

# **SafeTRAM<sup>1</sup> - Sustav za upozorenje na opasnost frontalnog sudara za urbana tračnička vozila**

Ivan Marković<sup>2</sup>, Igor Cvišić<sup>2</sup>, Juraj Peršić<sup>2</sup>, Marin Oršić<sup>2</sup>, Siniša Šegvić<sup>2</sup>,  
Ivan Petrović<sup>2,3</sup>, Josip Babić<sup>4</sup>, Andrija Eršek<sup>4</sup>, Tomislav Gavran<sup>4</sup>,  
Zlatka Tečec Ribarić<sup>4</sup>

<sup>2</sup> Sveučilište u Zagrebu Fakultet elektrotehnike i računarstva

<sup>3</sup> redoviti član HATZ-a u Odjelu sustava i kibernetike

<sup>4</sup> Končar – Institut za elektrotehniku d.d.

**Sažetak:** Povećanjem broja, ali i raznolikošću sudionika, svakodnevni promet postaje sve složeniji. Iz toga se razloga u moderna vozila ugrađuju sustavi za pomoći vozaču radi povećanja sigurnosti i/ili komfora voženje. Tračnička vozila predstavljaju zanimljivu primjenu za takve sustave, jer u mnogim gradovima sudjeluju izravno u prometu, a posljedice uzrokovane njihovim sudjelovanjem u sudaru mogu biti vrlo ozbiljne, čak i za same putnike koji često stoje tijekom vožnje. Iz toga bi razloga tračnička vozila imala veliku korist od primjene sustava za pomoći vozaču. Međutim, za razliku od cestovnih vozila, tračnička vozila ne mogu zaobilaziti prepreke jer je njihova putanja zadana tračnicama. U ovome članku predstavljamo istraživanje provedeno u sklopu projekta SafeTRAM kojemu je cilj bio razvoj sustava koji upozorava vozača o mogućem frontalnom sudaru korištenjem fuzije informacija iz heterogenih senzora postavljenih na električni tramvaj. U radu su korišteni sljedeći senzori: stereo kamera, inercijska mjerna jedinica, GPS te automobilski radar. Pomoću navedenih senzora moguće je graditi kartu tračničkih trasa tramvaja te estimacijom brzine tramvaja predvidjeti njegovu trajektoriju izravno na tračnicama. Također, korištenjem kamere moguće je raditi semantičku segmentaciju scene, a radarskim senzorom pratiti gibajuće objekte. Kako bi se provelo testiranje svih vrsta pristupa, snimljen je skup podataka u Zagrebu kroz nekoliko vožnji električnim tramvajem ZET-a u suradnji s Končar Električnim vozilima d.d.

**Ključne riječi:** sustavi pomoći vozaču, sustav za upozorenje na opasnost sudara, vizualna odometrija, semantička segmentacija, električni tramvaj

---

<sup>1</sup> Projekt SafeTram - Sustav za povećanje sigurnosti vožnje javnog urbanog tračničkog prometa financiran je sredstvima Europskog fonda za regionalni razvoj, MIS kod projekta: KK.01.2.1.01.0022. Projekt su realizirali Končar – Institut za elektrotehniku d.d. (nositelj projekta) i Fakultet elektrotehnike i računarstva Sveučilišta u Zagrebu.

## 1. Uvod

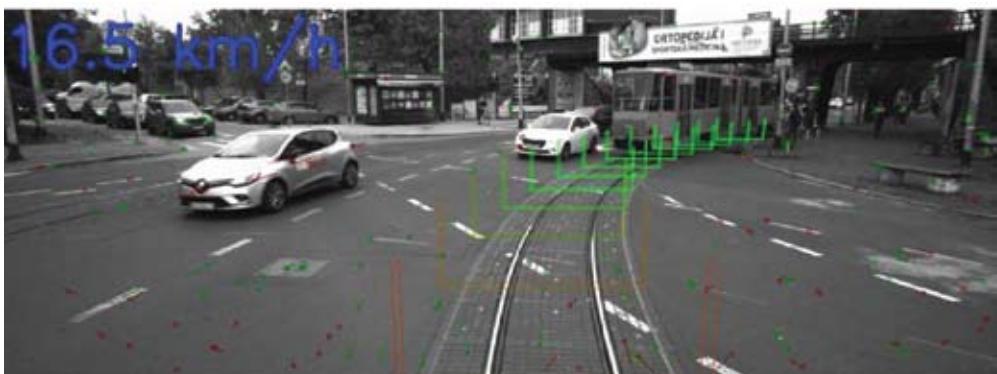
Zadatak je sustava SafeTRAM, koji se opisuje u ovome radu, predviđanje potencijalnih frontalnih sudara s objektima na tračnicama kako bi se moglo pravovremeno izdati upozorenje vozaču tramvaja. Za tu svrhu sustav treba biti opremljen percepcijskim senzorima čije će podatke kontinuirano obrađivati i analizirati te na temelju toga procjenjivati potencijalnu opasnost sudara. Osim percepcijskih senzora, sustav bi trebao biti opremljen i senzorima poput inercijske mjerne jedinice (IMU) i GPS-a kako bi se što točnije mogla predvidjeti trajektorija tramvaja. Od percepcijskih senzora najzastupljeniji su u ovakvim primjenama kamere, radari i laserski senzori udaljenosti. Za upozoravanje na opasnost frontalnog sudara ipak se najčešće koriste kamere i radari, dok su laserski senzori češći kod sustava s višom razinom autonomije. Kamere se mogu koristiti i u stereo postavu koji pruža mogućnost procjene vlastitoga gibanja te dubine iz stereo slike. Stereo postav kamera u fuziji s radarskim senzorom daje bogatu mogućnost analize stanja okoline u smjeru gibanja tramvaja.

