prošlim poglavljima. Slika 4. prikazuje postupak izdvajanja teksturne slike.

Korištenjem teksturne komponente slike u procesu modeliranja pozadine i kasnije detekcije rješavamo probleme koji nastaju kod nagle promjene osvjetljenja, ali dobivamo i toleranciju na spore promjene osvjetljenja također. Problem ovog postupka je u velikoj računskoj složenosti te jako velikom vremenu koje je potrebno za uklanjanje šuma iz trenutne slike i dobivanje teksturne slike te nažalost ovaj postupak nije pogodan za obradu slike na ugrađenom računalu u stvarnom vremenu. O usporedbi vremenske složenosti HOG i MOG modela pozadine u kombinaciji s teksturnom slikom te onih koji rade s izvornom slikom bavi se sljedeće poglavlje.



**Slika 4.:** Postupak izdvajanja teksturne komponente ulazne slike



**Slika 5.:** Teksturna slika pozadine, trenutne ulazne slike i detektirana razlika u teksturi

#### **4.4. Omogućavanje obrade u stvarnom vremenu na ugrađenom računalu**

Budući da se naš program u svojoj konačnoj implementaciji treba izvršavati na ugrađenom računalu s ARM procesorom, potrebno je bilo uvesti neke prilagodbe u samom načinu obrade kako bismo smanjili prostornu i vremensku složenost postupka detekcije te na taj način omogućili obradu u stvarnom vremenu na ugrađenom računalu. Za testiranje našeg programa dostupno nam je bilo računalo IGEPv2 s A8 Cortex ARM procesorom radnog takta 1 GHz i 512 MB radne memorije. Ostale specifikacije mogu se vidjeti na stranici [26]. U radnom okruženju sustava na ugrađeno računalo bismo spojili IP kameru te direktno učitavali slike pomoću nje. U eksperimentima smo ipak bili ograničeni na već pripremljene video snimke i program smo izvodili na osobnom računalu.

Kako bismo već u pripremi postupka smanjili prostornu složenost odlučili smo u proces izgradnje modela pozadine uključiti samo regije interesa na trenutnoj slici koje su obuhvaćene prethodno definiranim virtualnim petljama. Na taj način uvelike smanjujemo broj piksela koje je potrebno obraditi na svakoj novoj slici. Isto tako smanjenjem broja piksela koje je potrebno obraditi također dolazi i do značajnog smanjenja vremenske složenosti. Ukoliko uzmemo za primjer slike dimenzija 640x480 piksela, kakve inače dobivamo od IP kamere koja bi trebala biti spojena na ugrađeno računalo, prosječna veličina virtualne petlje u eksperimentima na takvim ispitnim snimkama nije bila većih dimenzija od 120x100 piksela. Preliminarni eksperimenti za koje je u dalnjem tekstu prikazana vremenska analiza vršeni su na mnogo većim slikama iz puno kvalitetnije video snimke. Dimenzije takvih slika bile su 1920x1080, a prosječna virtualna petlja imala je dimenzije 400x200.

U početnim analizama vremenske složenosti trajanja obrade slike usredotočili smo se na izvođenje na osobnom računalu s Intel i5 dvojezgrenim procesorom radnog takta 1.7 GHz te 4GB radne memorije. Izmjereno je trajanje izvršavanja obrade jedne slike za 5 implementiranih postupaka. Obrada jedne slike uključuje osvježavanje modela pozadine i detekciju prisutnosti vozila na slici.

Iz ove vremenske analize isključeno je vrijeme dohvaćanja slike iz ispitne video snimke te iscrtavanje slike na ekran. Slike videa Dobiveni su sljedeći rezultati na slikama većih dimenzija:

|                 | <b>MOG</b> | <b>HOG</b> | <b>HOH</b> | <b>MOG+ROF</b> | <b>HOG+ROF</b> |
|-----------------|------------|------------|------------|----------------|----------------|
| <b>trajanje</b> | 3-6 ms     | 1-3 ms     | 1-3 ms     | 500+ ms        | 500+ ms        |

\*ROF predstavlja postupak izdvajanja teksturne slike.

Rezultati mjerena trajanja obrade slike manjih dimenzija su sljedeći:

|                 | <b>MOG</b> | <b>HOG</b> | <b>HOH</b> | <b>MOG+ROF</b> | <b>HOG+ROF</b> |
|-----------------|------------|------------|------------|----------------|----------------|
| <b>trajanje</b> | 1-2 ms     | 1 ms       | 1 ms       | 500 ms         | 500 ms         |

Na ugrađenom računalu smo izmjerili trajanje obrade jedne slike te je prosječno trajanje obrade 3 do 5 puta duže nego na osobnom računalu te primjerice za MOG postupak iznosi prosječno malo više od 20 milisekundi.

Kao što vidimo iz priloženih, postupak izdvajanja teksturne slike uvelike povećava vremensku složenost postupka detekcije te smo ga unatoč dobrim preliminarnim rezultatima morali isključiti iz dalnjih eksperimenata budući da ga nije praktično upogoniti u stvarnom vremenu niti na osobnom niti na ugrađenom računalu u svrhu obrade video snimke.

Također bitna stvar je obratiti pozornost na vremena dohvaćanja slike iz video snimke. Dohvaćanje slike većih dimenzija iz snimke bolje kvalitete traje i do 90 milisekundi na osobnom računalu dok se slika manjih dimenzija iz snimke lošije kvalitete (snimka dobivena IP kamerom i pohranjena u obliku video snimke na disk računala) dohvaća u vremenu od 15 do 20 milisekundi. Vrijeme dohvaćanja slike iz same IP kamere bi trebalo biti znatno manje i ne bi smjelo uzimati više od nekoliko milisekundi tako da se nadamo da u konačnoj implementaciji sustava ovo vrijeme možemo zanemariti.

Vrijeme iscrtavanja virtualnih petlji na osobnom računalu za obje snimke je veće od 20 milisekundi, dok ako iscrtavamo cijelu sliku većih dimenzija to vrijeme raste i do 40 milisekundi.

## 4.5. Osvrt na važnost odabira početnog modela pozadine

Kao što je prikazano u odjeljku koji se bavi ostvarivanjem prilagodljivosti modela na spore promjene osvjetljenja, budući da pri izgradnji modela pozadine koristimo eksponenijalni pomični prosjek veliku važnost ima početna slika ili početni skup značajki kod modela koji se temelji na histogramima. Jedan od najbitnijih čimbenika velike uspješnosti rezultata koji će biti prikazani je dobro inicijaliziran model pozadine. U video snimci koja je korištena za početni skup eksperimenata prva slika prikazuje praznu cestu bez automobila te je početno stanje svakog modela inicijalizirano na stvarnoj slici pozadine te na temelju toga smo gradili dalje i dobili veoma dobre rezultate. S druge strane kada je početna slika bila slika na kojoj se nalazi automobil rezultati su bili osjetno lošiji te je modelu trebalo mnogo više vremena da se prilagodi i postane sličan stvarnoj pozadini. Stoga je razmotreno više načina za odabir početnog modela.

Najjednostavniji način bio je usrednjavanje duge sekvence slika odnosno vektora značajki kod HOG postupaka. Na taj način dobivamo dovoljno dobar početni model budući da će nakon usrednjavanja prevladati intenziteti slikovnih elemenata odnosno značajke slične stvarnim slikovnim elementima ili značajkama pozadine jer se ona najčešće pojavljuje u samoj sekvenci. Također na taj način zadržavamo svojstvo slučajnosti i nepristranosti pri određivanju početnog modela.

Sljedeći razmotreni način bio je da odaberemo dvije početne slike, jednu koja je istovjetna stvarnoj pozadini, a drugu takvu da se na njoj nalazi automobil. Zatim gradimo dva istovjetna modela, ali inicijalizirana različitim slikama, te mjerimo vrijeme koje će biti potrebno da oba modela dođu u isto ili približno isto stanje. To vrijeme bismo postavili kao vrijeme potrebno za inicijalizaciju modela na koji neće utjecati odabir početnog modela.

Razmotrena je i mogućnost da se početni model (mješavina Gaussijana ili vektor značajki modela temeljenog na histogramu) točno odredi pomoću algoritma maksimizacije očekivanja. Takav postupak je vremenski jako složen, ali bi dao

najbolji mogući ispravan početni model. Sličan postupak opisan je u [9], temeljen na modifikaciji algoritma maksimizacije očekivanja. Za inicijalizaciju modela pri izvršenim eksperimentima zbog jednostavne implementacije i brzine inicijalizacije odabrana je metoda usrednjavanja duge sekvene slika.



**Slika 6.:** Početna pozadina virtualne petlje dobivena usrednjavanjem 20000 slika na video snimci iz prvog ispitnog skupa



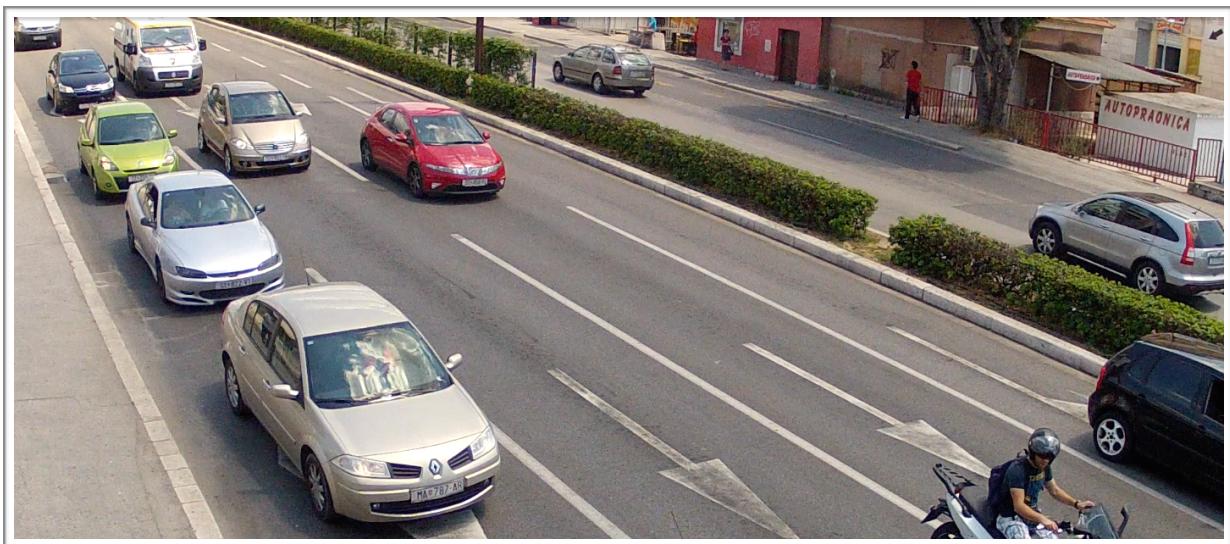
**Slika 6.:** Početna pozadina virtualne petlje dobivena usrednjavanjem 20000 slika na video snimci iz drugog ispitnog skupa

## 5. Eksperimenti i rezultati

U ovom poglavlju opisani su skupovi podataka na kojima je izvršeno ispitivanje izgradnje modela pozadine i validacija hiperparametara za svaki implementirani detekcijski model. U dalnjem tekstu razlikujemo model pozadine i detekcijski model. Model pozadine je temelj detekcijskog modela čije performanse mjerimo u eksperimentima. Također su navedeni i definirani hiperparametri metoda za izgradnju modela pozadine. Opisani su eksperimenti optimiranja spomenutih hiperparametara validacijom nad danim skupovima podataka. Rezultati validacije i ispitivanja su prikazani, opširno komentirani i ocijenjeni u posljednjem dijelu poglavlja.

### 5.1. Skupovi podataka za ispitivanje i validaciju

Detekcija vozila vrši se u stvarnom vremenu na slikama dobivenim iz video snimke urbanog prometnog raskrižja. Pri izradi ovog rada eksperimenti su izvršeni na dva skupa video snimki. Prvi skup sastoji se od niza kvalitetnih video snimki visoke rezolucije snimljenih kamerom postavljenom na stup prometnog svjetla koja na raskrižje gleda pomalo sa strane te slika obuhvaća četiri prometne trake. Sve snimke iz ovog skupa snimljene su u jednakim vremenskim uvjetima (sunčano vrijeme, bez padalina i vjetra koji uzrokuje nestabilnost i treskanje kamere) i uz jednaku razinu osvjetljenja scene budući da su snimljene tokom dnevnih sati. Drugi skup sastoji se od video snimki urbanog prometnog raskrižja snimljenih kroz period jednog cijelog dana. Kamera je ovdje postavljena okomito na cestu te slika obuhvaća tri trake za automobile te jednu tramvajsку prometnu traku. Također, vremenski uvjeti se mijenjaju kao i razina osvjetljenja (dnevno svjetlo, zora i sumrak, noćna rasvjeta). Eksperimenti na ovom skupu su posebno zanimljivi budući da su uvjeti bitno otežani. Dolazi do priličnog pomicanja i nestabilnosti kamere zbog vjetra te velik utjecaj na neke metode detekcije ima i refleksija automobilskih svjetala na površini ceste.



**Slika 7.:** Primjer slike iz prvog skupa



**Slika 8.:** Primjer slike iz drugog skupa

Početni niz validacijskih eksperimenata izvršili smo na odabranoj reprezentativnoj snimci visoke kvalitete iz prvog spomenutog skupa. Odabrana snimka se sastoji od 17500 uzastopnih slika. Model pozadine učimo na cijelom skupu tj. tokom punog trajanja snimke. Početnih 10000 slika snimke odvojili smo u početni skup za učenje i izgradnju modela pozadine te na tim slikama ne vršimo detekciju. Preostalih 7500 slika odvojili smo u skup za validaciju te se na tome skupu vrši detekcija vozila. Slike na kojima je izvršena validacija pripremili smo iz skupa za ispitivanje na sljedeći način:

- odabrana je svaka peta slika od početnih 7500 slika te je tako dobiven skup od 1500 slika na kojima će se vršiti validacijski postupak
- na slikama je ručno odabran prostor virtualne petlje unutar koje se vrši detekcija
- odabранe slike su ručno označene na sljedeći način:
  - ukoliko je prostor virtualne petlje posve ispunjen vozilom slika se označava kao pozitivna detekcija
  - ukoliko je prostor virtualne petlje posve prazan te vozilo ne zauzima niti jedan slikovni element unutra petlje slika se označava kao negativna detekcija
  - ukoliko je prostor virtualne petlje djelomično ispunjen slikovnim elementima vozila slika se ne uzima u obzir u konačnoj obradi rezultata
- na taj način skup slika koje će biti korištene za validaciju je efektivno reducirana na 1086 pozitivno ili negativno označenih slika

Zatim smo odabrali video snimku koja se sastoji od 10000 slika za pripremu ispitnog skupa. Kao i kod određivanja skupa za validaciju:

- odabrana je svaka peta slika od početnih 10000 slika te je tako dobiven skup od 2000 slika na kojima će se vršiti ispitivanje
- na slikama je ručno odabran prostor virtualne petlje unutar koje se vrši detekcija te su slike označene na isti način kao u validacijskom skupu
- time je ispitni skup reducirana na 1561 pozitivno ili negativno označenu sliku
- model se nastavlja učiti i za vrijeme ispitivanja tokom cijele ispitne snimke

Validacijske eksperimente na drugom skupu izvršili smo na dvije različite snimke. Jedna prikazuje dnevnu, a druga noćnu prometnu situaciju. Bitna značajka noćne snimke je jako malen broj automobila koji se pojave u sceni, dok se u dnevnoj snimci nalazi veći broj slika s automobilima nego slika bez automobila. Početnih 10000 slika iz dnevne snimke izdvojili smo u skup za učenje, sljedećih 7500 u skup za validaciju te konačno preostalih 10000 slika u skup za ispitivanje. Zatim smo odabrali svaku petu sliku iz skupova za validaciju i ispitivanje te smanjili broj slika na 1500 za validaciju te 2000 za ispitivanje po snimci. Za noćnu snimku je odabran duži period zbog male frekvencije automobila te je prvih 10000 slika noćne snimke određeno kao skup za učenje, zatim 10000 slika za validaciju, te konačno sljedećih 17500 kao skup za ispitivanje.

