Ušteda energije uz primjenu inteligentne ulične rasvjete

Pracny, Patrik

Undergraduate thesis / Završni rad

2024

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:200:524789

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2025-03-25**

Repository / Repozitorij:

Faculty of Electrical Engineering, Computer Science and Information Technology Osijek

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

Sveučilišni studij

Ušteda energije uz primjenu inteligentne ulične rasvjete

Završni rad

Patrik Pracny

Osijek, 2024.

FERIT
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I INFORMACIJSKIH TEHNOLOGIJA OSIJEK

Obrazac Z1P: Obrazac za ocjenu završnog rada na sveučilišnom prijediplomskom studiju

Ocjena završnog rada na sveučilišnom prijediplomskom studiju

Ime i prezime pristupnika:	Patrik Pracny
Studij, smjer:	Sveučilišni prijediplomski studij Elektrotehnika i informacijska tehnologija
Mat. br. pristupnika, god.	4722, 22.07.2019.
JMBAG:	0165083399
Mentor:	izv. prof. dr. sc. Višnja Križanović
Sumentor:	
Sumentor iz tvrtke:	
Naslov završnog rada:	Ušteda energije uz primjenu inteligentne ulične rasvjete
Znanstvena grana završnog rada:	**Telekomunikacije i informatika (zn. polje elektrotehnika)**
Zadatak završnog rada:	Velika količina potrebne električne energije i troškovi povezani s uličnom rasvjetom doveli su do potrebe za istraživanjem pitanja troškova. Gradovi diljem svijeta sve više ulažu u energetski učinkovite sustave ulične rasvjete. Moderna tehnologija ulične rasvjete može značajno smanjiti potrošnju energije kao i troškove rada i održavanja sustava. U radu je potrebno analizirati primjenu inteligentnog i energetski učinkovitog sustava široko rasprostranjene ulične rasvjete temeljene na detektiranju prometa. Potrebno je analizirati primjenu sustava namijenjenog promatranju kretanja vozila na cesti i uključivanja ulične rasvjete

Datum prijedloga ocjene završnog rada od strane mentora:	18.09.2024.
Prijedlog ocjene završnog rada od strane mentora:	Izvrstan (5)
Datum potvrde ocjene završnog rada od strane Odbora:	25.09.2024.
Ocjena završnog rada nakon obrane:	Izvrstan (5)
Datum potvrde mentora o predaji konačne verzije završnog rada čime je pristupnik završio sveučilišni prijediplomski studij:	26.09.2024.

FERIT
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I INFORMACIJSKIH TEHNOLOGIJA OSIJEK

IZJAVA O IZVORNOSTI RADA

Osijek, 26.09.2024.

Ime i prezime Pristupnika:	Patrik Pracny
Studij:	Sveučilišni prijediplomski studij Elektrotehnika i informacijska tehnologija
Mat. br. Pristupnika, godina upisa:	4722, 22.07.2019.
Turnitin podudaranje [%]:	7

Ovom izjavom izjavljujem da je rad pod nazivom**: Ušteda energije uz primjenu inteligentne ulične rasvjete**

izrađen pod vodstvom mentora izv. prof. dr. sc. Višnja Križanović

i sumentora

moj vlastiti rad i prema mom najboljem znanju ne sadrži prethodno objavljene ili neobjavljene pisane materijale drugih osoba, osim onih koji su izričito priznati navođenjem literature i drugih izvora informacija.
Izjavljujem da je intelektualni sadržaj navedenog rada proizvod mog vlastitog rada, osim u onom dijelu za koji mi je bila potrebna pomoć mentora, sumentora i drugih osoba, a što je izričito navedeno u radu.

Potpis pristupnika:

SADRŽAJ

1. UVOD **1**

1.1. Zadatak završnog rada **2**

2. ZNAČAJKE I PREDNOSTI PAMETNE RASVJETE U ODNOSU NA TRADICIONALNE SUSTAVE **3**

2.1. Energetska učinkovitost **3**

2.2. Automatizacija i kontrola **3**

2.2.1. Distribuirani 3

2.2.2. Centralizirane 5

2.3. Sigurnost **6**

2.4. Prikupljanje podataka do poboljšanja infrastrukture **7**

3. POTICAJNI I OGRANIČAVAJUĆI ČIMBENICI ZA IMPLEMENTACIJU PAMETNE RASVJETE **9**

3.1. Motivacijski faktori **9**

3.2. Potražnja za pametnim tehnologijama u ruralnim i urbanim područjima **9**

3.3. Ekološki benefiti **10**

3.4. Visoki početni troškovi **10**

3.5. Kompatibilnost sustava **11**

3.6. Sigurnost podataka **11**

3.7. Kvarovi **12**

4. PROBLEMATIKA IMPLEMENTACIJE PAMETNE RASVJETE **13**

4.1. Kompleksnost instalacije i održavanja **13**

4.2. Sigurnosni rizici **13**

4.3. Privatnost **13**

4.4. Nedostatak standardizacije **14**

5. PRIKAZ PRAKTIČNOG DIJELA RADA **15**

5.1. UVOD U PRAKTIČNI DIO RADA **15**

5.2. KORIŠTENE TEHNOLOGIJI I ALATI **15**

5.2.1. CupCarbon 15
5.2.2. Python 15
5.2.3. Microsoft Excel 16
5.3. IZRADA RADA 16
5.4. PRIKAZ RADA 24
5.5. REZULTATI 28
6. ZAKLJUČAK 35
LITERATURA 36
SAŽETAK 38
ABSTRACT 39

1. UVOD

Pametna rasvjeta predstavlja napredak u tehnologiji koji omogućuje visoku razinu automatizacije i prilagodbe rasvjetnih sustava. Upravljana je raznim senzorima koji su isprogramirani da se rasvjeta uključuje ili isključuje kada se detektira neki pokret na senzoru. Razvoj takve rasvjete potiču globalni čimbenici koji naglašavaju potrebu za energetskom učinkovitošću i održivijim ili „ECO“ rješenjima.

Jedan od glavnih razloga za razvoj pametne rasvjete je rast globalne populacije, što doprinosi urbanizaciji i povećava potražnju za energijom [1] [2]. Kako se gradovi šire, potreba za uličnom i javnom rasvjetom raste, što povećava energetsku ovisnost. Tradicionalni sustavi rasvjete, poput žarulja sa žarnom niti ili LED rasvjeta, nisu dovoljni za prilagodbu različitim uvjetima korištenja. Uvođenjem pametnih sustava rasvjete, koji uključuju LED tehnologiju i IoT (Internet of Things) upravljanje, moguće je smanjiti energetske zahtjeve bez smanjenja kvalitete osvjetljenja.

Drugi važan faktor je globalno zatopljenje, i potreba za smanjenjem emisija stakleničkih plinova. Svjetske energetske politike, sve više teže smanjenju potrošnje energije u svim sektorima, a rasvjeta čini jedan od većih dijelova te potrošnje. Rasvjeta čini značajan dio globalne potrošnje. Prema podacima iz 2006., rasvjeta je bila odgovorna za oko 19 % globalne potrošnje električne energije, dok se postotak smanjio na oko 13 % do 2018. zbog prelaska na energetski učinkovitije tehnologije, poput LED rasvjete [3]. S pametnom rasvjetom omogućila bi se optimizacija korištenja svjetlosnih izvora kroz razne senzore, i omogućila bi prikupljanje podataka o raznim dijelovima grada: o prometu, o količini buke, o svjetlosnom zagađenju.

Kada pričamo o svjetlosnom zagađenju, jedan aspekt koji možemo sagledati jest način na koji se to odražava na noćne životinje i biljke, jer tako sama rasvjeta izaziva probleme u njihovom biološkom ritmu i ometa im njima prirodan način života.

Energetska učinkovitost je pokazatelj doprinosa smanjenju potrošnje električne energije, a pametni sustavi rasvjete značajno pridonose smanjenju potrošnje električne energije, čime se smanjuje emisija ugljičnog dioksida i drugih stakleničkih plinova. U kombinaciji s obnovljivim izvorima energije, pametna rasvjeta postaje ključan element za održivo rješenje u budućnosti.