Tramvaj, kao gradsko vozilo, specifičan je po tome što ima ograničeno kretanje; međutim, za razliku od automobila, masa i tromost znatno su mu veći, a treba imati na umu i činjenicu da putnici u tramvaju mogu stajati tijekom vožnje. Iz toga se razloga sustav upozorenja na opasnost frontalnog sudara u projektu SafeTRAM razmatrao kao sustav upozorenja vozaču koji bi temeljem svoga iskustva i procjene stanja u prometu trebao odlučivati o načinu zaustavljanja tramvaja. Također, takav sustav bi trebao uzeti u obzir i odnos prema samome vozaču; primjerice prečesta upozorenja mogu dovesti do toga da se vozač prestane obazirati na sustav [1]. Nadalje, tramvaj u gradskim središtima uglavnom nije izoliran od drugog prometa te se na tračnicama mogu očekivati razni sudionici, od automobila, drugih tramvaja, kamiona, pa sve do pješaka i biciklista. To svakako postavlja mnoge izazove na sustav upozorenja na opasnost frontalnog sudara.

Konkretno, u sklopu projekta SafeTRAM korišteni su sljedeći senzori: IMU, GPS senzor, stereo monokromatska kamera, automobilski radar i kamera u boji. IMU mjeri ubrzanja i kutne brzine tramvaja za potrebe procjene vlastitog gibanja tramvaja, a GPS omogućuje poznavanje globalne lokacije tramvaja. Međutim, mjerenja GPS-a nisu dovoljno precizna da bi se predikcija trajektorije tramvaja mogla pouzdano odrediti. Stoga smo u sklopu projekta odlučili izvesti fuziju mjerenja IMU-a i GPS-a sa slikama iz stereo monokromatskih kamera. Tom kombinacijom dobiva se dubinska slika iz koje je moguće izračunavati tzv. vizualno-inercijsku odometriju. Drugim riječima, iz stereo slike i IMU-a moguće je procijeniti relativni pomak tramvaja te izračunati brzine pomoću kojih se može odrediti projekcija trajektorije gibanja tramvaja točnije nego samo GPS-om. Kombinacijom vizulano inercijske odometrije i GPS-a dobivamo preciznije globalnu lokaciju tramvaja i procjenu linearnih i kutnih brzina.

Predikcija trajektorije vozila obično se provodi pod pretpostavkom da će se vozilo nastaviti gibati trenutačnom brzinom; međutim, tramvaj ima ograničenje gibanja po

tračnicama te ne može, kao automobil, izvesti bilo koji putanju. Ta činjenica, uz poznatu globalnu lokalizaciju tramvaja, omogućuje izgradnju karte tramvajskih trasa te projiciranje trajektorije tramvaja izravno na tračnice. Tako dobivena predikcija trajektorije tramvaja omogućuje smanjenje broja lažnih upozorenja vozaču koja bi se, primjerice, pojavila pod pretpostavkom pravocrtnog gibanja tramvaja unatoč poznavanju da tračnice skreću. Ilustracija ovakvog slučaja prikazana je na Slici 1 iz koje možemo vidjeti da bi algoritam bez poznavanja trase gibanja tramvaja i projiciranja trajektorija na nju mogao zaključiti da postoji opasnost od sudara s vozilom koje dolazi iz suprotnoga smjera.



Slika 1: Predviđanje trajektorije tramvaja na tračnice

Osim vlastitoga gibanja, sustav za upozorenje na opasnost frontalnog sudara treba mjeriti i stanje prepreka u svojoj okolini. Za tu su svrhu predviđeni vizualni senzori (stereo kamera i kamera u boji) te automobilski radar. Zadatak je radara detekcija i estimacija brzina objekata u njegovu vidnom polju. Radar dobro detektira prepreke kao što su automobili, kamioni, tramvaji i ostala slična vozila s jakim metalnim tragom, a slabije detektiraju pješake, bicikliste i motocikliste. Stoga je njegova glavna svrha detekcija i estimacija brzina vozila u smjeru vožnje i neposredno ispred tramvaja. Iz mjerene brzine vozila mogu se predvidjeti njihove trajektorije koje se kasnije uspoređuju s predviđenom trajektorijom samoga tramvaja. Podaci s kamere u boji koriste se za semantičku segmentaciju scene, tj. za klasifikaciju i detekciju objekata od interesa, kao što su pješaci, automobili i biciklisti, primjenom metoda dubokog učenja. Detektirani se objekti mogu se pratiti kroz vrijeme, to jest može se estimirati njihova brzina te predviđati njihove buduće trajektorije i uspoređivati s trajektorijom tramvaja.

Za potrebe razvoja sustava za upozorenje na opasnost frontalnog sudara bilo je potrebno postaviti sve senzore na električni tramvaj, umjeriti ih te snimiti eksperimentalne scene u relevantnom okruženju. U nastavku članka opisujemo eksperimentalni postav i akviziciju podataka, umjeravanje kamera i radarskog senzora, stereo vizualnu

odometriju za estimaciju trajektorije tramvaja i izgradnju karte, semantičku segmentaciju za tumačenje scene te algoritam za detekciju frontalnog sudara.