Konačno izbačene su slike koje nisu označene ni kao pozitivne ni kao negativne te smo za dnevnu snimku iz drugog skupa ostavili 1781 označenu sliku u skupu ispitivanje, a za noćnu snimku iz drugog skupa odabrali smo 3128 označenih slika u skupu za ispitivanje od kojih je samo 215 pravih pozitiva.

## 5.2. Optimiranje hiperparametara validacijom

U pripremi validacijskog postupka u početku definiramo konačan skup vrijednosti koje može poprimiti svaki pojedini hiperparametar. Validaciju zatim vršimo iscrpnom pretragom prostora svih mogućih kombinacija odabralih mogućih vrijednosti hiperparametara. Za svaku kombinaciju gradimo detekcijski model koji prolazi učenje na početnom skupu, validaciju na validacijskom skupu i ispitivanje na ispitnom skupu slika[1]. Vrijednosti unutar jednog skupa mogućih vrijednosti za pojedini hiperparametar moraju biti odabrane smisleno i razumno, ovisno o definiciji hiperparametra i njegovom utjecaju na izgradnju modela pozadine.

### 5.2.1. Ocjena dobrote detekcijskog modela

Do konačne mjere za ocjenu dobrote pojedinog detekcijskog modela s određenom kombinacijom hiperparametara dolazimo pomoću postignute preciznosti i odziva [2] na skupu za ispitivanje. Preciznost i odziv se izračunavaju na sljedeći način:

$$\text{preciznost} = \frac{TP}{TP + FP} \quad (5.1) \qquad \text{odziv} = \frac{TP}{TP + FN} \quad (5.2)$$

gdje  $TP$  označava broj ispravnih pozitivnih detekcija,  $FP$  broj lažno pozitivnih detekcija te  $FN$  broj lažno negativnih detekcija na skupu za validaciju. Preciznost pokazuje broj ispravnih detekcija u omjeru s brojem svih prijavljenih detekcija, a odziv prikazuje omjer broja ispravnih detekcija s brojem detekcija koje su trebale biti prijavljene.

Za detekcijski model koji ocjenjujemo biramo prikladan hiperparametar kao prag. Kod detekcijskih modela temeljenih na modelu pozadine ostvarenog mješavinom Gaussovih razdioba taj prag je potrebna zauzetost površine virtualne petlje za indikaciju detekcije. Za svaki detekcijski model izračunavamo postotak zauzetosti virtualne petlje u svakoj slici i uspoređujemo ga s pragom te

postavljajući prag na svaku vrijednost iz njegovog definiranog skupa računamo preciznost i odziv svakog detekcijskog modela. Izračunate vrijednosti preciznosti i odziva prikazujemo kao točke na grafu odnosa preciznosti i odziva [4] (*Precision - Recall graph*). Preciznost je prikazana na ordinati grafa, a odziv na apscisi. Iz grafa odnosa preciznosti i odziva dobivamo konačnu ocjenu dobrote pojedinog detekcijskog modela i to kao prosječnu preciznost - *average precision*, AP [3]. Prosječna preciznost definirana je kao površina ispod krivulje grafa odnosa preciznosti i odziva. Integral kojim bismo izračunali površinu smo aproksimirali sljedećom konačnom sumom preko svih vrijednosti parova preciznost - odziv rangiranih od najmanje do najveće vrijednosti za odziv:

$$AP = \sum_k^n P(k) \Delta r(k) \quad (5.3)$$

gdje je  $k$  trenutni promatrani par vrijednosti preciznosti i odziva,  $n$  ukupan broj parova,  $P(k)$  preciznost u paru vrijednosti  $k$  te se unutar sume nalazi umnožak preciznosti u paru  $k$  i razlike odziva u parovima  $k$  i  $k-1$ .

Najbolji detekcijski model (kombinacija hiperparametara) će imati najveću najveću prosječnu preciznost, te će imati točku u svojoj krivulji koja će biti najbliže gornjem desnom uglu takvog grafa. Idealna operativna točka koja se najčešće uzima u takvom grafu je ona koja je najbliža gornjem desnom uglu uz uvjet da su preciznost i odziv približno istih ili identičnih vrijednosti. Ukoliko moramo odlučiti između dva detekcijska modela koji imaju približno istu operativnu točku, odluku možemo donijeti na temelju odabira vrijednosti koja nam je bitnija - preciznost ili odziv.

### **5.2.2. Popis i definicija hiperparametara za svaki model pozadine**

#### **1. MJEŠAVINA GAUSSOVIH RAZDIOBA NA RAZINI PIKSELA - JEDNOSTUPANJSKI MODEL**

Za detekcijski model s modelom pozadine temeljenim na mješavini Gaussovih razdioba na razini piksela s jednostupanjskim eksponencijalnim pomičnim prosjekom hiperparametri odabrani za postupak validacije su stopa učenja modela -  $\alpha$ , prag razlike vrijednosti piksela trenutne slike i pripadajućeg piksela modela pozadine koji određuje pripadnost piksela trenutne slike pozadini ili prednjem planu -  $t$ , te najveći mogući broj Gaussovih razdioba u modelu pozadine -  $n$ . Posljednji hiperparametar je prag zauzetosti virtualne petlje -  $d$ . Ukoliko je više od  $d$  površine petlje zauzeto pikselima prednjeg plana, petlja dojavljuje detekciju. Na temelju tog hiperparametra crtamo graf odnosa preciznosti i odziva. Odabrani konačni skupovi vrijednosti hiperparametara u validacijskom postupku:

$$\alpha \in \{0.000001, 0.000005, 0.00001, 0.0001, 0.001, 0.005\}$$

$$t \in \{5, 10, 20, 30, 40\}$$

$$n \in \{1, 2, 3\}$$

$$d \in \{0.05, 0.1, \dots, 0.45, 0.5, 0.55, \dots, 0.95, 1\}$$

Stopa učenja  $\alpha$  određuje koliki će utjecaj imati trenutna slika u fazi osvježavanja modela pozadine. Veoma niske vrijednosti ( $< 0.001$ ) će držati taj utjecaj niskim i time osigurati sporiju prilagodljivost modela pozadine na promjene. Veće vrijednosti stope učenja rezultirati će većom prilagodljivosti modela pozadine trenutnoj sceni te će statični objekti brže postajati dio modela pozadine. Definirane vrijednosti stope učenja su odabrane s ciljem određivanja optimalne razine utjecaja trenutne slike na model pozadine.

## 2. MJEŠAVINA GAUSSOVIH RAZDIOBA NA RAZINI PIKSELA - JEDNOSTUPANJSKI MODEL S PERIODIČNOM ODGODOM

Ovaj detekcijski model se razlikuje od prošloga po tome što ustvari gradimo tri modela pozadine. Prvi je dinamičan i posve istovjetan modelu pozadine bez odgode, a drugi je samo međumodel tj. statična reprezentacija dinamičnog modela pozadine koja se pamti svakih  $N$  slika ulaznog videa, dok je treći također statična reprezentacija dinamičnog modela pozadine od prije  $2N$  slika te je upravoj taj model onaj koji se koristi u detekciji. Hiperparametar koji se uvodi je broj slika nakon kojih se pamti stanje dinamičnog modela ili period odgode -  $N$ . Odgoda se uvodi radi izbjegavanja prebrzog prilagođavanja modela pozadine trenutnoj sceni te vjerujemo da bi idealan broj slika odgode bio u korelaciji s trajanjem jednog ciklusa semafora u promatranom raskrižju. U validaciji prvog modela određen je broj mješavina Gaussovih razdioba te taj hiperparametar više nije ulazio u validacijske postupke ostalih modela. Hiperparametar koji je odabran za prag na temelju kojeg se izrađuje graf odnosa preciznosti i odziva je prag zauzetosti virtualne petlje -  $d$ .

Odabrani konačni skupovi vrijednosti hiperparametara u validacijskom postupku:

$$\alpha \in \{0.000001, 0.000005, 0.00001, 0.0001\}$$

$$t \in \{5, 10, 15, 20, 25, 30, 35, 40\}$$

$$N \in \{100, 500, 1000, 1500, 2000, 2500, 3000, 4000, 5000\}$$

$$d \in \{0.05, 0.1, \dots, 0.45, 0.5, 0.55, \dots, 0.95, 1\}$$

Ovakav model pozadine bi trebao biti manje prilagodljiv trenutnoj sceni te su zato u postupku za stopu učenja odabrane samo niže vrijednosti u usporedbi s vrijednostima za prošli model.

### 3. MJEŠAVINA GAUSSOVIH RAZDIOBA NA RAZINI PIKSELA - DVOSTUPANJSKI MODEL S PERIODIČNOM ODODOM

Detekcijski model mješavina Gaussovih razdioba s dvostupanjskim eksponencijalnim pomičnim prosjekom sastoji se od dva jednostupanjska modela mješavina Gaussovih razdioba, zato ga nazivamo dvostupanjskim. Prvi se osvježava svakom novom slikom ulaznog videa te ima stopu učenja  $\alpha$  koja mora biti dosta malen broj. Kao i u prošlom modelu uvodimo parametar  $N$  koji predstavlja trajanje izgradnje modela u prvom stupnju, odnosno period osvježavanja modela iz drugog stupnja te se također koristi i kao period odgode kao u prošlom modelu. Drugi model se osvježava svakih  $N$  ulaznih slika sa slikom koja je trenutna reprezentacija prvog modela te njegova stopa učenja  $\alpha_d$  mora biti dosta visoka zbog mnogo manjeg broja slika koje ulaze u izgradnju tog modela pozadine. Na taj način vršimo raspršenje i uzorkovanje prvog modela pozadine. Konačni model pozadine koji se koristi pri detekciji je reprezentacija raspršeno uzorkovanog modela pozadine odgođena za  $N$  slika. Prag na temelju kojeg se izrađuje graf odnosa preciznosti i odziva je i dalje prag zauzetosti virtualne petlje -  $d$ . Parametar  $t$  je određen u prijašnjim postupcima i ne pojavljuje se u eksperimentima za ovaj detekcijski model.

Odabrani konačni skupovi vrijednosti hiperparametara u validacijskom postupku:

$$\alpha \in \{0.000001, 0.000005, 0.00001, 0.00015, 0.0001\}$$

$$\alpha_d \in \{0.1, 0.3, 0.5, 0.6, 0.7, 0.8, 0.9\}$$

$$N \in \{1000, 2000, 2500, 3000, 4000, 5000\}$$

$$d \in \{0.05, 0.1, \dots, 0.45, 0.5, 0.55, \dots, 0.95, 1\}$$

#### 4. HISTOGRAM ORIJENTACIJE GRADIJENTA NA RAZINI ĆELIJE 8 PUTA 8 PIKSELA

Model pozadine temeljen na histogramu orijentacije gradijenta gradimo eksponencijalnim pomičnim prosjekom uz stopu učenja  $\alpha$ . Hiperparametar detekcijskog modela na temelju kojeg izrađujemo graf odnosa preciznosti i odziva modela je prag  $k$  na temelju kojeg određujemo indikaciju detekcije u promatranoj ćeliji na sljedeći način:

$$(I_t - \mu_t)^2 > k \rightarrow \text{detekcija} \quad (5.4)$$

$$(I_t - \mu_t)^2 \leq k \rightarrow \text{pozadina} \quad (5.5)$$

gdje je  $I_t$  trenutni vektor HOG značajki za promatranu ćeliju,  $\mu_t$  vektor srednjih vrijednosti HOG značajki za promatranu ćeliju. Odabrani skupovi vrijednosti hiperparametara u validacijskom postupku:

$$\alpha \in \{0.000001, 0.000005, 0.00001, 0.0001, 0.005, 0.001, 0.005\}$$

$$k \in \{0, 0.05, 0.1, \dots, 0.5, \dots, 1, \dots, 1.5, \dots, 2, \dots, 2.5, \dots, 2.95, 3\}$$

#### 5. HISTOGRAM ORIJENTACIJE GRADIJENTA NA RAZINI ĆELIJE 8 PUTA 8 PIKSELA - DVOSTUPANJSKI MODEL

Kao i kod dvostupanjskog detekcijskog modela temeljenog na Gaussovim razdiobama i ovdje se izgradnja vrši na isti način. U usporedbi s jednostupanjskim HOG detekcijskim modelom uvodimo stopu učenja modela drugog stupnja te broj slika nakon kojih se vrši osvježavanje modela drugog stupnja.

$$\alpha \in \{0.000001, 0.000005, 0.00001\}$$

$$\alpha_d \in \{0.1, 0.3, 0.5, 0.7, 0.9\}$$

$$k \in \{0, 0.05, 0.1, \dots, 0.5, \dots, 1, \dots, 1.5, \dots, 2, \dots, 2.5, \dots, 2.95, 3\}$$

$$N \in \{1000, 2000, 3000, 4000, 5000\}$$

## 5.3. Prikaz i ocjena ostvarenih rezultata

Rezultate validacijskih eksperimenata na prvom i drugom skupu podataka prikazali smo putem tablica koje sadrže presjek rezultata te podatke o detekcijskim modelima koji su ih postigli, te su uz rezultate priloženi grafovi odnosa preciznosti i odziva. Rezultati u tablicama su izraženi prosječnom preciznošću na ispitnom skupu budući da nam je cilj ocijeniti generalizacijsku sposobnost najboljih detekcijskih modela. Rezultati su prokomentirani i određen je najpogodniji prostor vrijednosti za svaki optimirani hiperparametar.