Osim energetskih aspekata, pametna rasvjeta može doprinijeti stvaranju ugodnijih životnih prostora. Sposobnost prilagođavanja svjetla različitim aktivnostima ili potrebama korisnika doprinosi boljem mentalnom zdravlju. Na primjer, topla prigušena svjetla mogu stvoriti opuštajuću atmosferu u večernjim satima i to pridonosi dobrom kardinalnom ritmu.

S obzirom na navedene čimbenike: rast populacije, potrebu za energetskom učinkovitosti i borbu protiv globalnog zatopljenja, pametna rasvjeta postaje važan dio strategije za stvaranje održivih i sigurnijih gradova.

1.1. Zadatak završnog rada

Zadatak završnog rada je osmisliti scenarije pametne rasvjete i simulirati njenu primjenu u odabranim scenarijima. U radu treba proći kroz prednosti, poticaje i ograničenja za implementaciju pametne rasvjete, te potrebno je objasniti korišteni softver koji se koristio pri izradi i objasniti kako se radi s navedenim softverom. Potrebno je pokrenuti simulaciju te prikazati dobivene rezultate.

2. ZNAČAJKE I PREDNOSTI PAMETNE RASVJETE U ODNOSU NA TRADICIONALNE SUSTAVE

Jedna od velikih razlika tradicionalnih sustava od sustava pametne rasvjete je ta da se sustavi pametne rasvjete koriste raznim senzorima i dodatcima kao što su solarni paneli. Time se postižu značajne uštede, rasvjeta može biti prilagođenija, možemo imati veći uvid na stanje sustava radi održavanja i još niz različitih prednosti. U ovom radu fokus je stavljen na energetsku učinkovitost sustava.

2.1. Energetska učinkovitost

Sam prelazak na LED rasvjetu ima brojne koristi. Za razliku od tradicionalne rasvjete, LED rasvjeta troši manje energije. LED svjetiljke mogu smanjiti potrošnju za 50 – 70 % [4]. Samim smanjenjem energetske potrošnje, smanjuju se emisije ugljičnog dioksida (CO_2). Procjenjuje se da bi se s globalnim prijelazom na energetski učinkovitiju LED tehnologiju moglo uštedjeti više od 1400 milijuna tona CO_2 i spriječiti potreba za izgradnjom 1250 elektrana, uključuje primjenu LED u svim sektorima [5].

2.2. Automatizacija i kontrola

Posljednjih godina automatizacija ulične rasvjete postala je glavna tema istraživanja zbog visokih troškova električne energije potrebne za osvjetljivanje cesta, avenija, ulica i drugih javnih površina. Zbog toga su razvijena brojna pametna rješenja za rasvjetu kako bi se smanjila potrošnja energije. Tako, rasvjeta se može prilagoditi prirodnom svjetlu, a svjetla se mogu isključiti kada za njih nema potrebe. Razlikujemo dva načina kontroliranja - distribuirani i centralizirani.

2.2.1. Distribuirani

Distribuirani sustavi omogućuju da svaki stup rasvjete radi potpuno neovisno, jer su opremljeni senzorima koji detektiraju kretanje i prilagođavaju svjetlo prema potrebama trenutne situacije. Slika 2.1. prikazuje oblik distribuirane mreže. Ono što je najvažnije, ovi sustavi se brzo prilagođavaju promjenama u okolišu i vrlo su učinkoviti zbog svoje brzine i preciznosti. Na primjer, mogu pojačati svjetlo, isključiti ga ili prigušiti ako nema potrebe. Distribuirani sustavi pružaju vrlo učinkovit način upravljanja uličnom rasvjetom, osiguravajući optimalno osvjetljenje uz minimalne energetske troškove.

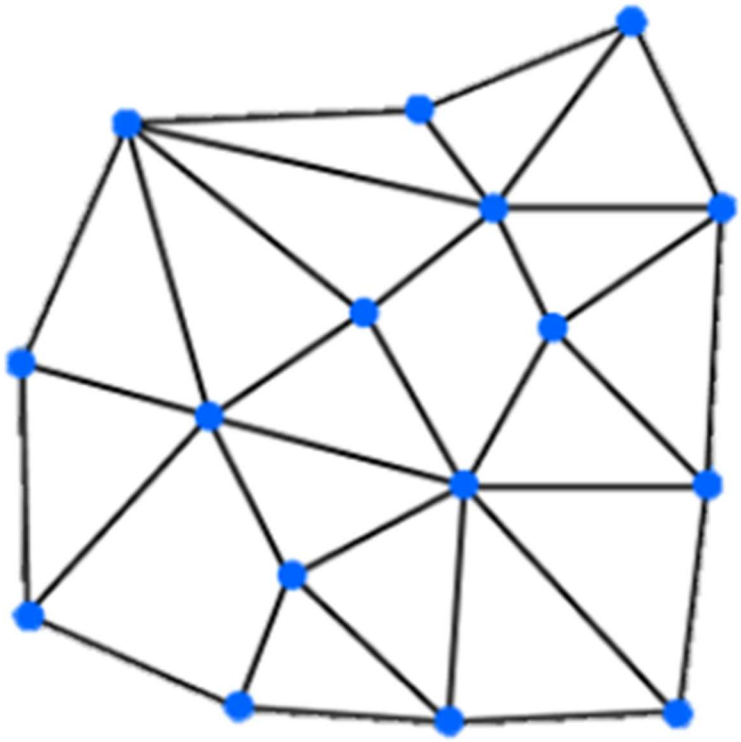

Slika 2.1. Distribuirana raspodjela

Nova predložena metoda za pametne sustave rasvjete su na temelju kašnjenja (engl. *Delay-based*, skr. DEL), na temelju nailaska (engl. *Encounter-based*, skr. ENC) i na temelju promjene intenziteta svjetla (engl. *Dimming*, skr. DIM) kao alternative trenutno korištene ulične rasvjete, koja podrazumijeva da su ulične svjetiljke uključene cijelo vrijeme u prosjeku 10 do 12 sati dnevno [6].

1. Na temelju kašnjenja (DEL)

Na temelju kašnjenja svjetiljka je isključena kada senzor detekcije pokreta nije detektirao pokrete na zadanoj udaljenosti i ako je unutar vremenskog raspona kada nitko ne prolazi u blizini. Ali ako senzor detektira pokret, ulična svjetiljka se uključi i radi punim intenzitetom.

2. Na temelju nailaska (ENC)

Metodologija na temelju nailaska slična je metodologiji na temelju kašnjenja, sa sitnom modifikacijom. Ovdje se svjetiljka uključi kada se detektira pokret na senzoru i ostaje aktivna tijekom unaprijed definiranog aktivnog razdoblja.

3. Na temelju promjene intenziteta svjetla (DIM)

Metodologija je temeljena na promjeni intenziteta svjetla tako da je količina svijetla od ulične svjetiljke zatamnjena u proporciji s brojem vozila na predefiniranoj udaljenosti. Minimalna razina intenziteta svjetla je definirana u sustavu, a kako se objekt približava uličnoj svjetiljci, tako se i razina svjetla poveća, sve do maksimuma od 100 %. Ova metoda nije perfektna jer treba voditi računa o preprekama koje se mogu pojaviti na tom putu, npr. životinja koja prelazi preko ceste.

2.2.2. Centralizirane

Za razliku od distribuirane, centralizirana raspodjela ulične rasvjete temelji se na centralnoj jedinici koja kontrolira rasvjetu. Slika 2.2. prikazuje oblik centralizirane mreže.