## 2. Akvizicija skupa podataka električnim tramvajem

Akvizicija skupova podataka za evaluaciju razvijenih algoritama provedena je u dnevnim i noćnim uvjetima vožnje tramvaja u Zagrebu. Na tramvaj su bili postavljeni sljedeći senzori: tri kamere (dvije monokromatske za stereo vizualnu odometriju i jedna kamera u boji za semantičku segmentaciju), 3 radara (u eksperimentima je korišten samo srednji automobilski dalekometni radar), IMU i GPS. Montaža senzora prikazana je na Slici 2. Kako se može vidjeti na slici, kamere i IMU s GPS-om postavljeni su na vrh vjetrobranskog stakla s unutarnje strane, kako ne bi bili izloženi vanjskim vremenskim uvjetima. To je postavilo novi izazov na sliku iz kamera zbog refleksije od vjetrobranskog stakla. Prvo je postavljeno sjenilo ispod kamera, ali je pri orientaciji prema suncu odblijesak od aluminijskih nosača dominirao slikom. Kako bi se taj problem uklonio u potpunosti, postavljanje su optičke zamke oko svake kamere što je omogućilo akviziciju slike bez refleksija i u dnevnim i noćnim uvjetima. Na Slici 2 može se vidjeti i položaj radara koji su bili montirani iznad prednjega branika s dalekometnim radarem u sredini, dok su radari srednjeg dometa postavljeni bočno. S obzirom da smo se ograničili na upozorenje vozača od mogućeg frontalnog sudara s objektima, podaci s bočnih radara nisu korišteni u provedenim eksperimentima. Podaci s kamera, IMU-a i GPS snimani su na računalo putem USB sabirnice, a podaci s radara preko CAN sabirnice. Slika 3 prikazuje primjer scene iz noćnog i dnevnog skupa podataka. Ukupno je snimljeno 290 minuta vožnje, odnosno 14.8 TB podataka.



**SI 2:** Prikaz montaže senzora na tramvaj TMK 2300 (uz pomoć kolega iz Končar Električnih vozila d.d.)

### 3. Umjeravanje senzorskog sustava

Umjeravanje sustava stereo kamera i radara obavlja se u dva koraka. Prvo se umjerava stereo par kamera s ciljem određivanja intrinzičnih parametara svake kamere te međusobnih ekstrinzičnih parametara (relativne transformacije između kamera), a potom se umjeravanjem određuju ekstrinzični parametri između radara i kamera.

#### 3.1 Umjeravanje kamera

Umjeravanje kamera neophodan je uvjet za ispravno geometrijsko tumačenje slika. U kontekstu stereo vizualnog sustava, potrebno je odrediti intrinzične parametre svake pojedine te njihov relativni odnos u prostoru, tj. ekstrinzične parametre. U tu svrhu, koristili smo programski paket Kalibr [2] zasnovan na meti sačinjenoj od mreže markera. S obzirom na karakteristike odabrane leće i kamere, intrinzični parametri kamere opisani su *pinhole* modelom te radikalno-tangencijalnom distorzijom. Kamere smo umjeravali prije svake vožnje tramvaja pomicajući metu ispred tramvaja u trajanju 1-2 minute. Procedura umjeravanja prikazna je na Slici 4.



SI 3: Primjeri scene iz noćnog (gore) i dnevнog skupa podataka

### 3.2 Umjeravanje radara i kamera

U svrhu ekstrinzičnog umjeravanja radara i kamera razvili smo novu metodu zasnovanu na meti za umjeravanje [3]. Predložena metoda uključuje posebnu izvedbu mete za umjeravanje, registraciju korespondencija te optimizaciju u dva koraka. Metoda zahtijeva snimanje mete na otvorenom s dovoljno slobodnog prostora oko mete, kako bi se smanjili utjecaji lažnih mjerjenja radara, višestruke propagacije signala i sl. Metu je potrebno snimiti na različitim udaljenostima (2-10 m) u području gdje se vidna polja kamere i radara preklapaju. Umjeravanje se izvršava prije same vožnje, a procedura je također prikazana na Slici 4.

## 4. Lokalizacija i predviđanje trajektorije tramvaja

Kao što smo već napisali u uvodu, poznavanje lokacije tramvaja potrebno je za uspješno predviđanje njegove trajektorije. Pod lokalizacijom tramvaja podrazumijevamo određivanje njegova relativnog pomaka, estimaciju njegove kutne i linearne brzine te fuziju tih informacija s GPS podacima za određivanje apsolutne (globalne) lokacije tramvaja i izgradnju karte trasa.



Slika 4: Primjer umjeravanja kamera (lijevo) te radara i kamere

Modul za relativnu lokalizaciju zasniva se na načelu vizualne odometrije potpomođene inercijskim mjerenjima, a modul za apsolutnu lokalizaciju na načelu fuzije relativne lokalizacije i GPS mjerjenja proširenim Kalmanovim filtrom. Modul za relativnu lokalizaciju određuje translacijski i rotacijski pomak u odnosu na početnu točku gibanja tramvaja. Nedostatak je relativne lokalizacije stalni rast lokalizacijske pogreške tijekom vremena, dok je njezina glavna prednost vrlo visoka preciznost lokalizacije u kraćim vremenskim intervalima koju smo postigli primjenom vlastitog algoritma vizualne odometrije na sekvencu slika iz monokromatskog stereo para kamera [4] koja je već nekoliko godina najtočnija vizualna metoda odometrije na javnom skupu podataka KITTI na kojem istraživači iz cijelog svijeta evaluiraju svoje algoritme [5].