### 5.3.1. Rezultati validacijskih eksperimenata i ispitivanja

#### 1. MJEŠAVINA GAUSSOVIH RAZDIOBA NA RAZINI PIKSELA - JEDNOSTUPANJSKI MODEL

**Tablica 1.** Odabrani najbolji modeli u postupku validacije i njihovi rezultati pri ispitivanju MoG jednostupanjskog modela, prag za izgradnju graf odnosa preciznosti i odziva je  $d$ , a kriterij odabira najboljih AP - average precision, prosječna preciznost na ispitnom skupu. AP1 je prosječna preciznost na prvom skupu, AP2 je prosječna preciznost na drugom skupu.

| RB model | $\alpha$ | $t$ | $n$ | AP1           | AP2 dnevna     | AP2 noćna |
|----------|----------|-----|-----|---------------|----------------|-----------|
| 1,2      | 0,000001 | 20  | 2,3 | 97,57%        | 76,38%         | 31,51%    |
| 3        | 0,000001 | 20  | 1   | 63,78%        | 9,07%          | 5,97%     |
| 4,5      | 0,000001 | 30  | 2,3 | 97,74%        | 76,23%         | 43,06%    |
| 6        | 0,000001 | 30  | 1   | 54,11%        | 7,68%          | 6,09%     |
| 7,8      | 0,000001 | 40  | 2,3 | 98,14%        | 76,07%         | 50,06%    |
| 9        | 0,000001 | 40  | 1   | 46,14%        | 6,96%          | 6,37%     |
| 10,11    | 0,000005 | 20  | 2,3 | 97,59%        | 76,40%         | 32,73%    |
| 12       | 0,000005 | 20  | 1   | 62,6%         | 8,92%          | 5,85%     |
| 13,14    | 0,000005 | 30  | 2,3 | 97,77%        | 76,28%         | 43,9%     |
| 15,16    | 0,000005 | 40  | 2,3 | 98,14%        | 74,44% / 76,05 | 52,03%    |
| 17       | 0,00001  | 20  | 3   | <b>98,59%</b> | 76,09%         | 35,69%    |
| 18       | 0,00001  | 30  | 3   | 98,06%        | 75,64%         | 47,98%    |

| RB model | $\alpha$ | $t$ | $n$ | AP1    | AP2 dnevna | AP2 noćna |
|----------|----------|-----|-----|--------|------------|-----------|
| 19,20    | 0,00001  | 40  | 2,3 | 98,83% | 76%        | 56,14%    |
| 20       | 0,0001   | 20  | 3   | 97,99% | 74,83%     | 71,43%    |
| 21       | 0,0001   | 20  | 2   | 98,30% | 76,05%     | 68,05%    |
| 22       | 0,0001   | 30  | 3   | 98,00% | 79,99%     | 78,77%    |
| 23       | 0,0001   | 30  | 2   | 98,76% | 76,29%     | 77,39%    |
| 24       | 0,0001   | 40  | 3   | 98,07% | 75,81%     | 84,07%    |
| 25       | 0,0001   | 40  | 2   | 98,98% | 79,41%     | 83,99%    |

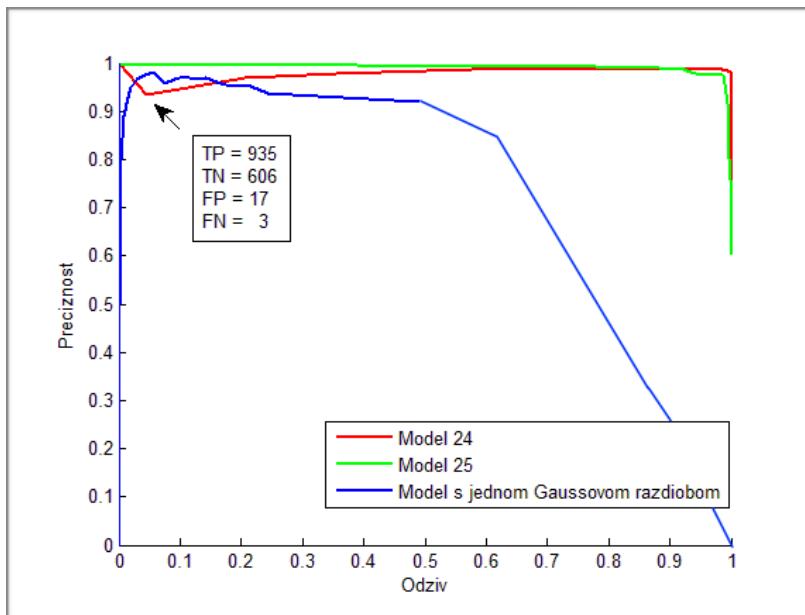
**Tablica 2.** Prikaz izabranih točaka grafovima preciznost-odziv različitih detekcijskih modela u validaciji MoG jednostupanjskog modela na prvom skupu podataka. Ilustracija bitnosti parametra praga na razini piksela te stope učenja

| RB točke | $\alpha$ | $t$ | $n$ | $d$ | TP  | TN  | FP  | FN | preciznost | odziv  |
|----------|----------|-----|-----|-----|-----|-----|-----|----|------------|--------|
| 1        | 0.00005  | 40  | 3   | 0,3 | 258 | 364 | 464 | 0  | 35,73%     | 100%   |
| 2        | 0,00001  | 40  | 3   | 0,3 | 258 | 361 | 467 | 0  | 35,58%     | 100%   |
| 3        | 0,0001   | 40  | 3   | 0,2 | 257 | 820 | 8   | 1  | 98,52%     | 99,15% |
| 4        | 0,0001   | 40  | 3   | 0,3 | 256 | 821 | 7   | 2  | 97,34%     | 99,22% |
| 5        | 0,0001   | 30  | 3   | 0,3 | 257 | 820 | 8   | 1  | 98,52%     | 99,15% |
| 6        | 0,0001   | 20  | 3   | 0,3 | 257 | 818 | 10  | 1  | 96,25%     | 99,15% |

**Tablica 3.** Prikaz dobrih operativnih točaka detekcijskih modela s najvećom prosječnom preciznošću gledajući rezultate na skupu za ispitivanje, prvi skup podataka, redni broj modela kao u Tablici 1.

| RB Model | $\alpha$ | $t$ | $n$ | $d$  | TP  | TN  | FP | FN | preciznost | odziv  |
|----------|----------|-----|-----|------|-----|-----|----|----|------------|--------|
| 24       | 0,0001   | 40  | 3   | 0,15 | 933 | 608 | 15 | 5  | 98,42%     | 99,47% |
| 25       | 0,0001   | 40  | 2   | 0,4  | 927 | 598 | 25 | 11 | 97,38%     | 98,83% |
| 22       | 0,0001   | 30  | 3   | 0,1  | 937 | 605 | 18 | 1  | 98,12%     | 99,89% |
| 19,20    | 0,00001  | 40  | 2,3 | 0,55 | 885 | 599 | 24 | 53 | 97,36%     | 94,35% |

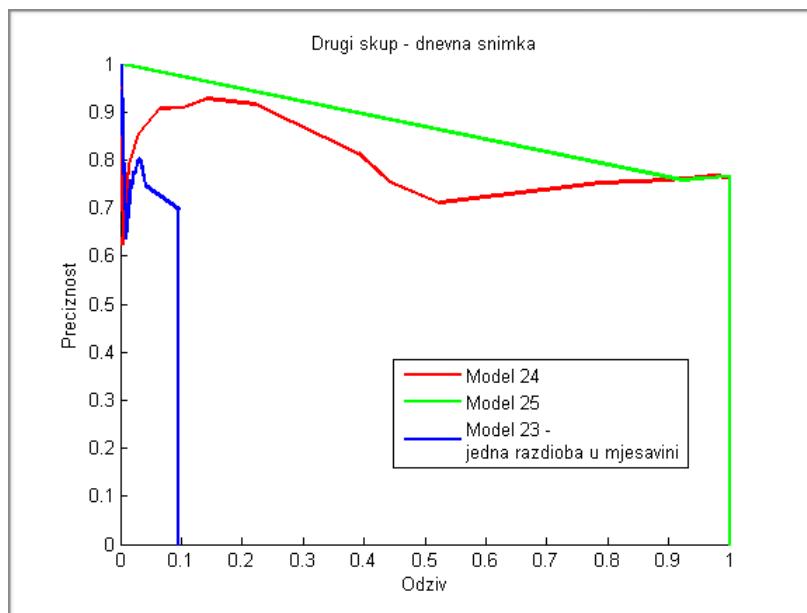
Promotrimo li podatke prikazane u tablicama s naglaskom na rezultate validacije dobivene na skupu podataka iz prve video snimke vidi se da je vrijednost stope učenja  $\alpha$  za ovaj model najbolje postaviti približno na 0,0001. Vrijednost praga  $t$  bi pak trebala biti između 20 i 40, dok bi najveći mogući broj Gaussovih razdioba u mješavini modela trebao biti 2 ili 3 jer rezultati modela koji koriste samo jednu razdiobu su polučili u prosjeku duplo slabije rezultate te se da zaključiti da takvi jednostavniji modeli ipak nisu dorasli ovom zadatku. Što se praga zauzetosti virtualne petlje  $d$  tiče, najpogodnije vrijednosti su u rasponu od 20 do 40 posto zauzetosti petlje.



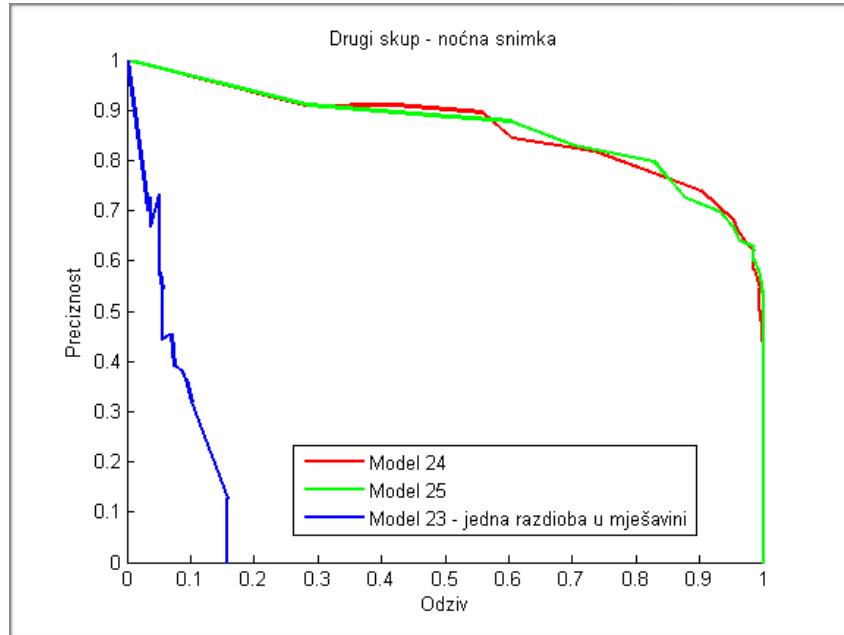
**Graf 3.** Odnos preciznosti i odziva za detekcijske modele iz Tablice 1., jednostupanjska mješavina Gaussovih razdioba, prvi skup podataka

Na grafu 3. vidimo krivulje odnosa preciznosti i odziva za tri različita modela. Stvar koju je bitno primijetiti je odnos modela 24 i 25. Model 25 ima ukupno bolju prosječnu preciznost. To znači da je površina grafa ispod krivulje modela 25 veća od površine grafa ispod krivulje 24. S druge strane, ako promotrimo operativne točke tih modela, vidimo da model 24 ima bolju operativnu točku. Razlog toj razlici u površini nalazi se u lijevom gornjem kutu grafa gdje vidimo točku u koju dolazimo mijenjajući prag zauzetosti virtualne petlje te se u

tom specifičnom trenutku pojavljuje nagli skok u broju lažnih pozitiva. Broj pravih pozitiva zatim naraste te se iznos preciznosti povećava.



**Graf 4.** Odnos preciznosti i odziva za detekcijske modele iz Tablice 1., jednostupanjska mješavina Gaussovih razdioba, drugi skup podataka, dnevna snimka



**Graf 5.** Odnos preciznosti i odziva za detekcijske modele iz Tablice 1., jednostupanjska mješavina Gaussovih razdioba, drugi skup podataka, noćna snimka

## 2. MJEŠAVINA GAUSSOVIH RAZDIOBA NA RAZINI PIKSELA - JEDNOSTUPANJSKI MODEL S ODGODOM

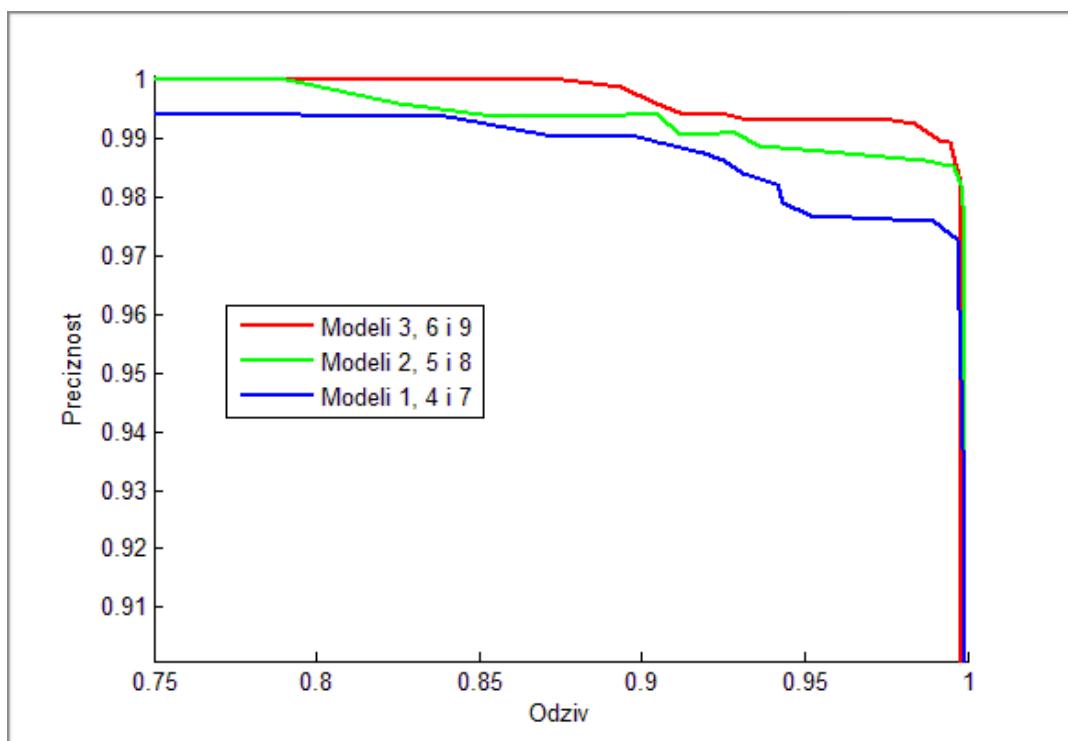
**Tablica 4.** Odabrani najbolji modeli u postupku validacije i njihovi rezultati pri ispitivanju MoG jednostupanjskog modela s odgodom, prag za izgradnju graf odnosa preciznosti i odziva je  $d$ , a kriterij odabira AP - average precision, prosječna preciznost na ispitnom skupu. AP1 je prosječna preciznost na prvom skupu, AP2 je prosječna preciznost na drugom skupu.

| RB model | $\alpha$       | $t$       | $N$                             | AP1           | AP2 dan                     | AP2 noć            |
|----------|----------------|-----------|---------------------------------|---------------|-----------------------------|--------------------|
| 1        | 0,00001        | 20        | 2000/2500/<br>3000/4000         | 99,19%        | 77% do 79%                  | svi oko 25%        |
| 2        | 0,00001        | 30        | 2000/2500/<br>3000/4000         | <b>99,79%</b> | <b>78,49% do<br/>81,52%</b> | svi oko 38%        |
| 3        | <b>0,00001</b> | <b>40</b> | <b>2000/2500/<br/>3000/4000</b> | <b>99,86%</b> | 76,82% do<br>81,86%         | <b>svi oko 48%</b> |
| 4        | 0,00005        | 20        | 2000/2500/<br>3000/4000         | 99,18%        | 76,73% do<br>79,57%         | svi oko 25%        |
| 5        | 0,00005        | 30        | 2000/2500/<br>3000/4000         | <b>99,79%</b> | <b>78,28% do<br/>81,99%</b> | svi oko 38%        |
| 6        | <b>0,00005</b> | <b>40</b> | <b>2000/2500/<br/>3000/4000</b> | <b>99,86%</b> | 76,83% do<br>81,86%         | <b>svi oko 48%</b> |
| 7        | 0,0001         | 20        | 2000/2500/<br>3000/4000         | 99,18%        | 76,73% do<br>79,57%         | svi oko 25%        |
| 8        | 0,0001         | 30        | 2000/2500/<br>3000/4000         | <b>99,80%</b> | <b>78,28% do<br/>81,99%</b> | svi oko 38%        |
| 9        | <b>0,0001</b>  | <b>40</b> | <b>2000/2500/<br/>3000/4000</b> | <b>99,86%</b> | <b>77,94% do<br/>80,29%</b> | <b>svi oko 49%</b> |

**Tablica 5.** Prikaz odabranih rezultata te dobrih operativnih točaka detekcijskih modela s najvećom prosječnom preciznošću gledajući rezultate na skupu za ispitivanje (podebljano), **prvi skup podataka**, redni broj modela kao u Tablici 4.