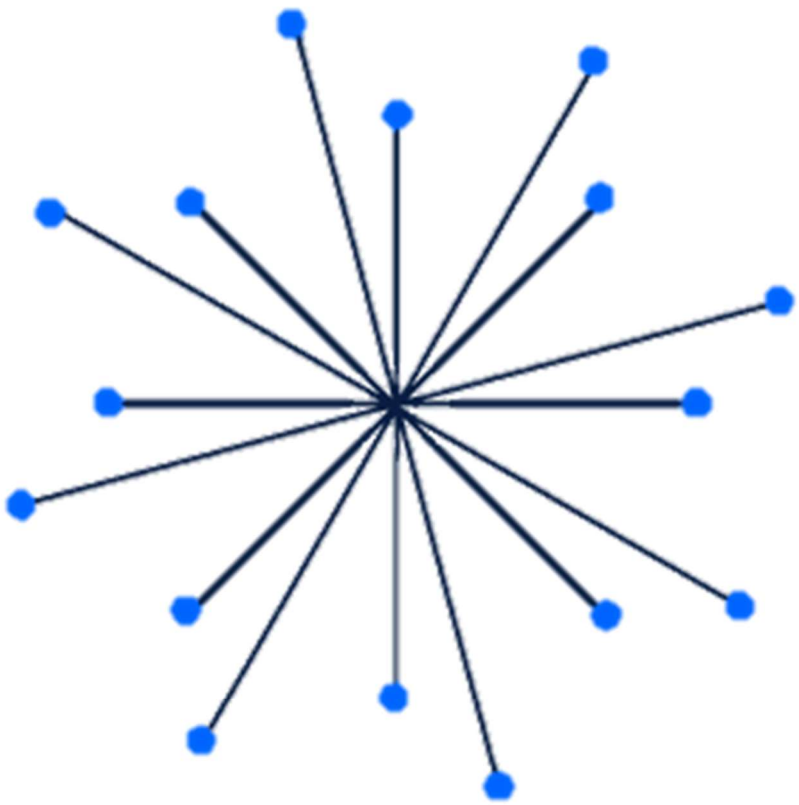

Slika 2.2. Centralizirana raspodjela

2.3. Sigurnost

Za razliku od tradicionalnih sustava, pametne ulične svjetiljke osim što su integrirane sa senzorima koji detektiraju kretanja, mijenjaju intenzitet osvjetljenja kako bi svjetiljke bile efikasnije. Uz pametnu rasvjetu integrirane su razne tehnologije poput video nadzora i praćenja prometa. Povezivanjem rasvjete s nadzornim sustavima, poboljšavaju se mogućnosti nadzora: u slučaju kriminala, u slučaju nekih nesreća ili u slučaju prekršaja kod parkiranja. Slika 2.3. predstavlja pametnu svjetiljku sa svim njenim senzorima.

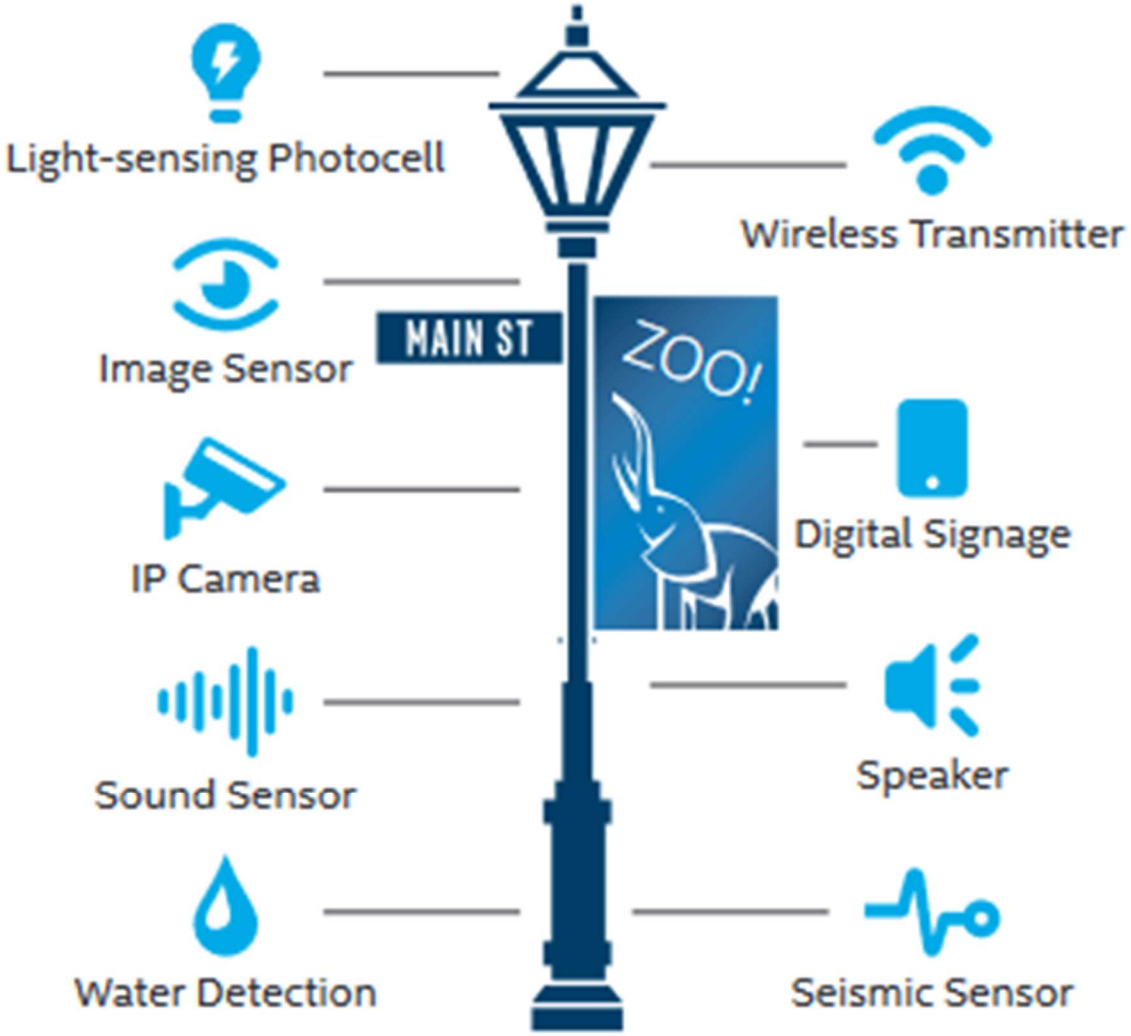

Slika 2.3. Pametna svjetiljka

2.4. Prikupljanje podataka do poboljšanja infrastrukture

Za razliku od tradicionalnih sustava, pametna ulična rasvjeta je opremljena s niz različitih senzora poput kamera i mikrofona. Oni omogućuju prikupljanje podataka koji se mogu analizirati u potrebe poboljšanja infrastrukture prometnica, i sigurnosti.

S pomoću kamera mogu se prikupiti podatci o prometu te koliko često dolazi do zagušenja prometa. Zagušen promet povećava potrošnju goriva, što istodobno povećava emisije ugljikovog dioksida, i tako dodatno zagađuje zrak. Također mogu se prikupiti podaci o parkirnim mjestima. Što može pomoći u planiranju i optimizaciji parkirnih prostora. Primjere uspješne primjene nalazi se u Barceloni, gdje su pametni senzori ugrađeni na parkiralištu, a aplikacija pruža informaciju vozačima o dostupnosti parkirnih mjesta [7].

Analizom podataka, mogu se prepoznati periodi visokog i niskog prometnog opterećenja te prilagoditi broj dostupnih mjesta.

Mikrofoni služe za praćenje zagađenja bukom, koji je jedan od značajnih, ali često zanemarenih problema današnjih gradova [8]. Na temelju prikupljenih podataka s mikrofona dodatno bi se omogućilo planiranje urbanog razvoja, kao što su donošenje odluke o smještaju novih stambenih područja, industrijskih zona ili komercijalnih objekata, ili kako bi se minimizirao utjecaj buke na stanovništvo. Također, analizom zvuka moga bi se identificirati izvor buke, kao što su promet, gradilište ili javna događanja.

3. POTICAJNI I OGRANIČAVAJUĆI ČIMBENICI ZA IMPLEMENTACIJU PAMETNE RASVJETE

3.1. Motivacijski faktori

Pametna rasvjeta ne samo da predstavlja korak prema modernizaciji urbanih centara, već je njezina primjena vođena nizom ključnih motivacijskih čimbenika, od kojih su najznačajnije klimatske promjene i rast broja stanovništva. Kako se globalno stanovništvo ubrzano povećava, trenutna populacija iznosi 7.9 milijardi ljudi, očekuje se da će doseći 8.6 milijardi do 2030., 9.8 milijardi do 2050 [9]. To dovodi do veće urbanizacije i većih zahtjeva za električnom energijom i boljom infrastrukturom, koji uključuje i sustave rasvjete. U tom kontekstu, tradicionalni sustavi rasvjete postaju neučinkoviti i zastarjeli, te ih je potrebno zamijeniti pametnijim, energetski učinkovitijim rješenjima.