Apsolutna lokalizacija jednostavnim očitanjem GPS mjerena ima visoku nesigurnost određivanja i pozicije i orientacije. Primjerice, uzastopna očitanja GPS lokacije s GPS uređaja koji miruje mogu se razlikovati i po nekoliko desetaka metara. Međutim, prednost korištenja GPS mjerena je dvostruka. Prvo, GPS daje absolutnu lokaciju na geografskoj karti, u obliku geografske dužine i širine, što je informacija koja je korisna i za širi spektar primjena. Drugo, za razliku od relativne lokalizacije, pogreška GPS mjerena dugoročno ne raste, odnosno nije ovisna o prijeđenom putu, već o konfiguraciji satelita, reflektirajućih objekata u okolini i vremenskim prilikama. Cilj je razvoja algoritma fuzije iskorištavanje dobrih svojstava modula relativne lokalizacije s dobrim svojstvima GPS senzora u lokalacijski modul koji daje absolutnu lokaciju tramvaja sa znatno manjom nesigurnošću nego sami GPS uređaj. Algoritam fuzije realiziran je proširenim Kalmanovim filtrom u kojem se relativni pomak odometrije koristi za predikciju lokacije, a GPS mjerena za njezinu korekciju. Stanje Kalmanova filtra čine geografska dužina i širina, azimut te linearna i kutna brzina u dvodimenzionalnom koordinatnom sustavu.

Prednost predloženog sustava ilustrirana je na Slici 5 gdje se može vidjeti putanja tramvaja prilikom zaokreta oko Kvaternikovog trga. Crvena linija prikazuje putanju dobivenu čistim očitanjima iz IMU i GPS uređaja, dok plava linija prikazuje putanju estimiranu fuzijom GPS-a i vizualne inercijalne odometrije primjenom proširenoga Kalmanova filtra. Lako je uočljivo veliko odstupanje lokacija tramvaja koje daje GPS od stvarnih lokacija, dok razvijeni algoritam fuzije daje lokacije koje se dobro slažu sa stvarnim lokacijama (plava linija poklapa se s trasom tramvajskih tračnica).

Kako smo u uvodu spomenuli, posebnost je tramvaja i drugih tračničkih vozila u odnosu na cestovna vozila vrlo ograničeno područje kretanja. Iz perspektive sustava za pomoć vozaču to ograničenje donosi i neke prednosti. Prvo, relativno je jednostavno održavati, nadograđivati i koristiti cjelokupnu kartu prostora u kojem se tramvaj može naći. Drugo, još važnije, kretanje je tramvaja uzastopno ponavljajuće pa se putanja tramvaja može predvidjeti, a karta se u svakoj vožnji tramvaja može obnavljati i poboljšavati.



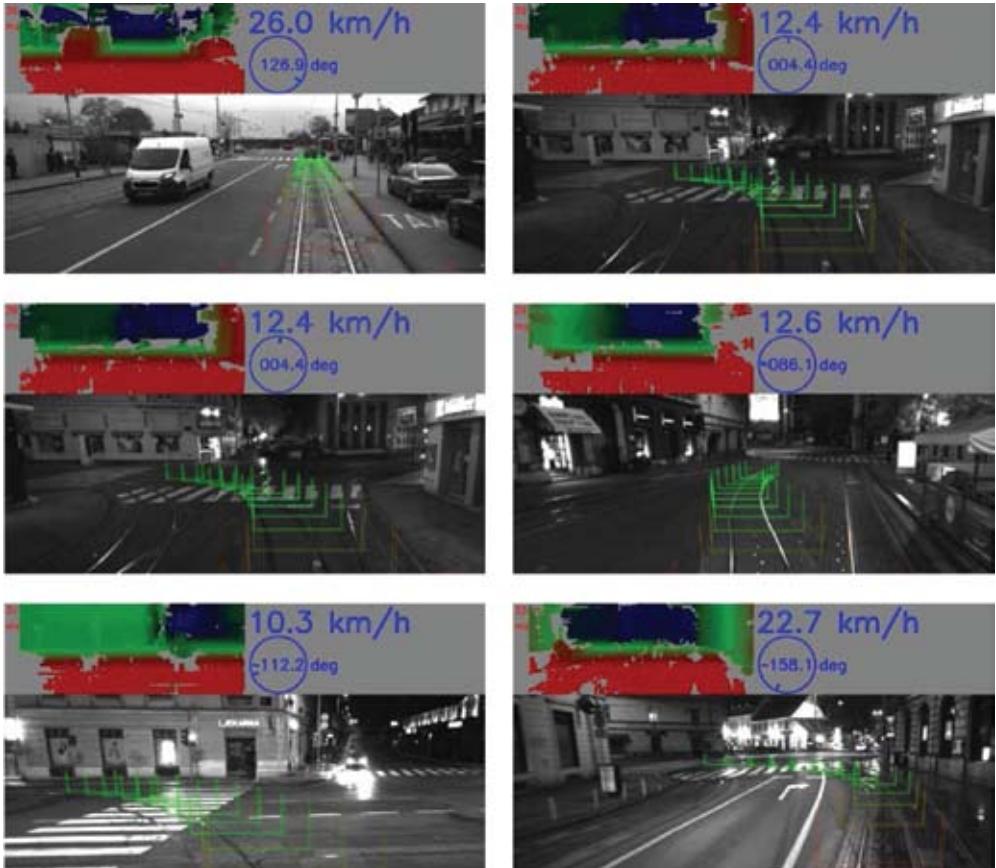
**Sl 5:** Putanja tramvaja prilikom zaokreta oko Kvaternikovog trga. Crvena putanja prikazuje rezultat iz IMU i GPS uređaja, dok je plava rezultat algoritma fuzije s vizualno inercijalnom odometrijom