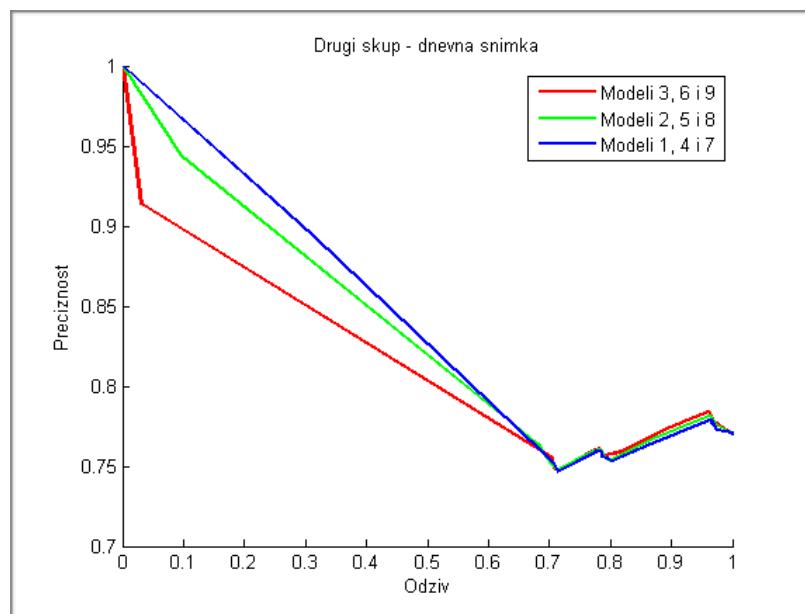
| RB | $\alpha$       | $t$       | $N$         | $d$         | TP         | TN         | FP        | FN        | preciznost    | odziv         |
|----|----------------|-----------|-------------|-------------|------------|------------|-----------|-----------|---------------|---------------|
| 9  | <b>0.0001</b>  | <b>40</b> | <b>4000</b> | <b>0,15</b> | <b>933</b> | <b>613</b> | <b>10</b> | <b>5</b>  | <b>98,94%</b> | <b>99,47%</b> |
| 6  | <b>0,00005</b> | <b>40</b> | <b>4000</b> | <b>0,15</b> | <b>931</b> | <b>613</b> | <b>10</b> | <b>5</b>  | <b>98,94%</b> | <b>99,47%</b> |
| 3  | <b>0.0001</b>  | <b>40</b> | <b>3000</b> | <b>0,2</b>  | <b>931</b> | <b>613</b> | <b>10</b> | <b>5</b>  | <b>98,94%</b> | <b>99,47%</b> |
| 1  | <b>0.00001</b> | <b>20</b> | <b>2000</b> | <b>0,75</b> | <b>862</b> | <b>512</b> | <b>11</b> | <b>76</b> | <b>98,99%</b> | <b>91,89%</b> |
| 5  | 0,00005        | 40        | 2000        | 0,75        | 807        | 623        | 0         | 131       | 100%          | 86,03%        |
| 6  | 0,00005        | 40        | 4000        | 0,75        | 807        | 623        | 0         | 131       | 100%          | 86,03%        |

Model temeljen na mješavini Gaussovih razdioba uz odgodu implementirali smo da bi mogli odrediti utjecaj vremenske odgode modela na eventualno poboljšanje rada programa pri situacijama u kojima se pojedino vozilo dugo zadržava u sceni i polako prelazi u pozadinu. Očekivano je da bi najbolje rezultate trebao imati model uz odgodu u trajanju približnog perioda semafora (oko 120 sekundi, 3000 slika), ali validacijski eksperimenti nisu potvrdili ta očekivanja iako ovaj model daje malo bolje rezultate od jednostupanjskog modela bez odgode na prvom skupu. Teško je reći da li je to poboljšanje zbilja rezultat odgode ili slučajnost vezana uz odabranu ispitnu video snimku. Poboljšanje je posve neovisno o parametru N te je vjerojatno uzrokovano samim odgađanjem budući da je to jedina stvar koja razlikuje ovaj pristup od prvog opisanog. Na drugom skupu u noćnoj snimci primjećujemo da su rezultati mnogo lošiji te odgoda ovdje ne pomaže već utječe na pogoršanje rezultata.

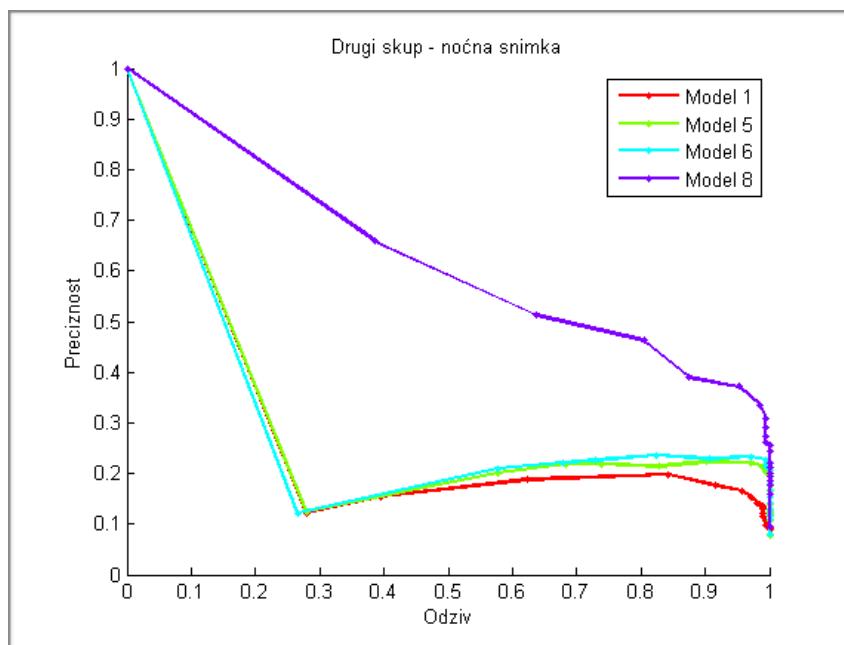


Graf 6. Odnos preciznosti i odziva detekcijskih modela prikazanih u Tablici 4., jednostupanjski MoG s odgodom, prvi skup podataka

Grafovi 7. i 8. prikazuju rezultate na drugom skupu podataka koji je općenito tež za vršenje detekcije na njemu zbog manje kvalitete snimke, treskanja kamere te čestih promjena u osvjetljenju scene. Rezultati detekcijskog modela s odgodom posebno su opali na noćnim scenama budući da se model presporo prilagođava sceni.



**Graf 7.** Odnos preciznosti i odziva za detekcijske modele iz Tablice 4., jednostupanjska mješavina Gaussovih razdioba s odgodom, drugi skup podataka, dnevna snimka



**Graf 8.** Odnos preciznosti i odziva za detekcijske modele iz Tablice 4., jednostupanjska mješavina Gaussovih razdioba s odgodom, drugi skup podataka, ноћна снимка

### 3. MJEŠAVINA GAUSSOVIH RAZDIOBA NA RAZINI PIKSELA - DVOSTUPANJSKI MODEL

**Tablica 6.** Odabrani najbolji modeli u postupku validacije i njihovi rezultati pri ispitivanju MoG dvostupanjskog modela, prag za izgradnju graf odnosa preciznosti i odziva je  $d$ , a kriterij odabira AP - average precision, prosječna preciznost na ispitnom skupu. AP1 je prosječna preciznost na prvom skupu, AP2 je prosječna preciznost na drugom skupu.

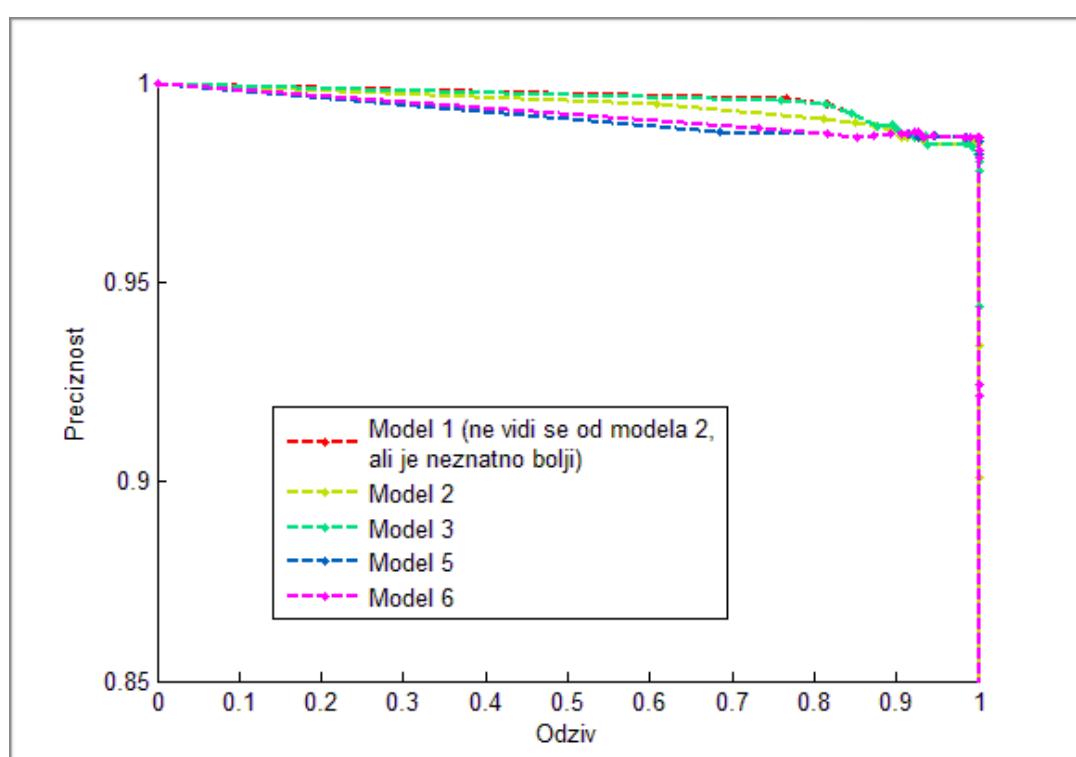
| RB<br>model | $\alpha$ | $\alpha_d$ | $t$ | $N$  | AP1           | AP2 dan       | AP2 noć       |
|-------------|----------|------------|-----|------|---------------|---------------|---------------|
| 1           | 0,000001 | 0,7        | 30  | 2500 | <b>99,43%</b> | 81,96%        | 16,40%        |
| 2           | 0,000001 | 0,8        | 30  | 2500 | 99,25%        | <b>82,89%</b> | 17,74%        |
| 3           | 0,000001 | 0,7        | 30  | 2500 | <b>99,42%</b> | 81,73%        | 16,64%        |
| 4           | 0,000001 | 0,8        | 30  | 3000 | 98,5%         | <b>82,89%</b> | 16,3%         |
| 5           | 0,00001  | 0,7        | 30  | 3000 | 99,29%        | 82,33%        | 18,7%         |
| 6           | 0,000015 | 0,7        | 30  | 3000 | 99,17%        | 79,78%        | 19,42%        |
| 7           | 0,000015 | 0,7        | 35  | 2500 | 98,80%        | <b>82,73%</b> | 18,62%        |
| 8           | 0,000015 | 0,9        | 30  | 2000 | 89,44%        | 73,01%        | <b>55,67%</b> |
| 9           | 0,000015 | 0,9        | 30  | 2500 | 98,82%        | 82,03%        | 18,24%        |
| 10          | 0,000015 | 0,9        | 30  | 3000 | 98,56%        | 77,19%        | 17,37%        |

**Tablica 7.** Prikaz dobrih operativnih točaka modela s najvećom prosječnom preciznošću gledajući rezultate na skupu za ispitivanje, prvi skup podataka, redni broj modela kao u Tablici 6.

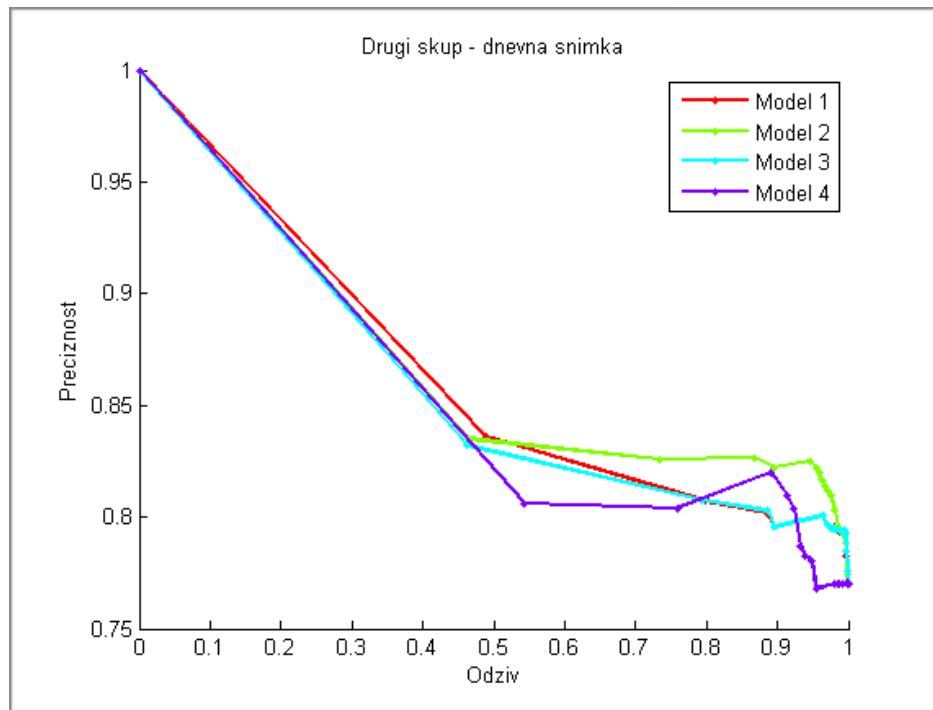
| RB | $\alpha$ | $\alpha_d$ | $N$  | $d$  | TP  | TN  | FP | FN | preciznost | odziv  |
|----|----------|------------|------|------|-----|-----|----|----|------------|--------|
| 1  | 0,000001 | 0,7        | 2500 | 0,25 | 936 | 606 | 17 | 2  | 98,22%     | 99,78% |
| 2  | 0,000001 | 0,8        | 2500 | 0,25 | 936 | 608 | 15 | 2  | 98,42%     | 99,78% |
| 3  | 0,000001 | 0,7        | 2500 | 0,3  | 931 | 608 | 15 | 7  | 98,41%     | 99,25% |
| 5  | 0,00001  | 0,7        | 3000 | 0,25 | 938 | 609 | 14 | 0  | 98,53%     | 100%   |
| 6  | 0,000015 | 0,7        | 3000 | 0,25 | 938 | 610 | 13 | 0  | 98,63%     | 100%   |