Isto tako, jedan od izazova današnjice su klimatske promjene. Prema navedenim priopćenjima G8 (naziv skupine industrijski najrazvijenijih i gospodarski najmoćnijih zemalja svijeta) cilj je postići smanjenje stakleničkih plinova za barem 50 % do 2050. godine [10]. Pametna rasvjeta može značajno doprinijeti ovom cilju jer se temelji na tehnologiji koja omogućuje optimizaciju potrošnje energije.

3.2. Potražnja za pametnim tehnologijama u ruralnim i urbanim područjima

Sve veća potražnja za pametnim tehnologijama postaje jedan od ključnih faktora uvođenja inteligentnih sustava rasvjete. Danas sve više potrošača traži tehnološka rješenja koja ne samo da povećavaju udobnost i učinkovitost, već i doprinose ekološkoj održivosti. Ova potražnja, vidljiva kroz ubrzani rast pametnih domova i gradova. Potiče razvoj pametnih rješenja u raznim sektorima, uključujući i ona u javnim.

Uvođenjem pametne ulične rasvjete, lokalne zajednice i gradske uprave zadovoljavaju potražnju stanovnika za modernim, tehnološkim naprednim rješenjima. Ovi sustavi također omogućuju bolju interakciju između građana i tehnologije, gdje se uz pomoć pametnih aplikacija ili platformi može kontrolirati rasvjeta, prijavljivati problemi ili dobivati povratne informacije o stanju infrastrukture. Takva povezanost stvara osjećaj aktivnog sudjelovanja građana u upravljanju javnim resursima i

povećava njihovo zadovoljstvo [11]. Pametna rasvjeta se uspješno implementirala u urbanim i ruralnim područjima, donoseći energetske uštede i poboljšanja kvalitete života.

1. **Scenariji implementacije pametne rasvjete u urbanim područjima** – Los Angeles, SAD: Grad Los Angeles implementirao je jedan od najvećih sustava pametne rasvjete, zamijenivši preko 140000 uličnih svjetiljki s LED svjetiljkama povezanima putem senzora i centraliziranog sustava kontrole. Projektom je smanjena potrošnju energije za rasvjetu za 63 %, a emisije CO_2 smanjene su za 47000 tona godišnje [12].
2. **Scenariji implementacije pametne rasvjete u ruralnim područjima** – ruralna područja Australije: Za implementaciju ovakvih sustava korišteni su solarni paneli i LED, te time eliminirala se potreba za podzemnim kablovima i priključenjem na elektroenergetsku mrežu. Ova svjetla lako se postavljaju, zahtijevaju minimalno održavanje i mogu se nadzirati na daljinu, što ih čini idealnim za ruralna i teško dostupna mjesta [13].

3.3. Ekološki benefiti

Pametna rasvjeta nije samo tehnološko rješenje već i ekološki alat koji doprinosi smanjenju potrošnje energije, smanjenju emisije stakleničkih plinova, smanjenju svjetlosnog onečišćenja te općenito pomiče održivu gradsku infrastrukturu.

Iako su prednosti implementacije pametne rasvjete velike, posebno u kontekstu globalnog zatopljenja i rasta broja stanovništva, postoje značajni izazovi u implementaciji tih sustava. Trenutni sustavi rasvjete često su zastarjeli, što znači da nije dovoljno samo instalirati nove senzore i očekivati da će sve funkcionirati. Potrebne su opsežne promjene, poput zamjene postojeće rasvjete s LED tehnologijom. Također, važno je osigurati da sustavi imaju pristup internetu za komunikaciju sa senzorima i osigurati sigurnost prikupljenih podataka od kibernetičkih napada kako bi se zaštitila privatnost podataka, i kako bi se osiguralo da se podaci ne koriste u krive svrhe.

3.4. Visoki početni troškovi

Uvođenjem pametne rasvjete često se suočava s visokim početnim troškom, zbog nekoliko ključnih čimbenika koji uključuju:

1. Zamjenu i nadogradnju postojećih sustava
2. Mrežnu povezanost i infrastrukturu

3. Sigurnost podataka
4. Djelatnika sustava održavanja

Iako pametna rasvjeta nudi mnogo prednosti, ove investicije zahtijevaju pažljivo planiranje i značajna ulaganja kako bi se osigurala uspješna implementacija i dugoročna funkcionalnost sustava.

3.5. Kompatibilnost sustava

Mnogi gradovi i općine imaju već instalirane sustave rasvjete koji nisu kompatibilni s novim pametnim tehnologijama. Stoga, implementacija pametne rasvjete često zahtijeva zamjenu ili nadogradnju postojeće rasvjete. U nekim slučajevima, javlja se potreba za modernizacijom električne instalacije kako bi se omogućila integracija s pametnim sustavima.

U slučaju da postojeće svjetiljke nisu LED, one će morati biti zamijenjene kako bi se omogućila funkcionalnost pametnog sustava. Pametni sustavi rasvjete isto tako zahtijevaju mrežnu povezanost za komunikaciju između senzora, kontrolera i korisničkih sučelja. Tu se može uključiti bežična mreža poput Wi-Fi-a, mobilna poput 5G ili 4G, ili žična povezanost putem Ethernet-a ili optike.

3.6. Sigurnost podataka

Sigurnost podataka je jedan od ključnih dijelova pametne rasvjete i pametnih gradova općenito. Jer s raznim senzorima moguće je prikupljati veliku količinu različitih podataka. Prije nego što se nastavi dalje unaprjeđivati pametnu uličnu rasvjetu, potrebno je osigurati prikupljene podatke od kibernetički napada. Također, bitna je pravna regulativa vezana uz privatnost podataka, ona utječe na razvoj pametne ulične rasvjete. Opća uredba o zaštiti podataka (GDPR) Europske unije postavlja jasne smjernice (Poglavlje 3, Članci 12–23) u vezi sa zaštitom osobne privatnosti, transparentnošću prikupljanja podataka i prvenstvom prava pojedinca na vlasništvo nad podacima [14].

GDPR zahtijeva da se osobni podaci prikupljaju i obrađuju na transparentan način, uz jasno informiranje pojedinaca o svrsi prikupljanja podataka. Također, pojedinci imaju pravo pristupa svojim podacima, pravo na ispravak netočnih podataka, pravo na brisanje podataka (pravo na zaborav), te pravo na ograničenje obrade podataka. Ove odredbe osiguravaju da pojedinci zadrže

kontrolu nad svojim osobnim podacima, što može predstavljati izazov za razvoj tehnologija koje zahtijevaju prikupljanje i obradu velikih količina podataka, poput pametnih uličnih svjetiljki.

3.7. Kvarovi

Iako pametna rasvjeta nudi napredne mogućnosti za precizno obavještavanje o kvarovima, njezina složenost, budući da se uglavnom sastoji od različitih senzora, može otežati proces popravka i održavanja. Ova kompleksnost često zahtijeva dodatno znanje i vještine koje postojeće osoblje možda nema. Stoga je potrebno investirati u obuku novih ili postojećih radnika koje će se osposobiti za rad s ovim naprednim sustavima. Obuka može biti dugotrajna i skupa, budući da uključuje učenje specifičnih tehnologija i procedura. Dok se novi radnici osposobljavaju, može doći do privremenog smanjenja učinkovitosti u održavanju sustava, što može dovesti do dodatnih troškova i mogućih problema u funkcioniranju rasvjete. Ovi dodatni troškovi za obuku i specijaliziranu opremu mogu predstavljati značajan financijski teret za organizacije koje implementiraju pametne sustave rasvjete. Stoga, iako pametna rasvjeta nudi mnoge prednosti u smislu energetske učinkovitosti i kontrole, njezina složenost zahtijeva pažljivo planiranje i resurse za uspješno upravljanje i održavanje.

4. PROBLEMATIKA IMPLEMENTACIJE PAMETNE RASVJETE

Implementacija pametne rasvjete nije jednostavna: moraju se osigurati dovoljna sredstva, sustav se mora osigurati od kibernetičkih napada, s podacima se mora rukovati s iznimnom transparentnošću u slučaju da bi došlo do neprimjerenog korištenja podataka. Isto tako da bi se sustav radio na veliko potrebna je odgovarajuća standardizacija.