Razvijeni programski modul kartiranja prostora stvara i svakom novom vožnjom tramvaja po istoj trasi poboljšava kartu tramvajskih tračnica (nažalost, zbog ograničenog broja raspoloživih vožnji u eksperimentima, nije bilo moguće proći istu trasu više puta). Karta je predstavljena nizom povezanih točaka u dvodimenzionalnom prostoru s pripadajućom geografskom dužinom i širinom te orijentacijom pruge. Prilikom puštanja sustava u rad u novome okruženju nije potrebnom imati na raspaganju nikakvu inicijalnu kartu prostora, nego se ona snimi u prvom prolazu tramvaja tračnicama. Snimljena karta tračnica, uz poznatu lokaciju tramvaja, omogućuje predikciju trajektorije tramvaja. Trajektorijom tramvaja smatramo putanju tramvaja koja u svakoj točki putanje ima definiran vremenski trenutak u kojem se tramvaj mora nalaziti, odnosno to je putanja koja uz lokacijske informacije sadrži i informaciju o brzinama tramvaja. Predikcija trajektorije tramvaja računa se primjenom modela konstantne brzine na predviđenu putanju tramvaja određenu segmentom tračnica neposredno ispred njega. Slika 6 prikazuje nekoliko primjera predikcije trajektorije putanjom izgrađene karte i modelom konstantne brzine sedam (7) sekundi unaprijed, dobivenih iz snimljenih podatkovnih skupova. Virtualni markeri postavljeni su u razmacima od pola sekunde.

## 5. Semantička segmentacija scene

Potencijal informacija koje daju kamere dodatno se može iskoristiti primjenom semantičke segmentacije scene dubokim neuronskim mrežama. Cilj modela semantičke segmentacije jest svakom pikselu ulazne slike dodijeliti semantičku oznaku iz predodređenog skupa, npr. automobil, pješak, cesta, nebo, vegetacija i sl. Semantička se segmentacija radi na slici u boji. U takvoj kameri senzor prikuplja crvenu, zelenu i plavu komponentu dolazećeg svjetla korištenjem zasebnih filtera boje za svaku komponentu.

To se može napraviti korištenjem zasebnih senzorskih ravnina za svaku komponentu. Međutim, to nije uobičajeno u modernim senzorima iz razloga što je proizvodnja takvog senzora skupa. Umjesto toga koristi se jedna senzorska ravnina koja filtrira različite komponente boje u uzorcima koji su poznati pod nazivom Bayerov filter. Uzorak se sastoji od 50% zelene, 25% crvene i 25% plave boje. Podaci sa senzora spremaju se u monokromatsku sliku (1 kanal po pikselu) formata PNG. Kako bi se moglo pročitati RGB vrijednosti, potrebno je napraviti demosaicing. Svaki piksel drži pravu vrijednost za jednu od komponenata boje dok je ostale vrijednosti potrebno interpolirati na temelju susjednih piksela. Postoji više mogućih Bayerovih filtera i interpolacijskih postupaka koji su dostupni u modernim bibliotekama za računalni vid.



SI 6: Primjeri predikcije trajektorije tramvaja na tračnice

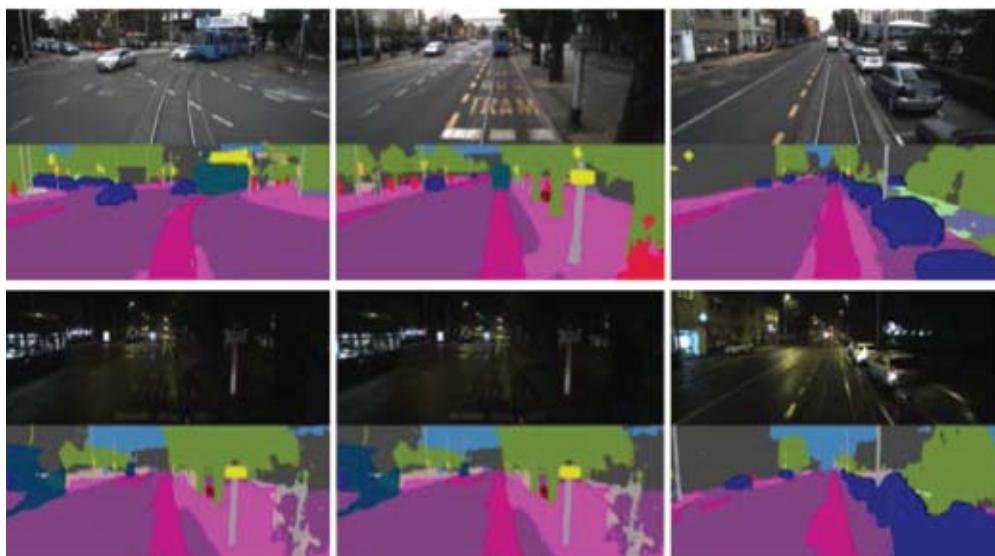
cesta	pločnik	zgrada	zid	ograda	stup	semafor	prometni znak	vegetacija	zemlja
nebo	osoba	biciklist	automobil	kamion	autobus	tramvaj	motocikl	bicikl	tračnice

SI 7: Razredi i odgovarajuće boje za vizualizaciju korišteni u semantičkoj segmentaciji