\*  $t = 30$  za sve modele

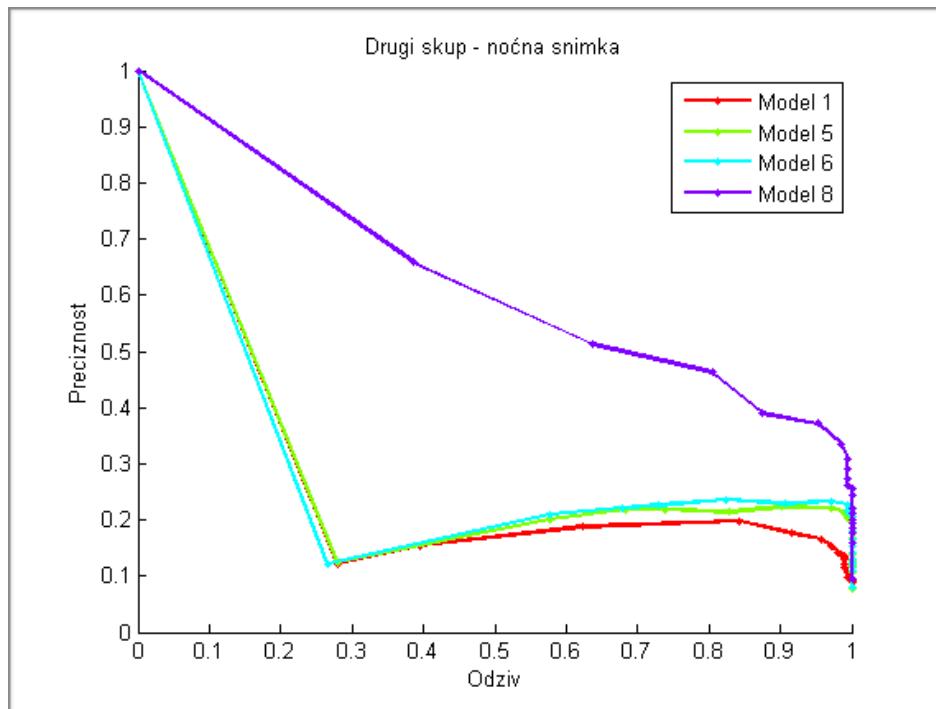
Kao što je bilo i predviđeno, stopa učenja raspršenog modela potvrđena validacijom je dosta visoka i iznosi između 0.7 i 0.9, a stopa učenja dinamičnog modela pozadine je veoma niska. Dvostupanjski model pozadine uveden je kako bismo dobili raspršenu i odgođenu reprezentaciju dinamičnog modela koja bi sadržavala ukupnu informaciju, ali bi bila otpornija na brze promjene scene i prelazak u pozadinu objekata koji se duže zadržavaju u sceni. Eksperimenti su pokazali da to nije slučaj i takav model ostvaruje ponekad i slabije rezultate od jednostupanjskog modela bez odgode i raspršivanja, posebno to vidimo u drugom skupu gdje koncept odgode donosi pogoršanje rezultata. Model pozadine s odgodom i raspršivanjem je dosta složeniji od osnovnog jednostupanjskog modela, ali ne donosi poboljšanje u rezultatima detekcijskih modela temeljenih na odgodi i raspršivanju prvog stupnja modela s mješavinom Gaussovinh razdioba.



**Graf 9.** Odnos odziva detekcijskih modela prikazanih u Tablici 6., dvostupanjski MoG modeli



**Graf 10.** Odnos odziva detekcijskih modela prikazanih u Tablici 6., dvostupanjski MoG modeli, drugi skup podataka, dnevna snimka



**Graf 11.** Odnos odziva detekcijskih modela prikazanih u Tablici 6., dvostupanjski MoG modeli, drugi skup podataka, noćna snimka

#### 4. HISTOGRAM ORIJENTACIJE GRADIJENTA NA RAZINI ĆELIJE 8 PUTA 8 PIKSELA

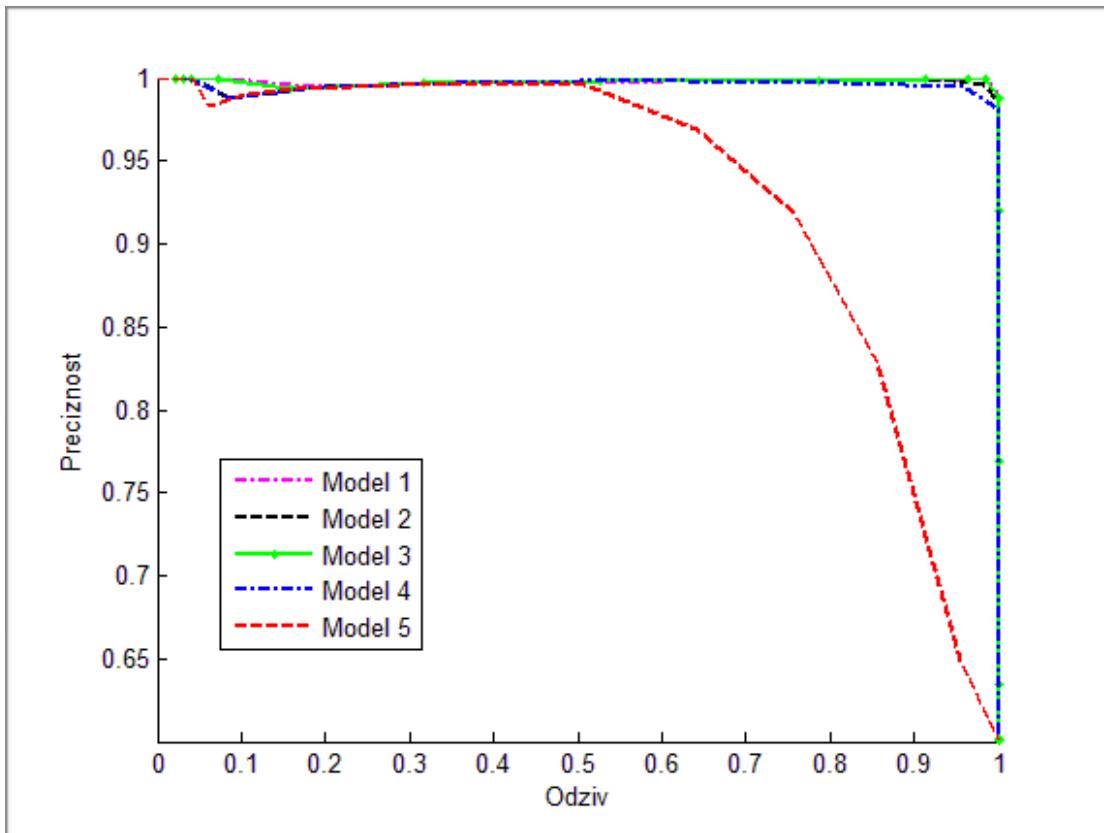
**Tablica 8.** Odabrani najbolji modeli u postupku validacije i njihovi rezultati u koraku ispitivanja HOG modela na razini ćelije 8x8 piksela, prag za izgradnju graf odnosa preciznosti i odziva je  $k$  - prag za detekciju unutar ćelije, a kriterij odabira najboljih AP - average precision, prosječna preciznost na ispitnom skupu. AP1 je prosječna preciznost na prvom skupu, AP2 je prosječna preciznost na drugom skupu.

| RB model | $\alpha$ | AP1    | AP2 dan | AP2 noć |
|----------|----------|--------|---------|---------|
| 1        | 0,00001  | 99,78% | 78,31%  | 90,71%  |
| 2        | 0,00005  | 99,57% | 78,57%  | 91,26%  |
| 3        | 0,00001  | 99,77% | 78,88%  | 88,07%  |
| 4        | 0,0001   | 99,69% | 77,93%  | 89,86%  |
| 5        | 0,0005   | 91,45% | 74,03%  | 87,40%  |

**Tablica 9.** Prikaz dobrih operativnih točaka modela gledajući rezultate na skupu za ispitivanje, prvi skup podataka, redni broj modela kao u Tablici 8.

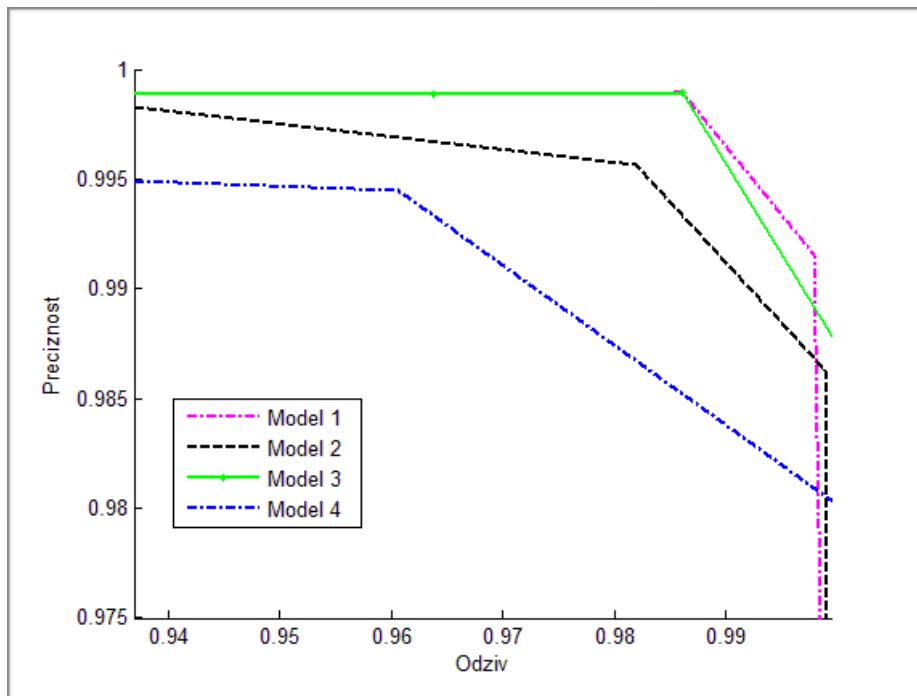
| RB | $\alpha$ | $k$  | TP  | TN  | FP  | FN  | preciznost | odziv  |
|----|----------|------|-----|-----|-----|-----|------------|--------|
| 1  | 0,000001 | 0,45 | 936 | 615 | 8   | 2   | 99,15%     | 99,79% |
| 2  | 0,00005  | 0,3  | 937 | 610 | 13  | 1   | 98,63%     | 99,89% |
| 3  | 0,00001  | 0,4  | 938 | 611 | 12  | 0   | 98,74%     | 100%   |
| 4  | 0,0001   | 0,25 | 938 | 604 | 19  | 0   | 98,01%     | 100%   |
| 5  | 0,0005   | 0,2  | 803 | 457 | 166 | 135 | 82,86%     | 85,6%  |

Validacija pokazuje da se optimalna stopa učenja HOG modela učenog eksponencijalnim pomicnim prosjekom kreće između 0,000001 i 0,0001. U slučaju niže vrijednosti stope učenja optimalan prag za detekciju unutar ćelije  $k$  bi trebao biti iznositi oko 0.45 - 0.5, a u slučaju nešto više stope učenja od primjerice 0,0001 taj prag se smanjuje i iznosi oko 0.3. Na noćnim snimkama pak prag  $k$  bi trebao biti iznad 1 te ići čak i do 1,5.

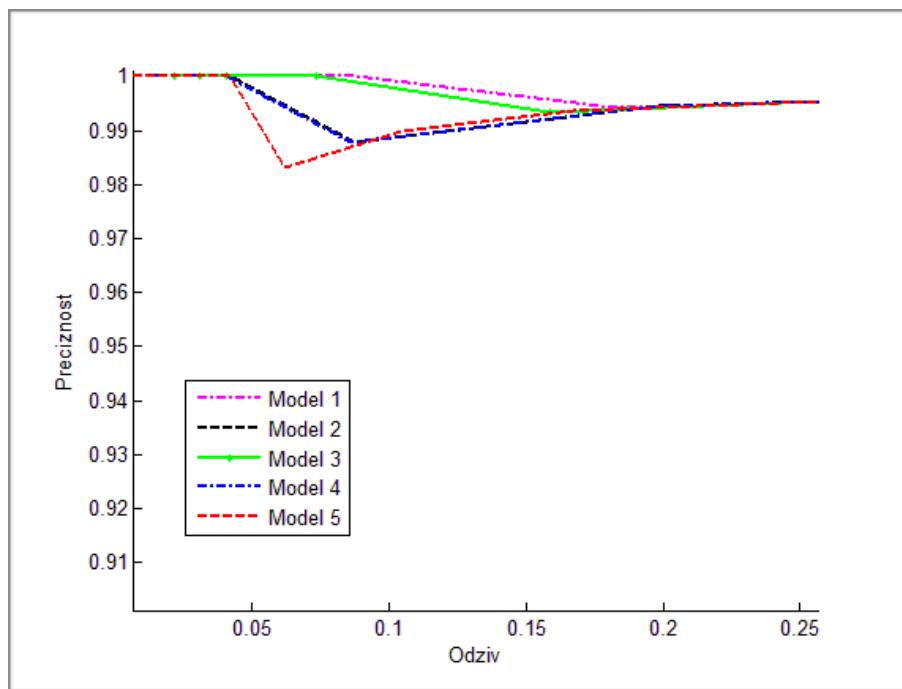


**Graf 12.** Odnos preciznosti i odziva modela prikazanih u Tablici 8., jednostupanjski modeli temeljeni histogramu orijentacije gradijenta, prvi skup

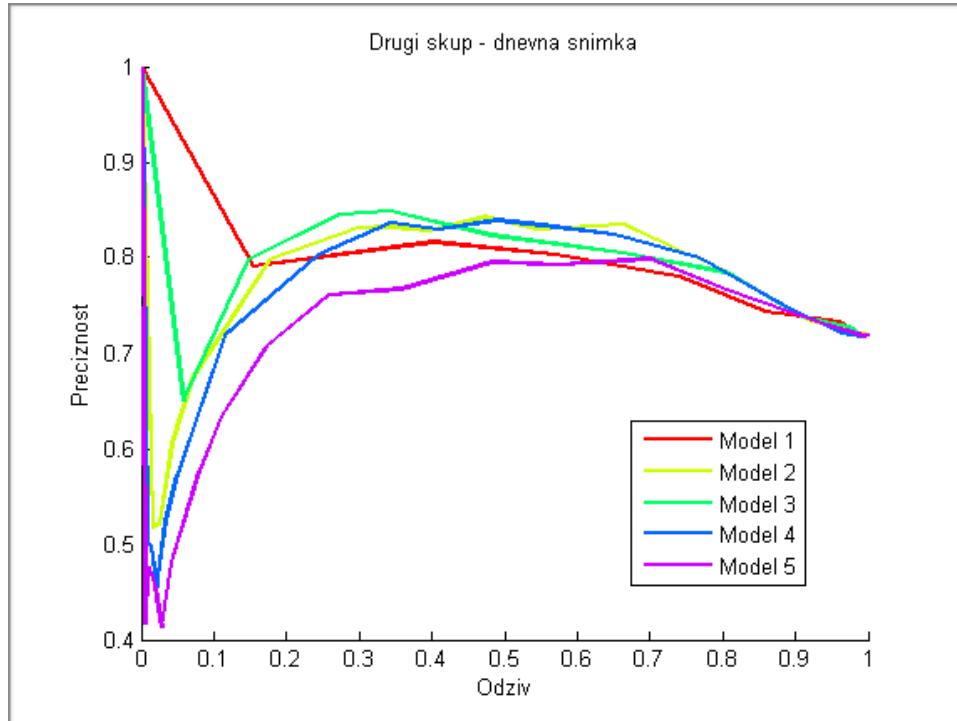
Model temeljen na histogramu orijentacije gradijenta na razini ćelije se pokazao najuspješnijom metodom u validacijskoj fazi eksperimenata na oba skupa slika. Rezultati na drugom skupu slika su ispali nešto lošiji zbog same razlike u skupovima te učestalog treskanja kamere. HOG na dnevnoj snimci drugog skupa daje rezultate koji su i dalje mjerljivi s MOG modelima, čak i bolji u nekim situacijama. Detekcijski modeli temeljeni na HOG modelu pozadine su ostvarili osjetno bolje rezultate na noćnoj snimci nego oni temeljeni na MOG postupcima. Uzrok toga je bolja otpornost HOG modela pozadine na lokalne promjene u osvjetljenju koje su veoma česte u noćnoj snimci zbog automobilskih svjetla i sjene koju bacaju tramvaji koji prolaze.