4.1. Kompleksnost instalacije i održavanja

Jedan od glavnih izazova prilikom uvođenja pametne rasvjete je njihova kompleksnost. Za razliku od tradicionalnih sustava, pametni sustavi zahtijevaju postavljanje dodatnih komponenti, kao što su senzori, kontrolne jedinice i sl. što uključuje složeniju instalaciju. Osim toga, održavanje isto postaje složenije zbog napredne tehnologije koja zahtjeva redovito ažuriranje softvera i nadzor nad ispravnosti umreženih komponenti.

4.2. Sigurnosni rizici

Budući da pametni sustavi ovise o digitalnim mrežama, oni postaju potencijalne mete kibernetičkih napada. Hakeri mogu pristupiti sustavima rasvjete te ih koristiti za narušavanje infrastrukture grada ili prikupljanje osjetljivih podataka.

4.3. Privatnost

Pametna ulična rasvjeta, koja sa sobom donosi niz funkcionalnosti uz veliku količinu senzora, donose sa sobom i značajne brige u vezi sa samom privatnošću, kao i izazove oko upravljanja osjetljivim podacima koje prikupljaju. Ovi sustavi, opremljeni sa senzorima kao što su kamere i mikrofoni, omogućuju brojne korisne primjene, uključujući nadzor prometa, upravljanje parkiranjem, poboljšanje javne sigurnosti i praćenje zagađenja bukom. Međutim, prikupljeni video i audio podaci mogu sadržavati detalje o osobama koji se mogu koristiti za njihovu identifikaciju putem automatskog prepoznavanja lica, dok audio zapisi mogu bilježiti osobne razgovore koji se mogu analizirati pomoću tehnologija kao što je to tehnologija za obradu prirodnih jezika (NPL). Ove vrste podataka predstavljaju značajan izazov za očuvanje privatnosti, što može dovesti do zabrinutosti među građanima i ograničiti prihvaćanje ili širenje inicijativa pametne rasvjete.

4.4. Nedostatak standardizacije

Nedostatak jedinstvenih standarda za implementaciju pametne rasvjete, jedan je od izazova koji utječe na uspjeh ovih sustava na globalnoj razini. U trenutnoj fazi razvoja pametnih sustava, postoje različiti protokoli i tehnologije koje se koriste, a ovise od proizvođača do proizvođača i regije. Taj nedostatak standardizacije može dovesti do problema u kompatibilnosti između različitih sustava i opreme. I samo zbog tog nedostatka jedinstvenih tehničkih standarda, gradovi i općine riskiraju ulaganje u sustave koji bi mogli biti teški za nadogradnju ili povezivanje s drugim gradskim infrastrukturama.

5. PRIKAZ PRAKTIČNOG DIJELA RADA

5.1. UVOD U PRAKTIČNI DIO RADA

Praktični dio rada usmjeren je na analizu stvarne implementacije pametne rasvjete u specifičnom okruženju, s naglaskom na učinkovitost sustava i uštede energije. Kroz testiranje i evaluaciju sustava nastoji se prikazati stvarna vrijednost ovih tehnologija te identificirati daljnje mogućnosti unapređenja.

5.2. KORIŠTENE TEHNOLOGIJI I ALATI

Simulacija sustava pametne rasvjete izrađena je uz pomoć specijaliziranog softvera, pri čemu je ključni dio vizualizacije i analize dobiven korištenjem alata CupCarbon. Za prikaz numeričkih podataka korišten je Microsoft Excel. Za automatizaciju i generiranje skripti koje upravljaju senzorskim sustavima i rasvjetom korišten je Python.

5.2.1. CupCarbon

CupCarbon je simulator za pametne gradove i Internet of Things (skr. IoT) bežične senzorske mreže (SCI-WSN). CupCarbon služi za dizajniranje, vizualizaciju, ispravljanje pogrešaka i za utvrđivanje distribuiranih algoritama za praćenje prikupljenih podataka iz okoliša. Njegova primjena uključuje stvaranje različitih okolišnih scenarija, poput simulacije požara, ispuštanja plinova, kretanja mobilnih objekata i drugih situacija, s posebnim naglaskom na edukacijske i znanstvene projekte. CupCarbon nudi simulacijsko okruženje koje omogućava sveobuhvatno modeliranje i testiranje sustava pametnih gradova i senzorskih mreža [15] [16].

S CupCarbon-om mogu se dizajnirati i prototipirati mreže putem ergonomski prilagođenog sučelja koje koristi OpenStreetMap (skr. OSM), okvir za postavljanje senzora izravno na kartu stvarnog svijeta. Također uključuje skriptu pod nazivom SenScript koja omogućuje programiranje i konfiguriranje svakog senzorskog čvora pojedinačno [17].

CupCarbon jednostavan je za koristiti, ali iznimno kompleksan s obzirom na ogromnu količinu mogućnosti i same slobode izrade raznih scenarija.

5.2.2. Python

Python je programski jezik opće namjene, interpretirani, objektno orijentirani programski jezik visoke razine, poznat po svojoj jednostavnosti i čitljivosti koda. Dizajniran je s naglaskom na

jasnoću sintakse, što ga čini pristupačnim za početnike, a istovremeno dovoljno moćnim za iskusne programere. Osim što može poslužiti za razvoj aplikacije, može se koristiti kao skriptni jezik [18].

Ključne značajke:

- Podržava različite paradigme programiranja: objektno orijentirano, proceduralno i funkcionalno programiranje.
- Višenamjenski jezik: koristi se u različitim područjima uključujući web razvoj, znanstvene i numeričke proračune, automatizaciju, strojno učenje, analizu podataka i još mnogo različitih primjena.
- Jednostavnost.

5.2.3. Microsoft Excel

Microsoft Excel je alat za rad s tabličnim podacima. Koristi se za unos, obradu, analizu i vizualizaciju podataka kroz tablice, grafikone i različite formule.

Ključne značajke:

- Proračunske tablice
- Filtriranje i sortiranje podataka
- Grafikoni i vizualizacija
- Upravljanje podacima

5.3. IZRADA RADA

U radu je korišten simulacijski program CupCarbon, koji služi za simulaciju pametnih gradova i IoT za simulaciju mreže. Projekt je ciljan na simulaciju gradske rasvjete koja sa sobom sadrži senzore za detekciju kretanja. S time simulacija je ciljana na to da su svjetla upaljena samo kada senzor detektira kretanje, a kada nema kretanja da se isključi, s time dolazi do uštede energije i smanjenja svjetlosnog zagađenja.

Prije nego što se implementira simulacija potrebno je naglasiti neka pravila odnosno ograničenja simulacije, i skripte koje će biti korištene u simulaciji.

U projektu svjetla je potrebno postaviti na razmaku od 20 metara, kako je propisano zakonom [19]. Članak 12. navodi da se udaljenost dobije tako da se pomnoži visina rasvjete * 3.8. Za visinu

rasvjete uzeta je visina od 5 metara jer se u propisima navodi da je rasvjeta od 30 W do 60 W na visini manjoj od 6 metara [20].

Senzori detektiraju kretanje na udaljenosti od 40 metara. Razlog uzimanja 40 metara kao udaljenosti je: prosječna brzina kretanja vozila u gradu je od 50 km/h (~14 m/s), nadalje uzeta je u obzir reakcija vozača na praćenje prometa od 2 s, što daje 28 metara udaljenost (prosječna je 1.5 s) i u obzir je još uzeto vrijeme kočenja što nadodaje još 10 metara [21].

Za senzore detekcije korištena je skripta prikazana na slici 5.1..

```
loop

dreadsensor x

# Ovo detektira ako je objekt u detekcijskom krugu

if ($x == 1)

        send 1 {sensor_id}

else

        send 0 {sensor_id}

end

delay 500
```

Sl. 5.1. Skripta (senzor_id.csc)

Kod prikazan na slici 5.1. predstavlja rad jednog senzora. Tako da, ako detektira objekt koji je u pokretu poslat će potvrdu (engl. *True*) ili „1“, u suprotnom negaciju (engl. *False*) ili „0“.