Sustav za vizualno raspoznavanje koji se primjenjuje u tračničkom okruženju morao bi sadržavati klasu "tračnice" na svom izlazu. Veliki podatkovni skupovi poput Mapillary Vistas [6] ne sadrže dovoljnju količinu slika koje prikazuju tračnice. Međutim, Vistas je koristan za učenje modela zbog svoje raznolikosti i veličine. Stoga je neuronski model treniran istovremeno na podatkovnim skupovima Vistas i RailSem [7]. RailSem je javno dostupan podatkovni skup koji sadrži slike snimljene iz vlakova i tramvaja. S obzirom da u okviru snimanja u Zagrebu nije provedeno označavanje podataka za semantičku segmentaciju, definiran je skup razreda koji

je prikidan za učenje na drugim podatkovnim skupovima. Skup razreda prikazan na Slici 7 definiram je u dva jednostavna koraka. Četiri razreda iz RailSem-a koji odgovaraju dijelovima tračnica spojeni su u zajednički razred. Nadalje, preostali Vistas i RailSem razredi preslikani su u jedan od 19 razreda iz skupa Cityscapes [8]. Kako bi se postigla što bolja segmentacijska točnost, korišten je jednorazinski model koji koristi točniji koder DenseNet-161. Za efikasno memorjsko zauzeće korišteno je spremanje aktivacija gusto povezanih slojeva prilikom unazadnog prolaza [9].

Slike 8 i 9 ilustriraju osjetljivost segmentacije modela na različite vremenske uvjete i osvjetljenje. Slika 8 prikazuje iste scene snimljene tijekom dana i noći. Izlazi modela prikazani su za ulazne slike. Svaki stupac uspoređuje segmentaciju istog dijela scene. Prvi stupac pokazuje da noćni uvjeti značajno degradiraju segmentacijsku točnost u pikselima tramvaja. Srednji stupac prikazuje da tamni dijelovi slike zbunjuju model. Zadnji stupac prikazuje da je model sposoban pronalaziti sitne pješake tijekom noći. Primjeri pokazuju smanjenje segmentacijske točnosti na tramvajima i podeksponiranim dijelovima scene (kojih u noćnim snimkama ima mnogo). Nadalje, uslijed spore brzine zatvarača kamere dolazi do zamućenja slike pokretom i posljedično loše segmentacije. Primjerice, taj se efekt događa kod gibajućih objekata ili u čitavoj sceni prilikom kretanja kamere. Slika 9 uspoređuje segmentacijske izlaze na istim lokacijama tijekom sunčanoga i oblačnoga vremena. Ti primjeri pokazuju kako preekspiranost uslijed visokog dinamičkog raspona u sceni utječe na segmentacijsku performansu. Nadalje, odbljesci sunca, koji se zbivaju prilikom izravnog osvjetljenja leće kamere, mogu značajno utjecati na segmentaciju. To je najbolje prikazano u zadnjem stupcu, gdje isti autobus ima različite segmentacije na izlazu modela.



**Sl 8:** Kvalitativna usporedba točnosti modela tijekom dana i noći



**SI 9:** Kvalitativna usporedba točnosti modela prilikom sunčanog i oblačnog vremena

## 6. Praćenje gibajućih objekata i predikcija sudara

### 6.1 Praćenje gibajućih objekata radarom

Automobilski radari, kao mjerjenja mogu dati tzv. listu detekcija ili listu praćenih objekata na temelju tih detekcija algoritmom implementiranim izravno u sklopolju radara. Detekcije su obrađena mjerena radara koja sadrže informacije iz samo jednog vremenskog očitanja, pri čemu se svaku detekciju opisuju njezina udaljenost, azimut, radikalna brzina određena pomoću Dopplerovog efekta te radarski presjek (*engl. radar cross section*) - mjera vidljivosti detektirane mete. Budući da radari svoja mjerena zasnivaju na obradbi informacija iz svega nekoliko antena za odašiljanje i primanje signala, njihova razlučivost i preciznost znatno su niže nego kod senzora poput lasera i kamera. Uz to, česte su pojave lažnih detekcija, izostanka detekcija te detekcija nastalih stapanjem više različitih objekata. Stoga je detekcije potrebno vremenski filtrirati praćenjem gibajućih objekata kako bi se mjerena radara mogla iskoristiti u predikciji sudara. Problem praćenja više gibajućih objekata može biti računski zahtjevan, ali unatoč tome mnogi proizvođači uz osnovnu obradbu radarskih očitanja daju i osnovno praćenje u ugradbenom računalu radara. Time radar generira listu praćenih objekata, pri čemu svaki element ima svoj jedinstveni identifikacijski broj, poziciju/brzinu/ubrzanje objekta u 2D prostoru te klasifikacijske zastavice o pouzdanosti, stacionaranosti i sl.

Ne temelju analize rada korištenog dalekometnog radara (koji kao ulazne parametre zahtijeva i linearne i kutne brzine tramvaja) odredili smo situacije u kojima sustav može izdati sigurnosna upozorenja isključivo zasnovana na podacima iz radara te IMU i GPS sustava. Estimacija brzina objekata koju daje radar, a koja je nužna u