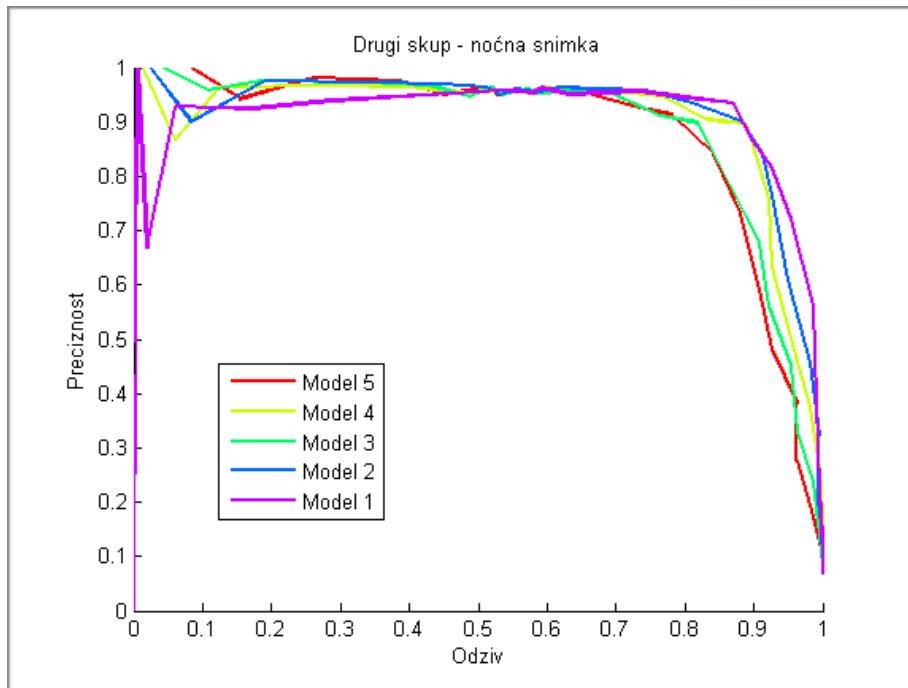
**Graf 13.** Uvećani desni gornji ugao Grafa 6. Prikazuje operativne točke iz tablice 9. za modele iz Tablice 8., prvi skup podataka



**Graf 14.** Uvećani gornji lijevi ugao Grafa 13. Prikazuje točke u kojima se događa naglo pojavljivanje lažnih pozitiva koje smanjuje ukupnu prosječnu preciznost promatranih modela opisanih u Tablici 8., prvi skup podataka



**Graf 15.** Odnos preciznosti i odziva modela prikazanih u Tablici 8., jednostupanjski modeli temeljeni histogramu orijentacije gradijenta, drugi skup podataka - dnevna snimka



**Graf 16.** Odnos preciznosti i odziva modela prikazanih u Tablici 8. , jednostupanjski modeli temeljeni histogramu orijentacije gradijenta, drugi skup podataka - noćna snimka

## 5. HISTOGRAM ORIJENTACIJE GRADIJENTA NA RAZINI ĆELIJE 8 PUTA 8 PIKSELA - DVOSTUPANJSKI MODEL

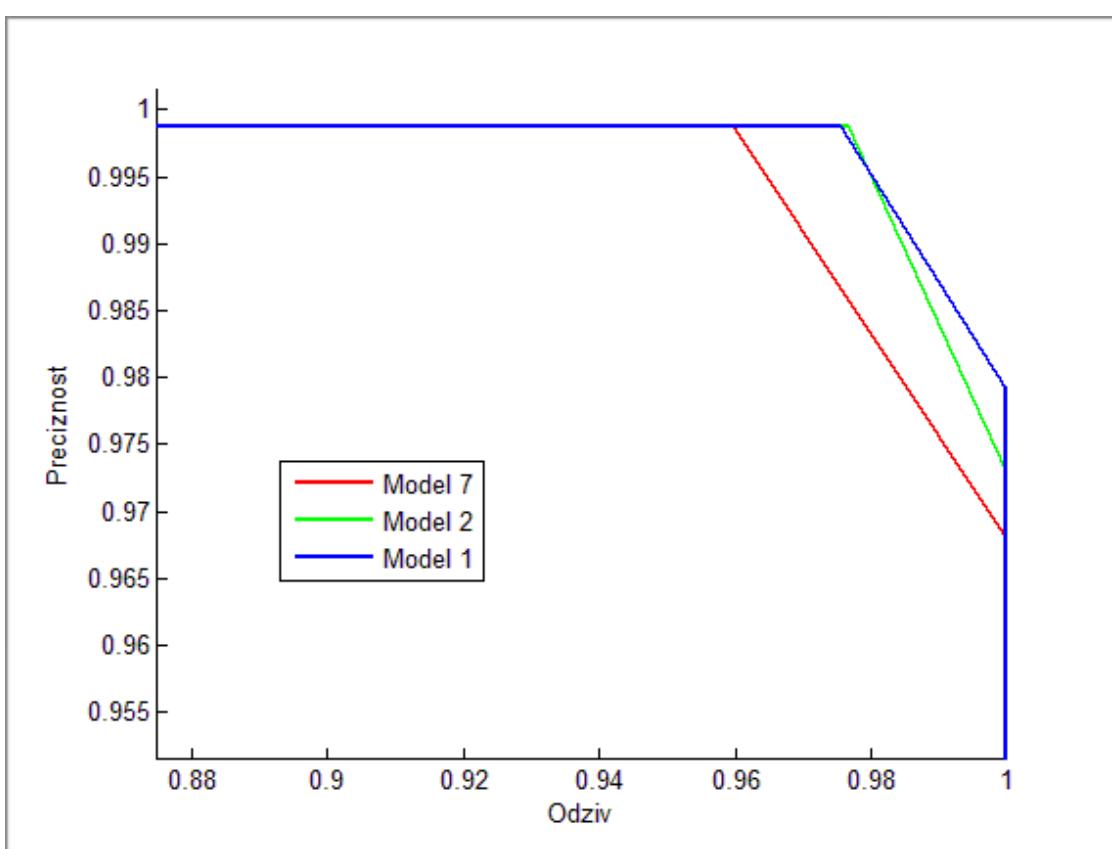
**Tablica 10.** Odabrani najbolji modeli u postupku validacije i njihovi rezultati u koraku ispitivanja HOG dvostupanjskog modela na razini ćelije  $8 \times 8$  piksela, prag za izgradnju graf odnosa preciznosti i odziva je  $k$  - prag za detekciju unutar ćelije, a kriterij odabira najboljih AP - average precision, prosječna preciznost na ispitnom skupu

| RB model | $\alpha$ | $\alpha_d$ | $N$  | AP1            | AP2 dan       | AP2 noć       |
|----------|----------|------------|------|----------------|---------------|---------------|
| 1        | 0,0001   | 0,9        | 4000 | <b>99,798%</b> | 84,90%        | 90,06%        |
| 2        | 0,0001   | 0,9        | 3000 | <b>99,792%</b> | 85,80%        | 90,97%        |
| 3        | 0,0001   | 0,7        | 4000 | 99,798%        | 84,39%        | <b>91,84%</b> |
| 4        | 0,0001   | 0,7        | 3000 | 99,796%        | 85,16%        | 90,04%        |
| 5        | 0,0001   | 0,7        | 2000 | <b>99,802%</b> | <b>86,59%</b> | 90,04%        |
| 6        | 0,00001  | 0,9        | 2000 | 99,706%        | 85,14%        | 87,48%        |
| 7        | 0,00001  | 0,7        | 2000 | 99,68%         | 85,92%        | 87,45%        |

**Tablica 11.** Prikaz dobrih operativnih točaka modela gledajući rezultate na skupu za ispitivanje, prva video sekvenca, redni broj modela kao u Tablici 10.

| RB | $\alpha$ | $\alpha_d$ | $N$  | $k$  | TP  | TN  | FP | FN | preciznost | odziv  |
|----|----------|------------|------|------|-----|-----|----|----|------------|--------|
| 1  | 0,0001   | 0,9        | 4000 | 0,35 | 938 | 592 | 31 | 0  | 96,8%      | 100%   |
| 2  | 0,0001   | 0,9        | 3000 | 0,3  | 936 | 606 | 17 | 2  | 98,21%     | 99,79% |
| 3  | 0,0001   | 0,7        | 4000 | 0,3  | 938 | 591 | 32 | 0  | 96,7%      | 100%   |
| 4  | 0,0001   | 0,7        | 3000 | 0,3  | 937 | 602 | 21 | 1  | 97,81%     | 99,89% |
| 5  | 0,0001   | 0,7        | 2000 | 0,3  | 935 | 616 | 7  | 3  | 99,15%     | 99,68% |
| 6  | 0,00001  | 0,9        | 2000 | 0,4  | 938 | 604 | 19 | 0  | 98,01%     | 100%   |
| 7  | 0,00001  | 0,7        | 2000 | 0,4  | 938 | 603 | 20 | 0  | 97,91%     | 100%   |

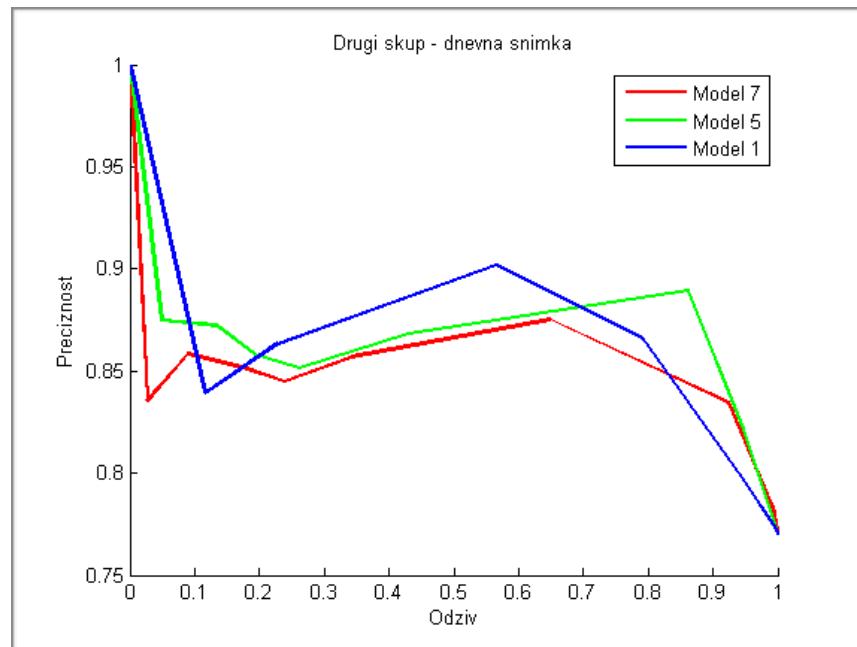
Detekcijski modeli s dvostupanjskom inačicom HOG modela pozadine dajeu neznatno bolje rezultate od detekcijskih modela s jednostupanjskim modelom pozadine s optimiranim parametrima. Zaključak je da dvostupanjski modeli ne donose drastično poboljšanje na prvom skupu podataka, a unose dodatnu složenost. Validacijom je pokazano da bi stopa učenja α bi trebala biti postavljena na vrijednosti između 0.00001 i 0.0001, stopa učenja α bi morala biti iznad 0.7, a period osvježavanja drugog stupnja N najbolje je postaviti na broj između 2000 i 4000.



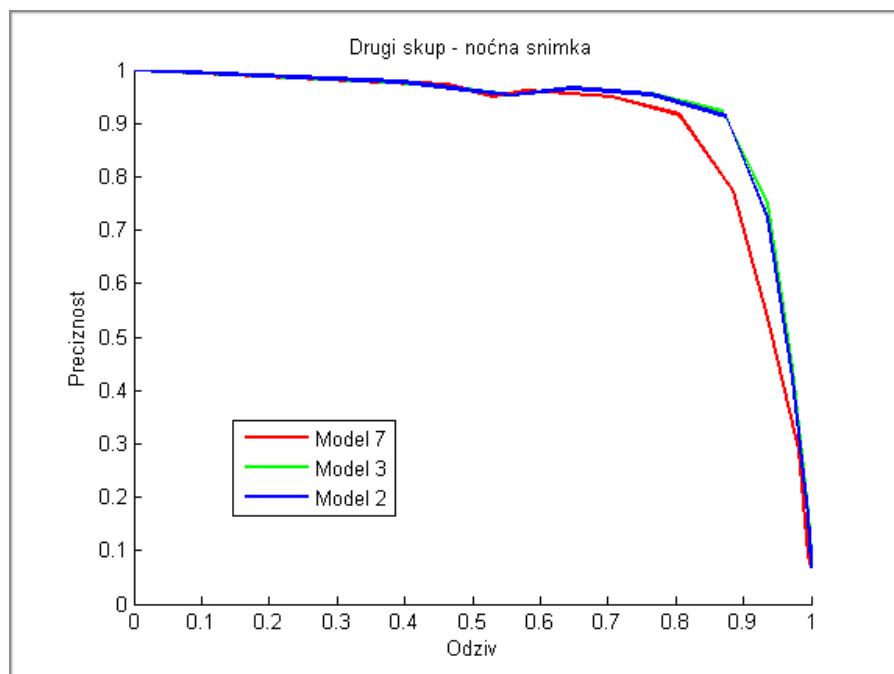
**Graf 17.** Uvećani gornji desnji ugao odnosa preciznosti i odziva za modele 7, 2 i 1 iz Tablice 10. te prikaz njihovih operativnih točki

Kada promotrimo rezultate na drugom skupu podataka vidimo veoma veliko poboljšanje u odnosu na jednostupanjski HOG model. Naime, odgođeni i raspršeni drugi stupanj dvostupanjskog modela daje mnogo bolje rezultate detekcije u noćnoj snimci što je vidljivo iz grafa. Poboljšani rezultati proizlaze iz činjenice da

se zbog raspršenosti i odgode u obzir uzima manje kratkotrajnih i nedavnih promjena osvjetljenja te je ovaj model u konačnici mnogo uspješniji od jednostupanjskog modela na noćnim snimkama.