U ovoj simulaciji korišteno je 30 senzora. Pošto u programu nema lakšeg načina za pisanje više istih skripti u Pythonu je napravljena skripta koja će olakšati proces izrade (.csc dokumenata za svaki senzor [id]) jer će automatski napraviti 30 skripti (.csc dokument):

```
import os



# Funkcija koja generira svaki CSC dokument
```

```
def generate_csc_content(sensor_id):
    content = f"""loop
dreadsensor x
# Ovo detektira ako je objekt u detekcijskom krugu
if ($x == 1)
    # Ako je detektiran pošalji signal i upali svjetlo
    send 1 {sensor_id}
else
    # Ako nije detektiran nemoj paliti svjetlo
    send 0 {sensor_id}
end
delay 500
"""
    return content


# Pravi direktorij s csc dokumentima
output_directory = "csc_files"
os.makedirs(output_directory, exist_ok=True)


# Generira 30(id)CSC dokumenata
for sensor_id in range(1, 30):
    file_content = generate_csc_content(sensor_id)
    file_path = os.path.join(output_directory, f"sensor_{sensor_id}.csc")
    with open(file_path, "w") as file:
```

```
    file.write(file_content)



print(f"Generirano 30 CSC u '{output_directory}' directory.")
```

Sl. 5.2. Python kod (generator.py)

Na primjeru slike 5.2. prikazan je Python kod, koji omogućuje tu automatizaciju za izradu više različitih skripti.

Također potrebna je i skripta za samu rasvjetu koja kada primi signal sa senzora, koja uključuje svjetlo.

```
Loop
        wait
        read x
        if($x == 1)
                mark 1
                send 1
                PRINT „ON“
        else
                mark 0
                PRINT „OFF“
end
```

Sl. 5.3. Skripta (rasvjeta.csc)

Kod prikazan slikom 5.3. predstavlja rad rasvjete, koja kada primi vrijednost „1“ sa senzora, uključit će se svjetiljka. Odnosno kada se pošalje „0“ svjetiljka će se isključiti ili će ostati isključena sve dok ne dođe „1“

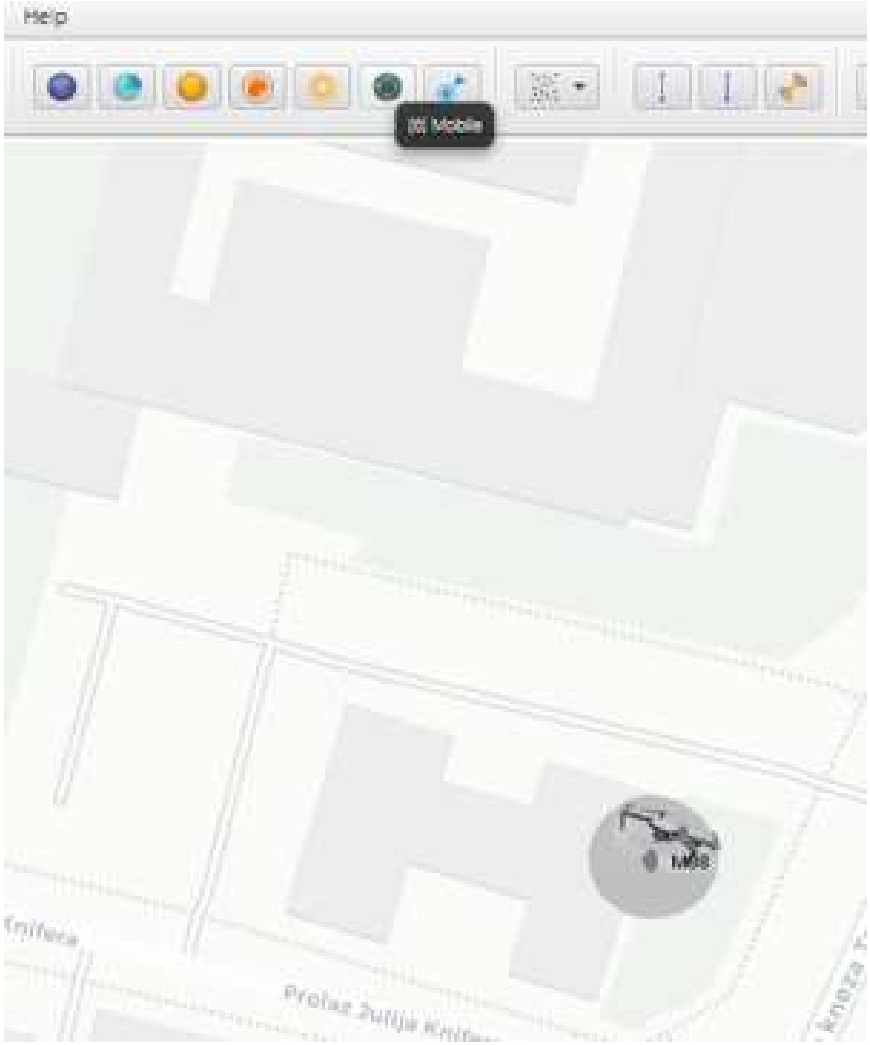

Sl. 5.4. Dodavanje Mobilne točke

Prije izrade simulacije potrebno je upoznati se s parametrima koji će biti ključni za samu izradu. Mobilna točka, koja će se kretati po zamišljenom rutom.

Klikom na „Mobile“ kao što je prikazano na slici 5.4., možemo kreirati mobilnu točku kojoj možemo dodati rutu kretanja prikazanoj na slici 5.8..

Rutu kretanja dodajemo markerom klikom na „Marker“ i proizvoljnim klikovima pravimo rutu prikazano slikom 5.5. Nakon što je markerom napravljena rutu moramo je i spremiti u rutu da ju Mobilna točka može pratiti. Prikaz dodavanja rute prikazan je na slici 5.7. Naknadno potrebno je na „Marker“ ruti dodati točke na koje će ta Mobilna točka „preskakati“, kao što je i prikazano na slici 5.6..