predviđanju trajektorija tih objekata u svrhu predviđanja sudara, pokazala se nepouzdanom u određenim slučajevima. Naime, radar estimira brzinu na temelju mjerena radijalne brzine te promjene pozicije objekta između dvaju očitanja. Niska preciznost i razlučivost radara u mjerenu kuta te učestalost pojave lažnih mjerena, rezultiraju pogreškom u estimaciji brzine objekata. Primjerice, estimacija brzine vegetacije uz tračnice vrlo je često znatno veća od nule. Budući da radar nema dovoljno informacija da bi mogao zaključiti da se radi o vegetaciji, moguće je pogrešno zaključiti kako će vegetacija ući u putanju tramvaja. Iz toga smo razloga iskoristili smo klasifikaciju radarom estimiranih objekata na gibajuće i stacionarne. Na taj je način moguće razdvojiti trake estimiranih objekata koje su znatno pouzdanije od ostalih traka. Time smo riješili veliki broj lažnih predviđanja sudara, ali i ograničili osnovni sustav na analizu gibanja isključivo drugih gibajućih vozila u prometu. U predloženom rješenju, dinamički model ljudi nije izvediv jer ih radar klasificira kao stacionarne objekte zbog sporog gibanja. Nadalje, analizom postojećeg rješenja, uočili smo da sustav nepouzdanije estimira smjer brzina vozila u susjednom traku koja voze u suprotnome smjeru. Naime, pogreška estimacije njihove lateralne brzine dovodi do pogrešne predikcije njihove trajektorije. Stoga, dinamički model vozila iz suprotnog traka nije moguće koristiti, već ih se tretira kao statičke objekte. Drugim riječima, informacija iz radara korisna je isključivo za vozila koja se nalaze na tračnicama ispred tramvaja.

S obzirom na navedene razloge, praćenje objekata i predikcija sudara pomoću rada- ra može predvidjeti nekoliko situacija. Dinamički model i predviđanje trajektorije vozila koriste se isključivo za vozila koja voze po tračnicama u istome smjeru kao i tramvaj. S druge strane, vozila koja se ne nalaze na tračnicama, tretiraju se kao stacio-narni objekti. Kod predviđanja sudara sa stacionarnim objektima, koristi se isključivo dinamički model gibanja tramvaja.

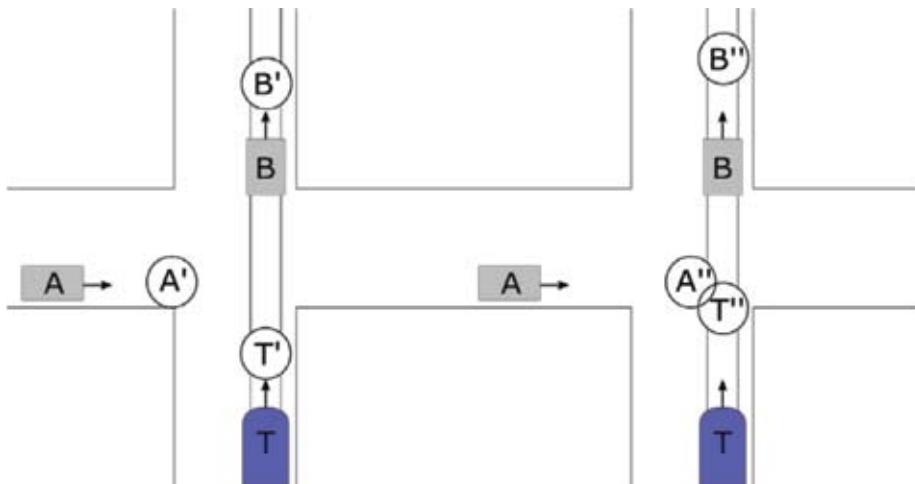
## 6.2 Algoritam predikcije sudara

Predikcija sudara zasniva se na predikciji gibanja tramvaja te na predikciji gibanja drugih objekata. Budući da su situacije u urbanom prometu vrlo dinamične s veli-kim brojem sudionika, potrebno je za reprezentaciju objekata koristiti što učinko-vitiju predikciju. Iz toga se razloga razmatrani algoritam predikcije sudara zasniva na reprezentaciji objekata kružnicama. Ovisno o njihovoj duljini, objekti mogu biti opisani jednom kružnicom ili s više njih. Predikcija buduće pozicije objekata i tram-vaja uzorkovana je s vremenom  $\Delta t = 0.5$  s. Za sve diskrete trenutke u budućnosti razmatramo mogućnost sudara tramvaja sa svim drugim objektima u prometu tako da promatramo odnos odgovarajućih parova kružnica  $K_1 (X_1, Y_1, R_1)$  i  $K_2 (X_2, Y_2, R_2)$ . Ako se kružnice sijeku, tj. ako zadovoljavaju sljedeći uvjet:

$$\sqrt{((X_1-X_2)^2 + (Y_1 - Y_2)^2)} \leq R_1 + R_2,$$

previđamo sudar te sustav u tom slučaju izdaje upozorenje vozaču.

Ilustracija rada algoritma predikcije sudara dana je na Slici 10, koja prikazuje križanje na kojem se susreću vozila A i B te tramvaj T. Predikcije njihovih pozicija dane su za dva diskretna trenutka,  $t'$  (1s) i  $t''$  (2s). U trenutku  $t'$ , buduća pozicija tramvaja (prikazana samo jednom kružnicom radi preglednosti) ne preklapa se niti s jednom kružnicom drugih sudionika u prometu te sustav ne izdaje upozorenje. S druge strane, u trenutku  $t''$ , kružnica T'' preklapa se s kružnicom A'' te sustav izdaje upozorenje.



**Sl 10:** Primjeri detekcije sudara metodom presjeka kružnica

## 7. Zaključak

U ovom je radu predstavljen sustav pomoći vozaču tramvaja razvijen u okviru projekta SafeTRAM. Glavna je zadaća sustava upozoravati vozača tramvaja na opasnost od frontalnog sudara, za što je potrebno kvalitetno projicirati u budućnost moguće trajektorije tramvaja i ostalih sudionika u prometu. Za tu je svrhu tramvaj opremljen sljedećim senzorima: stereo monokromatska kamera, kamera u boji, prednji dalekometni radar, IMU te GPS.