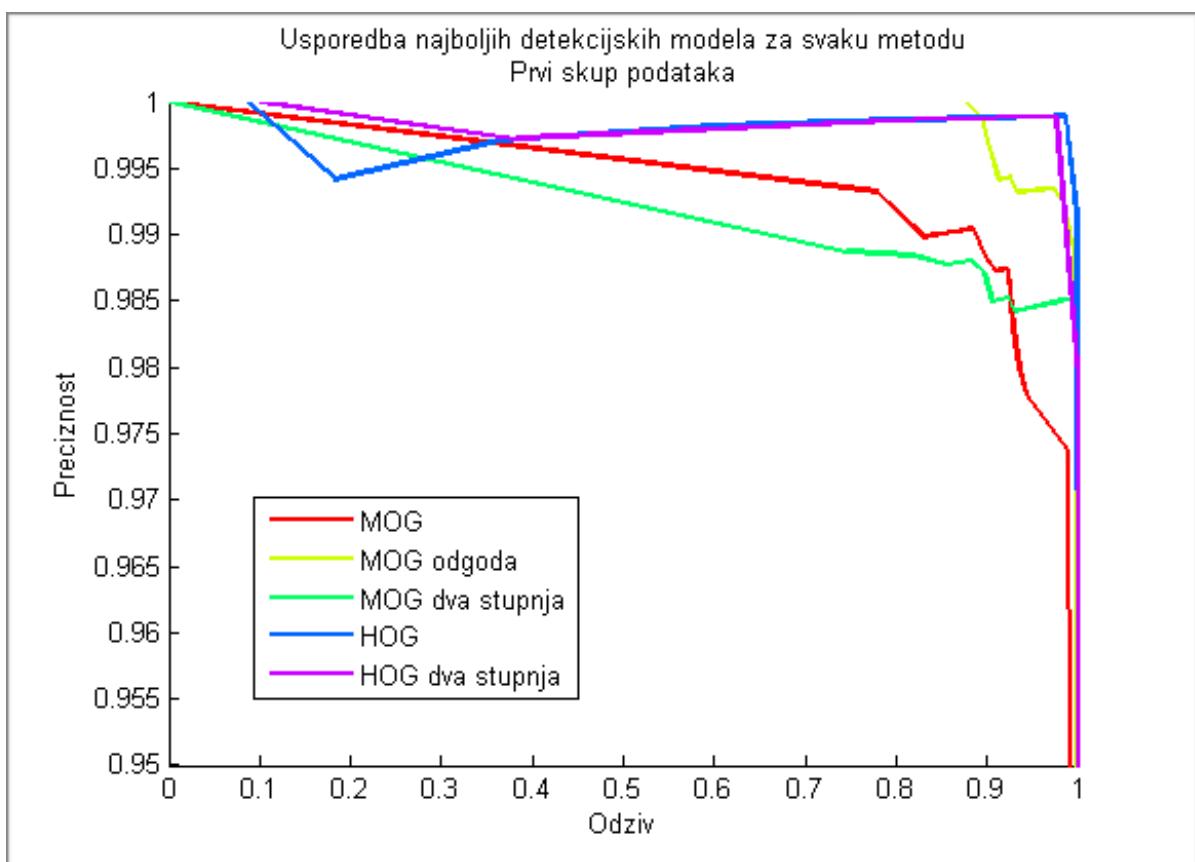
**Graf 18.** Odnos preciznosti i odziva modela prikazanih u Tablici 10., dvostupanjski modeli temeljeni histogramu orijentacije gradijenta, drugi skup podataka - dnevna snimka



**Graf 19.** Odnos preciznosti i odziva modela prikazaniх u Tablici 10., dvostupanjski modeli temeljeni histogramu orijentacije gradijenta, drugi skup podataka - ноћна снимка

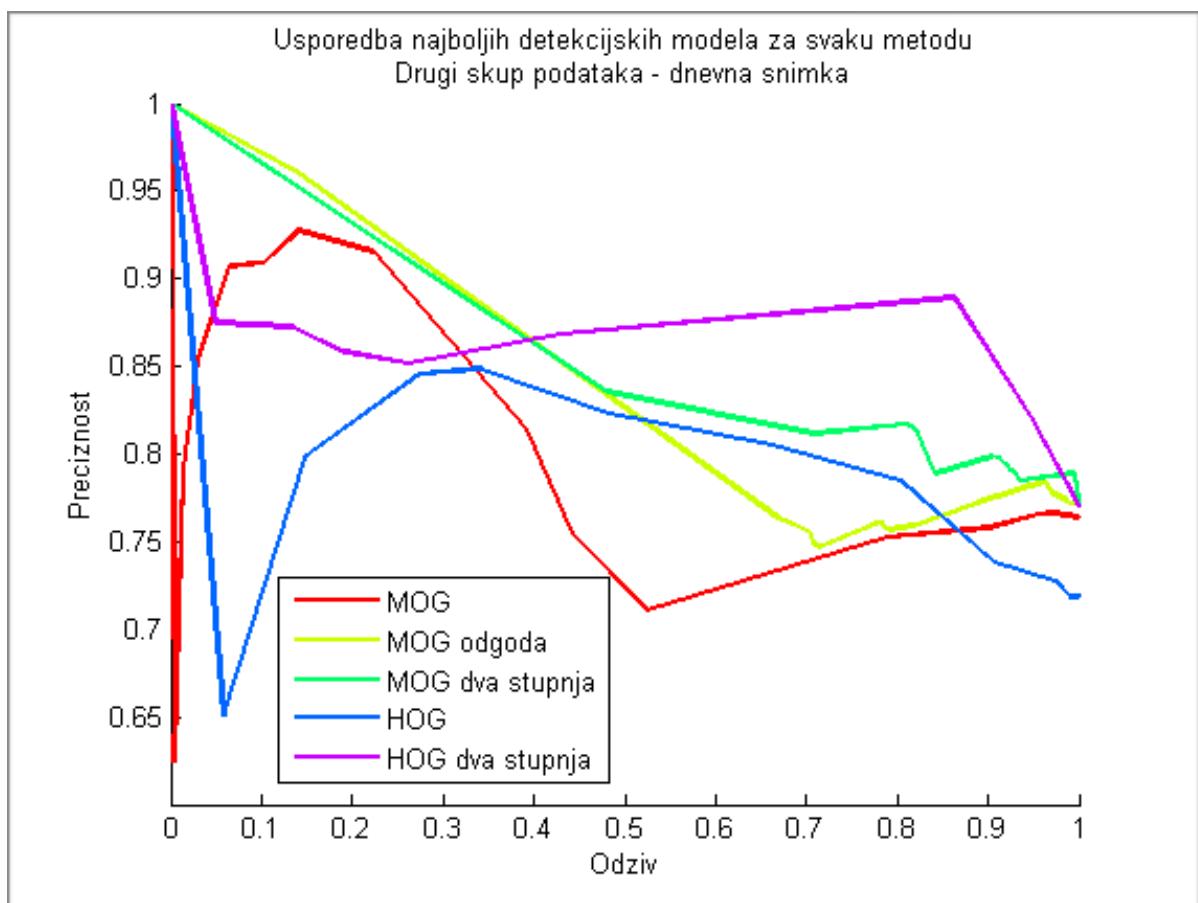
### 5.3.2. Usporedba najboljih detekcijskih modela nakon izvršenih validacijskih eksperimenata

Za početak promotrimo rezultate na prvom skupu podataka. Najboljim su se pokazali detekcijski modeli koji svoj model pozadine grade na temelju histograma orijentacije gradijenta. Ispitivanjem na ispitnom skupu je odabran najbolji jednostupanjski HOG model te on daje najbolju operativnu točku, a najbolji dvostupanjski HOG model ima najveću prosječnu preciznost. Kada gledamo detekcijske modele temeljene na izgradnju pozadine mješavinom Gaussova razdioba dolazimo do zaključka da su odgođeni jednostupanjski i dvostupanjski modeli pozadine manje uspješni u svrhu detekcije te daju manju prosječnu preciznost. Usporedba je prikazana grafom 20.



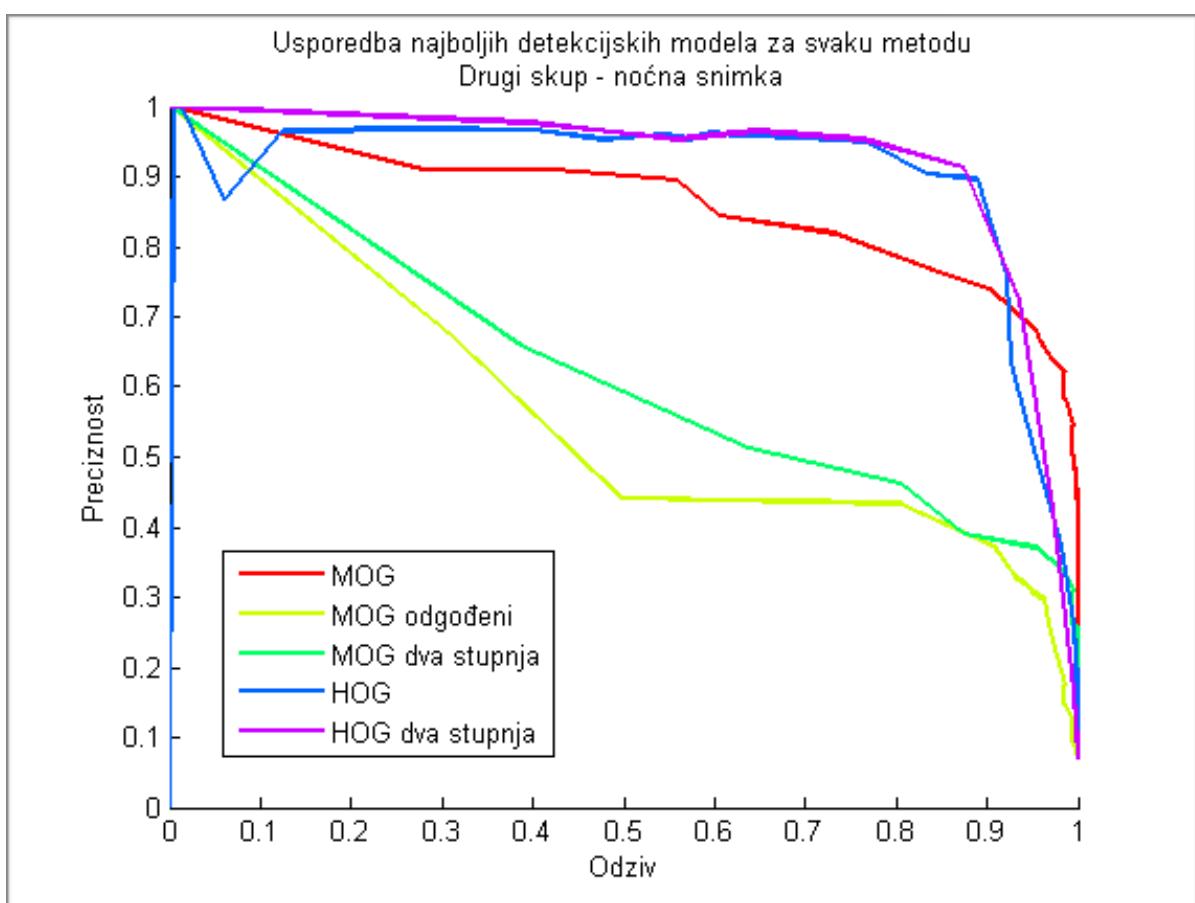
**Graf 20.** Usporedba najboljih detekcijskih modela po metodama na prvom skupu podataka

Drugi skup podataka podijeljen je u dnevnu i noćnu snimku. Na dnevnoj snimci izvršeni su validacijski eksperimenti i dobiveni su rezultati koji su nešto lošiji, uglavnom zbog toga što je prikazana situacija veoma otežana u usporedbi sa snimkom iz prvog skupa podataka kroz treskanje kamere, zalazak sunca, padanje sjene tramvaja iz trake pokraj virtualne petlje koju promatramo te refleksije svjetala automobila na samoj cesti. Ovaj puta najbolju prosječnu preciznost ostvaruju dvostupanjski modeli. Najbolju prosječnu preciznost i najbolju operativnu točku ima validacijom i ispitivanjem odabrani detekcijski model temeljen na dvostupanjskom HOG modelu pozadine. Također se vidi da su dvostupanjski MOG modeli polučili bolje rezultate od jednostupanjskih na ovoj snimci. Usporedba je prikazana grafom 21.



**Graf 21.** Usporedba najboljih detekcijskih modela po metodama na drugom skupu podataka, dnevna snimka

Konačno, rezultati na noćnoj snimci iz drugog skupa podataka su očekivano najlošiji budući da snimka unosi dodatne probleme za detekciju u odnosu na snimku iz prvog skupa i dnevnu snimku iz drugog skupa. Učestale i nagle promjene osvjetljenja uzrokovane svjetlima tramvaja i vozila iz susjednih traka, refleksija svjetla na pozadini koja dolazi od vozila iz promatrane trake te se proteže nekoliko metara ispred vozila te dodatno treskanje kamere uzrokovano vjetrom čine noćnu snimku drugog skupa najtežom od svih odabranih za ispitivanje. Posebno zanimljivi su jako dobri rezultati jednostupanjskog HOG modela na ovoj snimci te poboljšanje koje je ostvareno s dvostupanjskim HOG modelom. Usporedba je prikazana grafom 22.

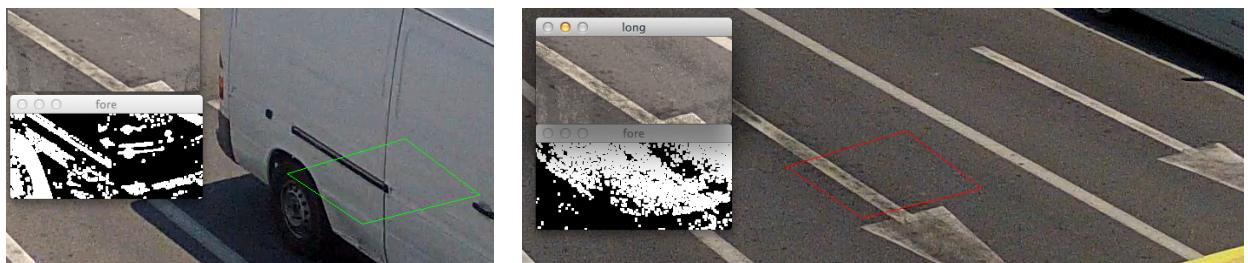


**Graf 22.** Usporedba najboljih detekcijskih modela po metodama na drugom skupu podataka, noćna snimka

### 5.3.3. Neki primjeri uspješnih i neuspješnih detekcija

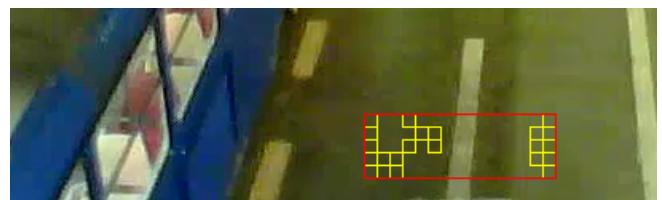


**Slika 9.** Uspješna detekcija, detekcijski model s dvostupanjskim MOG postupkom, back prozorčić prikazuje trenutno stanje prvog stupnja, long prikazuje drugi stupanj modela pozadine, a fore detektirane piksele prednjeg plana



**Slika 9. (lijevo):** lažno negativna detekciju zbog velike sličnosti vozila i pozadine, prag zauzetosti petlje je  $>40\%$

**Slika 10. (desno):** lažno pozitivna reakcija zbog adaptiranja kamere globalnom osvjetljenju scene



**Slika 11. (lijevo):** ispravna detekcija, HOG model pozadine, drugi skup noćna snimka

**Slika 12. (desno):** lažno pozitivna reakcija zbog treskanja kamere, HOG model pozadine, drugi skup, noćna snimka

## 6. Programska implementacija

Programsko ostvarenje sustava napisali smo u jeziku C++. Koristili smo OpenCV biblioteku, ponajviše zbog već implementirane klase za modeliranja pozadine mješavinom Gaussova razdioba - `BackgroundSubtractorMOG2`. Popis parametara i primjer korištenja metode možete vidjeti na [27]. Implementacija te metode temeljena je na radu [2]. Također u postupcima izdvajanja teksturne slike koristimo biblioteku za uklanjanje šuma iz slike dostupnu na stranicama [28].