Za razliku od cestovnih vozila kod koji se buduće trajektorije mogu odrediti na temelju informacija o kutovima zakreta kotača, kod tračničkih su vozila buduće trajektorije određene položajem tračnicama. Primjerice, netom prije skretanja tračnica, mjerena pozicije tramvaja pokazuju samo translacijsku brzinu u smjeru gibanja te bi bez poznавanja točne lokacije tramvaja na tračnicama i trase algoritam procjene trajektorije mogao samo zaključiti da će se tramvaj nastaviti givati ravno. Iz toga razloga algoritmi upozorenja o opasnosti sudara moraju uključivati projekciju gibanja tramvaja na tračnicama, iako bi estimacija translacijske brzine trebala biti dovoljna za projekciju trajektorije na trasama bez skretanja. Naravno, pitanje je kako kvalitetno

razlučiti jesu li tračnice ispred tramvaja pravocrtne ili skreću? U ovome članku smo se fokusirali na lokalizaciju tramvaja na temelju prethodno izgrađene karte trasa kojima se tramvaj giba primjenom fuzije informacija iz kamere, inercijske mjerne jedinice i GPS-a. Na taj način tramvaj uvjek može znati gdje se točno nalazi te projicirati svoju trajektoriju na tračnice. Izazov je izgradnja kvalitetne karte trasa te što sustav može raditi jedino nakon što se karta izgradi, odnosno potreban je barem jedan prolaz tramvaja kroz trasu. Alternativni pristup uključuje detekciju tračnica u slici (tračnice su bile jedna od klase semantičke segmentacije) iz koje se može izravno procijeniti gdje će se tramvaj gibati. Prednost je toga pristupa što može raditi bez prethodne izgradnje karte, a nedostaci su što se tračnica ne može detektirati kada nije jasno vidljiva u slici, primjerice kada su druga vozila neposredno ispred tramvaja, postoji prirodni pokrov preko tračnica, sunce se snažno reflektira od tračnica te dovodi te segmente slike u zasićenje ili je presloženo detektirati tračnice na tračničkim raskrižjima. Neovisno o korištenju informacije o tračnicama za procjenu trajektorije, prvo je svakako nužno dobro estimirati translacijsku i rotacijsku brzinu tramvaja, što se može raditi pomoću inercijske mjerne jedinice i GPS-a, vizualne stereo odometrije te kombinacije navedenih senzora.

Za procjenu trajektorije gibanja drugih sudionika u prometu nužno je koristiti percepcijske senzore. Mi smo koristili vizujske senzore i radar. Glavna je funkcija rada detekcija objekata sa snažnim metalnim tragom, a u nekim se slučajevima može detektirati i ljude, ali s manjom pouzdanošću. Kamere mogu pružati informacije o drugim sudionicima u prometu na više načina, a u ovom je radu obrađena semantička segmentacija dubokim neuronskim mrežama. Za pristupe zasnovane na dubokim neuronskim mrežama potrebno je imati i specijalnu sklopovsku podršku, poput grafičkih kartica. Naravno, uz mjerena iz kamera, objekte je potrebno i pratiti kroz vrijeme da bi se estimirale njihove brzine i mogle predvidjeti njihove trajektorije. U usporedbi s radarom, pješaci se mogu znatno pouzdanoje detektirati vizualnim senzorima.

## Literatura

- [1] Kochenderfer, M.; Decision Making under Uncertainty, MIT Lincoln Laboratory, ISBN: 9780262029254, Lexington, USA, (2015)
- [2] Rehder, J. & Nikolic, J. & Schneider, T. & Hinzman, T. & Siegwart R.: Extending kalibr: Calibrating the extrinsics of multiple IMUs and of individual axes, IEEE International Conference on Robotics and Automation (ICRA), str. 4304-4311, Stockholm, Švedska, (2016)
- [3] Peršić, J. & Marković, I. & Petrović, I.: Extrinsic 6DoF Calibration of a Radar-LiDAR-Camera System Enhanced by Radar Cross Section Estimates Evaluation, Robotics and Autonomous Systems, 114 (2019), str. 217-230, ISSN: 0921-8890
- [4] Cvišić, I. & Ćesić, J. & Marković, I. & Petrović, I.: SOFT-SLAM: Computationally Efficient Stereo Visual SLAM for Autonomous UAVs, Journal of Field Robotics, 35 (2019) 4, str. 578-595, ISSN: 1556-4967

- [5] [http://www.cvlibs.net/datasets/kitti/eval\\_odometry.php](http://www.cvlibs.net/datasets/kitti/eval_odometry.php) Pristupljeno: 2021-02-02
- [6] Neuhold, G. & Ollmann, T. & Rota Bulo, S. & Kortschieder, P.: The Mapillary Vistas dataset for semantic understanding of street scenes, International Conference on Computer Vision (ICCV), Venecija, Italija, (2017)
- [7] Zendel, O. & Murschitz, M. & Zeilinger, M. & Steininger, D. & Abbasi, S. & Beleznai, C.: Railsem19: A dataset for semantic rail scene understanding, IEEE Conference on Computer Vision and Pattern Recognition (CVPR) Workshops, Long Beach, USA, (2019)
- [8] Cordts, M. & Omran, M. & Ramos, S. & Rehfeld, T. & Entweiler, M. & Benenson, R. & Franke, U. & Roth, S. & Schiele, B.: The Cityscapes dataset for semantic urban scene understanding, IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, USA, 2016
- [9] Krešo, I. & Krapac, J. & Šegvić, S.: Efficient ladder-style DenseNets for semantic segmentation of large images, IEEE Transactions on Intelligent Transportation Systems, (2020), ISSN: 1524-9050