Program je podijeljen u sljedeće module: `Algorithms`, `Denoising`, `Helpers`, glavni izvršni modul te u klase `Controls`, `BackgroundModel` te `BackgroundHOG`, `BackgroundMOG` i `BackgroundHOH` koje nasljeđuju `BackgroundModel`.

`Controls` je klasa koja se bavi detekcijom i iscrtavanjem virtualnih petlji na ekran te pohranom podataka o detekciji u datoteku ako je potrebno.

`Algorithms` sadrži implementaciju pet ispitanih postupaka detekcije izgradnjom jednostupanjskih i dvostupanjskih MOG i HOG modela pozadine.

`Denoising` sadrži funkciju koja koristi biblioteku [28], odvaja teksturnu sliku te je vraća na daljnju obradu.

`BackgroundModel` abstraktna klasa koju nasljeđuju klase modela pozadine.

`BackgroundMOG` klasa koja je omotač oko OpenCV klase `BackgroundSubtractorMOG2`.

`BackgroundHOG` klasa koja je implementira HOG model pozadine.

`BackgroundHOH` klasa koja je implementira HOH (histogram nijanse) model pozadine.

`Helpers` sadrži pomoćne funkcije za računanje vremena obrade jedne slike te parsiranja datoteka s parametrima.

Izvorni kod je priložen uz rad. Pripremljene su sve datoteke potrebne za demonstraciju ispitivanih metoda. Opis pripreme parametara nalazi se u README.txt datoteci priloženoj uz izvorni kod.

Za prevođenje programa potrebno je imati instaliran OpenCV. Program prevodimo iz konzole UNIX operacijskih sustava naredbom:

---

```
gcc main.cpp Algorithms.cpp Helpers.cpp BackgroundModel.cpp  
BackgroundHOG.cpp BackgroundMOG.cpp BackgroundHOH.cpp  
Denoising.cpp Controls.cpp -o video-detector-demo `pkg-config  
--cflags opencv` `pkg-config --libs opencv`
```

---

Postupak prevođenja i pokretanja programa na ugrađenom računalu s ARM procesorom zahtijeva da na početku na ugrađeno računalo postavimo neki UNIX operacijski sustav te prevedemo OpenCV biblioteku za ARM koristeći upute na stranici [29]. Na nama dostupno IGEPv2 računalo program smo prebacivali SD memorijskom karticom, a prethodno bismo ga preveli na posebno pripremljenom virtualnom stroju koji je dostupan na stranicama proizvođača. Program se može prevesti i na samom uređaju ukoliko je već pripremljen OpenCV te su dostupne sve biblioteke koje on zahtijeva.

## 7. Zaključak

U ovom radu predstavili smo sustav detekcije prisutnosti vozila u slikama urbanih raskrižja ugrađenim računalom. Detekcijski sustav temelji se na modelu pozadine. Proučena je i predstavljena literatura koja se bavi modeliranjem pozadine te detekcijom vozila u prometnim scenama. Opširno je opisan niz metoda izgradnje modela pozadine poput modeliranja pozadine mješavinom Gaussovih razdioba, histogramima orientacije gradijenta i histogramom nijanse. Poseban naglasak stavljen je na ostvarivanje prilagodljivosti modela raznim postupcima za ostvarivanje tolerancije na spore i brze promjene u osvjetljenju, te načinima smanjenja vremenske i prostorne složenosti u svrhu omogućavanja obrade i rada sustava na ugrađenom računalu s ARM procesorom. Opisane postupke ostvarenja detekcijskog modela temeljenog na izgradnji modela pozadine smo implementirali te isprobali na dva skupa video snimki različite kvalitete, trajanja te uvjeta u kojima se odvija prometna situacija. Prepoznali smo, pobrojali i pojasnili hiperparametre u postupku ostvarenja detekcijskog modela za pet različitih metoda izgradnje modela pozadine. Izvršili smo validaciju spomenutih hiperparametara na posebno pripremljenim ručno označenim skupovima slika koje smo izdvjajili iz spomenutih skupova video snimki. Detekcijske modele koji su se pokazali najboljima u postupku validacije ispitali smo na nezavisnim ispitnim skupovima te smo rezultate prikazali nizom grafova odnosa preciznosti i odziva. Na temelju grafova odnosa preciznosti i odziva detekcijskih modela koji su ostvarili najbolje rezultate na ispitnim skupovima izvršili smo usporedbu spomenutih pet načina ostvarenja detekcijskog modela. Konačno, prikazali smo ukratko programsku implementaciju i opisali postupak prevođenja programa za ARM procesor.

Eksperimenti provedeni na skupu kvalitetnijih video snimki ostvarili su veoma dobre rezultate u procesu detekcije automobila u raznim situacijama, dok oni na skupu video snimki slabije kvalitete ukazuju na mnogo problema s kojima bismo se trebali suočiti u budućem radu. Neki od problema koje smo identificirali

su netolerancija detekcijskog modela na pomicanje pozadine uzrokovano treskanjem kamere, lažno pozitivne detekcije uzrokovane reflektiranim svjetlima vozila te bacanje sjene vozila iz susjednih traka. Budući rad mogao bi se odvijati u dva različita paralelna kolosijeka. Prvi bi bio rad na unaprjeđenju metoda izgradnje modela pozadine te poboljšavanju tolerancije modela i otpornosti na spomenute uočene probleme. Korisno bi bilo implementirati i isprobati neke druge metode izgradnje modela pozadine poput modela koji se temelji na histogramu boje ili modela koji kombinira značajke histograma orijentacije gradijenta i histograma nijanse. Također bi zanimljivo bilo pokušati ostvariti model pozadine koji se ne temelji samo na statističkom modeliranju elemenata pozadine već je obogaćen nekim dobrim karakteristikama drukčijih uspješnih modela poput onoga predstavljenog u radu [7]. Potrebno bi bilo izvesti testove na mnogo dužim snimkama te vidjeti kako se ostvareni detekcijski sustav ponaša kroz kontinuirani dugi vremenski period od recimo jednog cijelog dana. Drugi kolosijek budućeg rada bio bi usmjeren na razvoj konkretnog sustava te provođenje eksperimenata koristeći stvarnu kombinaciju kamere i ugrađenog računala koja bi se trebala nalaziti u konačnom ostvarenju detekcijskog sustava.

## 8. Literatura

- [1] C. Stauffer, W.E.L Grimson: *Adaptive background mixture models for real-time tracking*, IEEE Computer Society Conference on Computer Vision and Pattern Recognition 2. pp. 246–252, 1998.
- [2] Z. Živković: *Improved Adaptive Gaussian Mixture Model for Background Subtraction*, Pattern Recognition, 2004., ICPR Proceedings of the 17th International Conference 2004.
- [3] C. R. Wren: *Pfinder: Real-Time tracking of the Human Body*, IEEE Transactions on Pattern Analysis and Machine Intelligence 19 (7): 780–785, 1996.
- [4] S. S. Cheung, C. Kamath: *Robust techniques for background subtraction in urban traffic video*, 2004.
- [5] S. S. Cheung, C. Kamath: *Robust Background Subtraction With Foreground Validation For Urban Traffic Video*, 2005.
- [6] S. Brutzer, B. Hoferlin, G. Heidemann: *Evaluation of Background Subtraction Techniques for Video Surveillance*, 2011.
- [7] O. Barnich, M. Van Droogenbroeck: *ViBe: a disruptive method for background subtraction*, 2013.
- [8] S.H. Kim, J. Shi, A. Alfarrarjeh, D. Xu, Y. Tan, C. Shahabi: *Real-Time Traffic Video Analysis Using Intel Viewmont Coprocessor*, 2013.
- [9] N. Greggio, A. Bernardino, C. Laschi, P. Dario, J. Santos-Victor: *Self-Adaptive Gaussian Mixture Models for Real-Time Video Segmentation and Background Subtraction*, 2010.
- [10] S. Liao, G. Zhao, V. Kellokumpu, M. Pietikainen, S.Z. Li: *Modeling Pixel Process with Scale Invariant Local Patterns for Background Subtraction in Complex Scenes*, 2010.
- [11] Z. Shao-Ping, F. Xiao-Ping: *Nighttime Motion Vehicle Detection Based on MILBoost*, Sensors & Transductors, svezak 171, izdanje 5, svibanj 2014.
- [12] S. Zhou, J. Li, Z. Shen L. Ying: *A Night Time Application for a Real-Time Vehicle Detection Algorithm Based on Computer Vision*, Research Journal of Applied Sciences, Engineering and technology 5, 2013.

- [13] J. Batista, P. Peixoto, C. Fernandes, M. Ribeiro: *A Dual-Stage Robust Vehicle Detection and Tracking for Real-time Traffic Monitoring*, 2006.
- [14] M. Harville: *Adaptive Video Background Modeling using Color and Depth*, International Conference on Image Processing, 2001.
- [15] N. Dalal, B. Triggs: *Histograms of Oriented Gradients for Human Detection*, International conference on Computer Vision and Pattern Recognition CVPR 2005.
- [16] N. Buch, J. Orwell, S.A. Velastin: *3D Extended Histogram of Oriented Gradients (3DHOG) for Classification of Road Users in Urban Scenes*, 2009.
- [17] J. Duran, B. Coll, C. Sbert: *Chambolle's Projection Algorithm for Total Variation Denoising*, Image Processing Online, 17.12.2013.

Izvori s interneta:

- [18] Wikipedija, Optimizacija hiperparametara, pristupljeno stranici u ožujku 2014.:  
[http://en.wikipedia.org/wiki/Hyperparameter\\_optimization#Grid\\_search](http://en.wikipedia.org/wiki/Hyperparameter_optimization#Grid_search)
- [19] Wikipedija, Preciznost i odziv, pristupljeno stranici u travnju 2014.:  
[http://en.wikipedia.org/wiki/Precision\\_and\\_recall](http://en.wikipedia.org/wiki/Precision_and_recall)
- [20] Wikipedija, Prosječna preciznost, pristupljeno stranici u lipnju 2014.:  
[http://en.wikipedia.org/wiki/Information\\_retrieval#Average\\_precision](http://en.wikipedia.org/wiki/Information_retrieval#Average_precision)
- [21] Wikipedija, Induktivna petlja, pristupljeno stranici u travnju 2014.:  
[http://en.wikipedia.org/wiki/Induction\\_loop](http://en.wikipedia.org/wiki/Induction_loop)
- [22] Wikipedija, Lokalni binarni uzorak, pristupljeno stranici u lipnju 2014.:  
[http://en.wikipedia.org/wiki/Local\\_binary\\_patterns](http://en.wikipedia.org/wiki/Local_binary_patterns)
- [23] OpenCV, biblioteka otvoreno dostupnog koda za računalni vid:  
<http://opencv.org/>

[24] Wikipedija, Pomični projek, pristupljeno stranici u lipnju 2014.:  
[http://en.wikipedia.org/wiki/Moving\\_average](http://en.wikipedia.org/wiki/Moving_average)

[25] Wikipedija, Mješavina Gaussovih razdioba, pristupljeno stranici u lipnju 2014.:  
[http://en.wikipedia.org/wiki/Gaussian\\_mixture\\_model#Gaussian\\_mixture\\_model](http://en.wikipedia.org/wiki/Gaussian_mixture_model#Gaussian_mixture_model)

[26] IGEPv2 računalo s ARM procesorom, službene stranice proizvođača,  
pristupljeno stranici u lipnju 2014.:

<https://www.isee.biz/products/igep-processor-boards/igepv2-dm3730>

[27] OpenCV, modeliranje pozadine MoG postupkom:

[http://docs.opencv.org/modules/video/doc/motion\\_analysis\\_and\\_object\\_tracking.html?  
highlight=backgroundsubtractormog2](http://docs.opencv.org/modules/video/doc/motion_analysis_and_object_tracking.html?highlight=backgroundsubtractormog2)

[28] Image processing online, *Chambolle's Projection Algorithm for Total Variation Denoising*, izvorni kod:

<http://www.ipol.im/pub/art/2013/61/>

[29] OpenCV, prevođenje za ARM:

[http://docs.opencv.org/doc/tutorials/introduction/crosscompilation/arm\\_crosscompile\\_with\\_cmake.html](http://docs.opencv.org/doc/tutorials/introduction/crosscompilation/arm_crosscompile_with_cmake.html)

# Detekcija prisutnosti vozila ugrađenim računalom

## Sažetak

Detekcija prisutnosti vozila na snimkama s kamere postavljene na urbanim raskrižjima u svrhu automatizacije upravljanja prometom u raskrižju predstavlja zanimljivu alternativu ugrađivanju induktivnih petlji.

U sklopu rada ostvaren je i prikazan sustav za detekciju vozila u slikama raskrižja koristeći model pozadine. U radu je dan osvrt na srodnu literaturu. Predstavljeni su jednostupanjski i dvostupanjski modeli pozadine te metode izgradnje modela pozadine temljene na histogramu orientacije gradijenta, mješavini Gaussovih razdioba i histogramu nijanse. Posebna pažnja posvećena je pristupima za ostvarivanje prilagodljivosti modela, ostvarivanju tolerancije na različite uvjete osvjetljenja te povećanju brzine obrade na ugrađenom računalu. Izvršen je niz validacijskih eksperimenata u svrhu optimiziranja hiperparametara opisanih metoda izgradnje modela pozadine. Ostvareni učinak različitih varijanti modeliranja pozadine te postupka detekcije vrednovan je na ispitnom skupu. Rezultati su predstavljeni nizom tablica i grafova te opširno komentirani.

**Ključne riječi:** detekcija vozila, virtualne petlje, model pozadine, MOG, HOG, ugrađeno računalo, ARM

# Detecting the vehicle presence by an embedded computer

## Abstract

Detecting the vehicle presence in videos obtained by camera placed to record the urban crossroad with the goal of statistical data extraction and automatic traffic control makes an interesting alternative to existing detection systems that use induction loops.

This work explores the vehicle detection system implementation based on the background model. Related work concerning background modelling is discussed. Single stage and two stage background models are described along with background modelling methods based on histograms of oriented gradients, mixture of Gaussians and hue histogram. Special attention was given to approaches for realising adaptability of the model, achieving tolerance to different lighting conditions and increasing the detection process speed on the embedded computer. A set of validation experiments was conducted in order to optimise hyperparameters of described background modelling methods. The actual performance of detection system based on different background models was evaluated on the test set. Results are presented in a series of tables and graphs and discussed in detail.

**Key words:** vehicle detection, virtual loop, background model, MOG, HOG, embedded computer, ARM