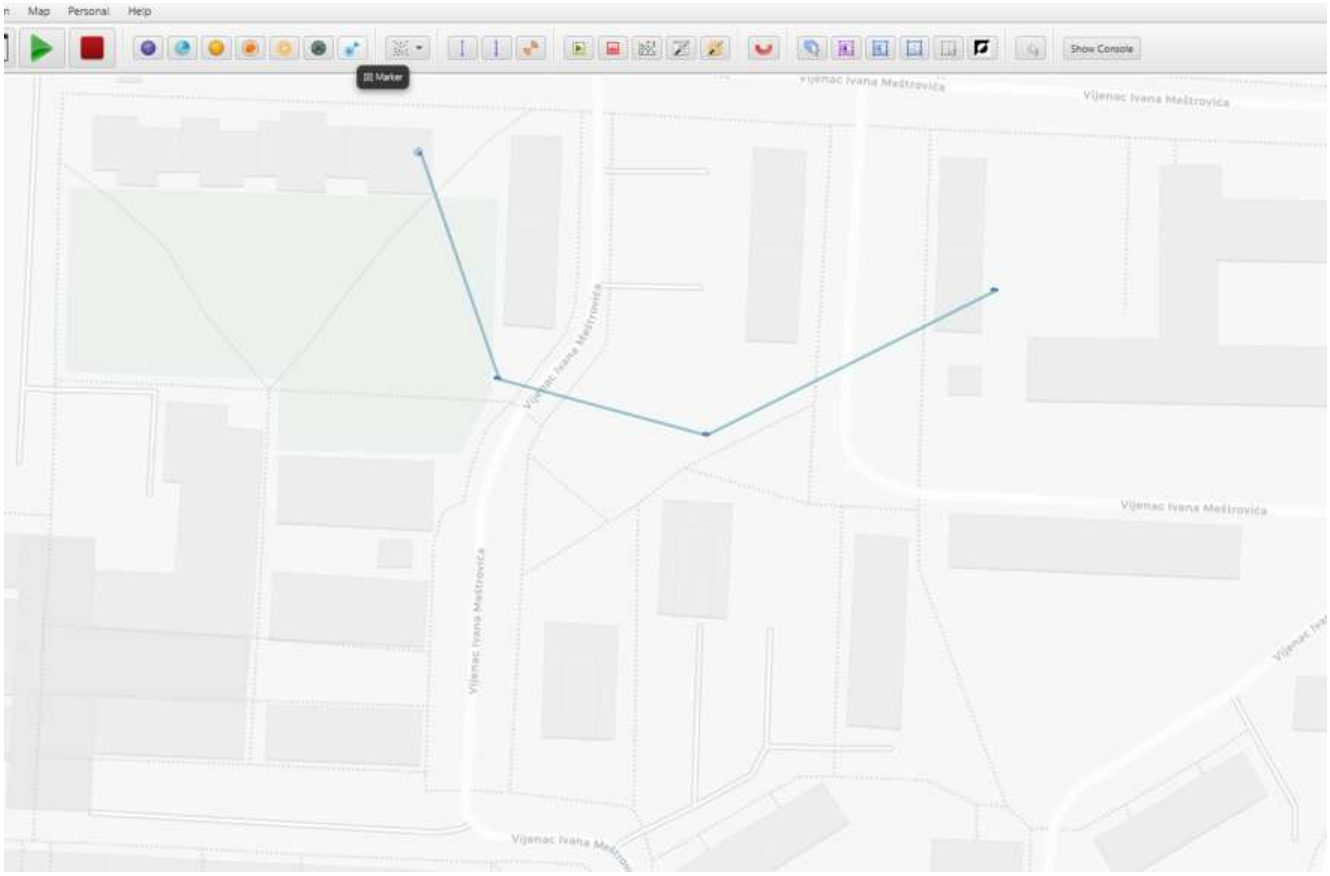

Sl. 5.5. Dodavanje markera

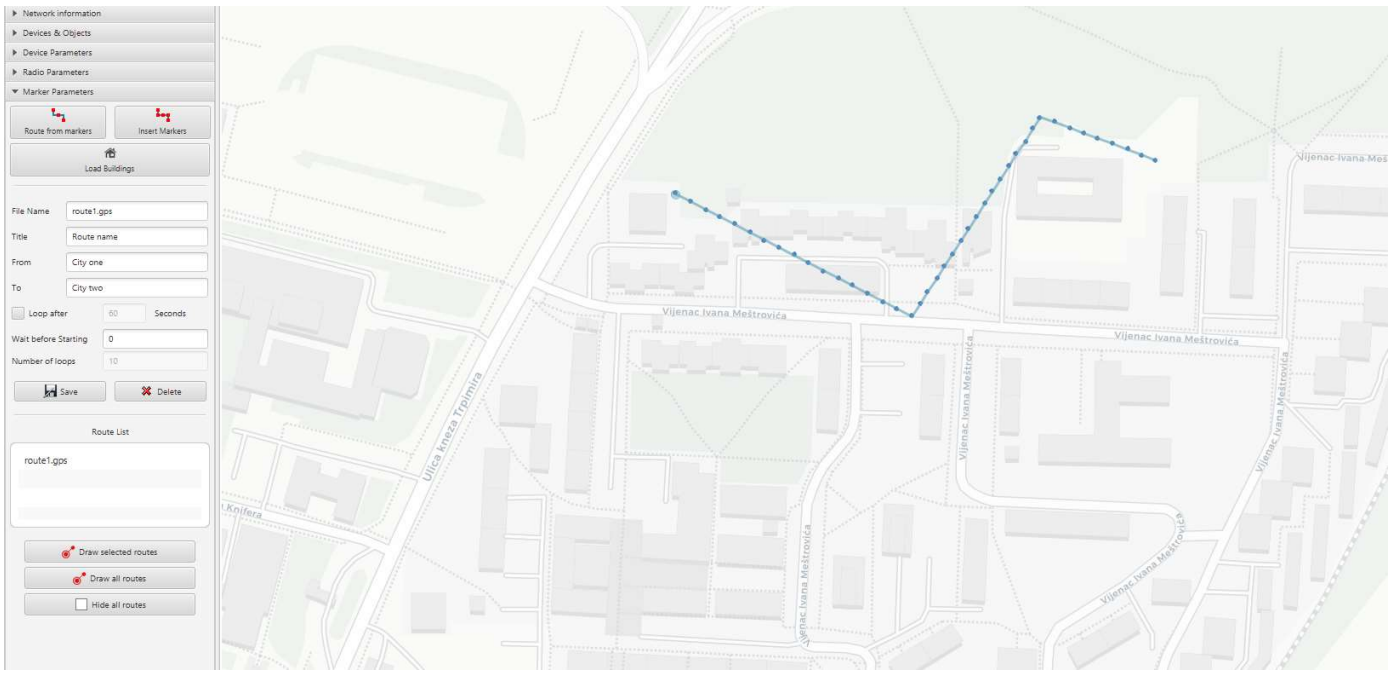

Sl. 5.6. Klikom na „Insert Markers“ dodaje točke za „skakanje“

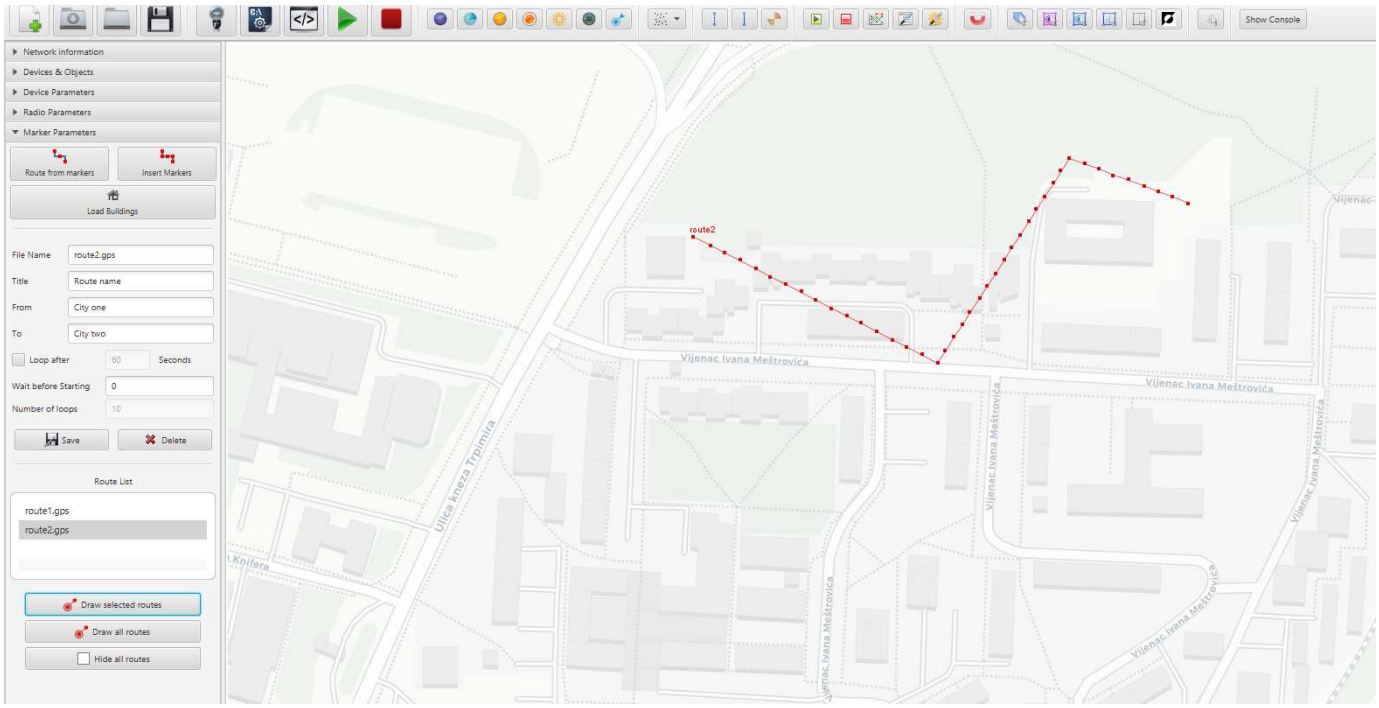

Sl. 5.7. Dodavanje rute

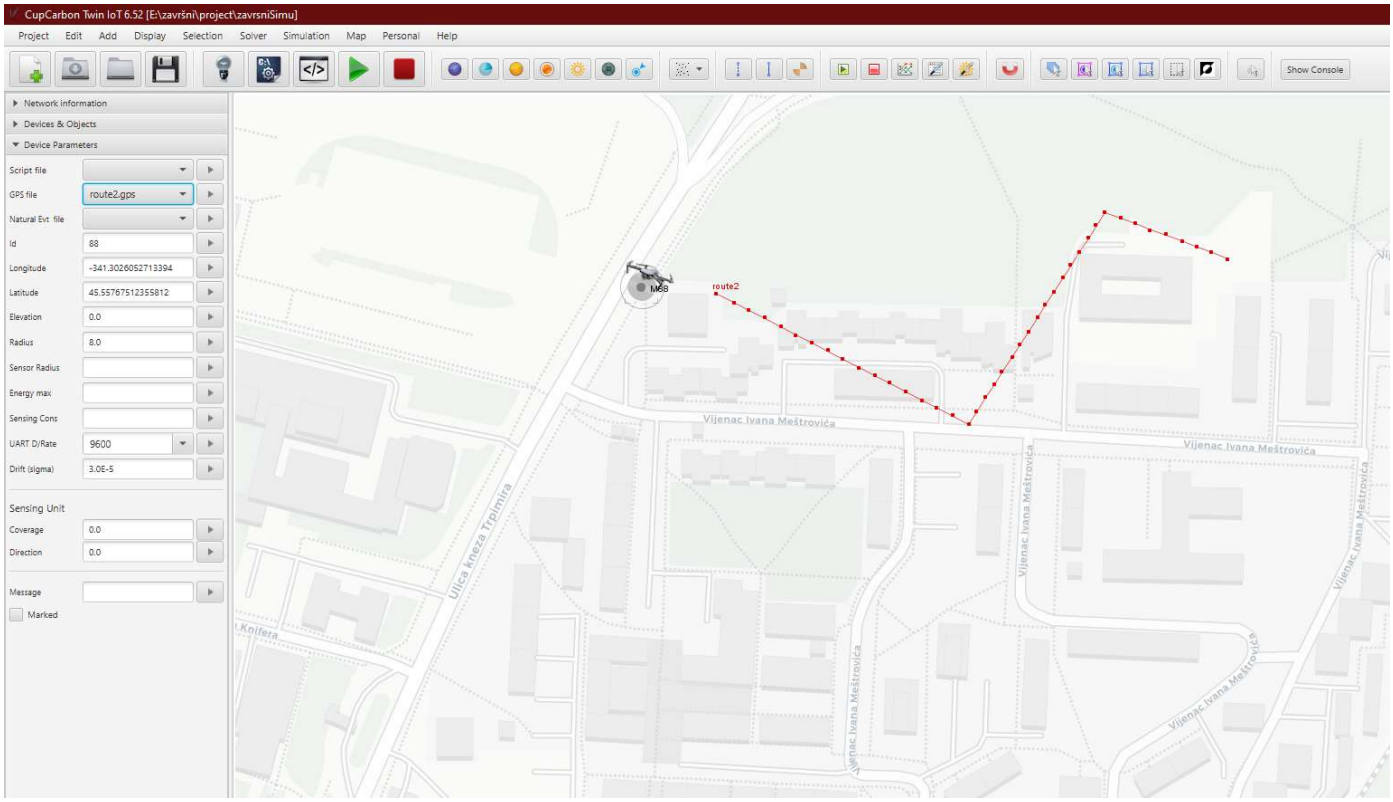

Sl. 5.8. Spremanje rute na Mobilnu točku

Sada kada je dodana ruta kojom će se kretati Mobilna točka, moramo dodati senzorske točke, imat ćemo dva tipa:

1. prvi tip je senzor za detekciju
2. drugi tip je senzor koji će služiti kao rasvjeta (svjetlo)

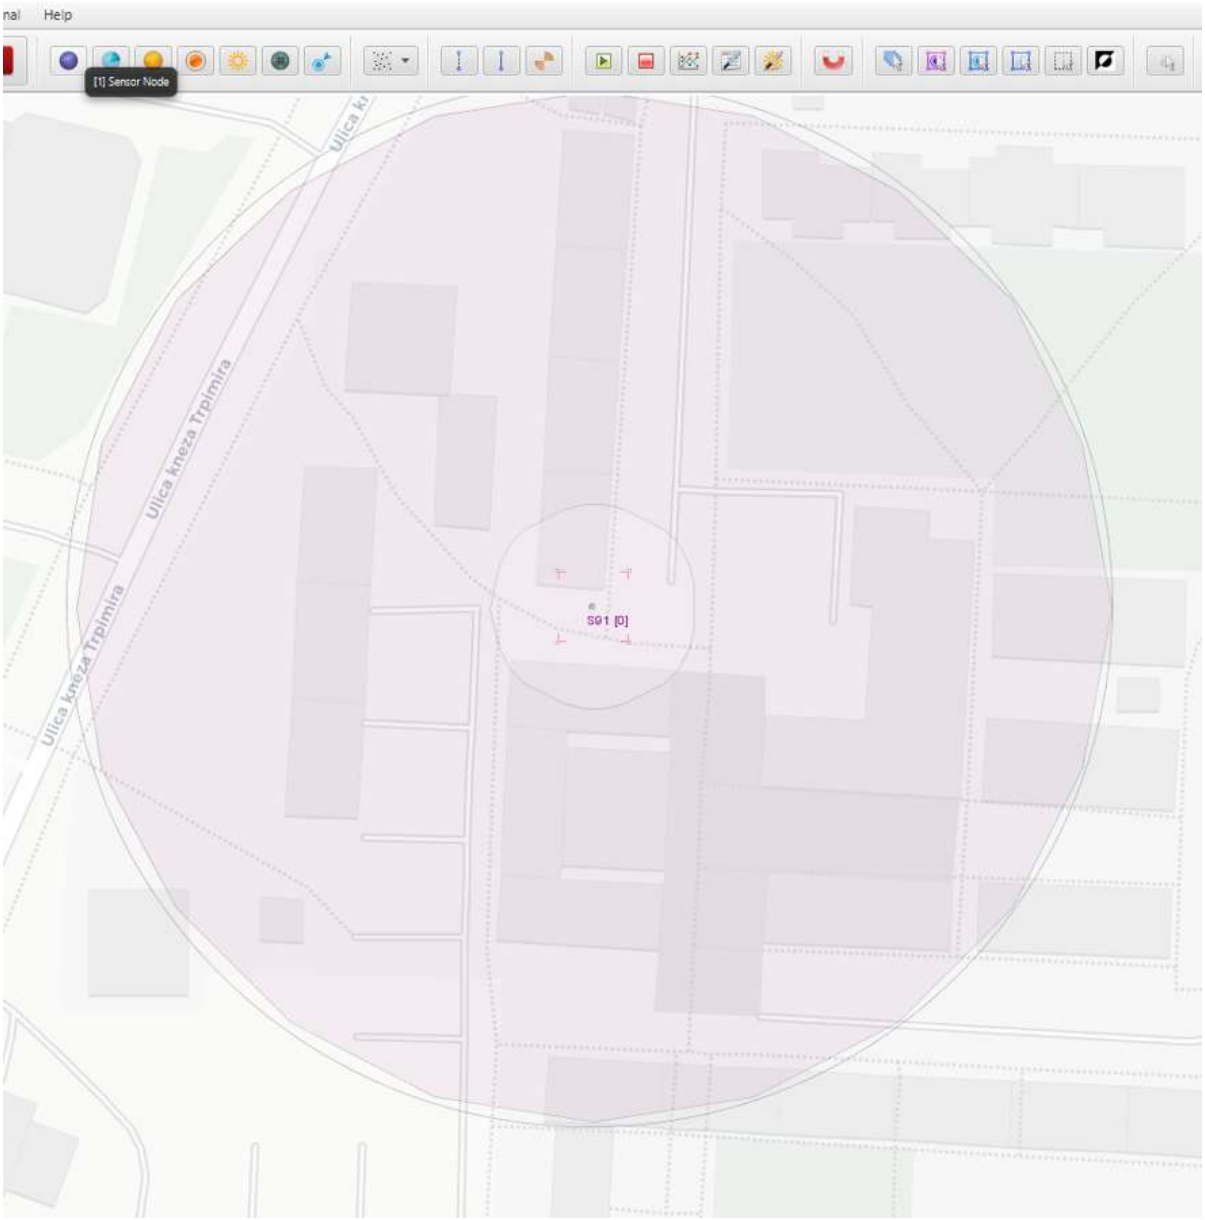

Sl. 5.9. Dodavanje senzora

Slika 5.9. predstavlja dodavanje senzora u simulaciju.

S91 – predstavlja Senzor i njegov identifikator (skr. id) u ovom slučaju Senzor – 91, što će biti od iznimne važnosti s obzirom na skriptu koju je napisana za senzor detekcije (senzor_id.csc) gdje id predstavlja br. 91.

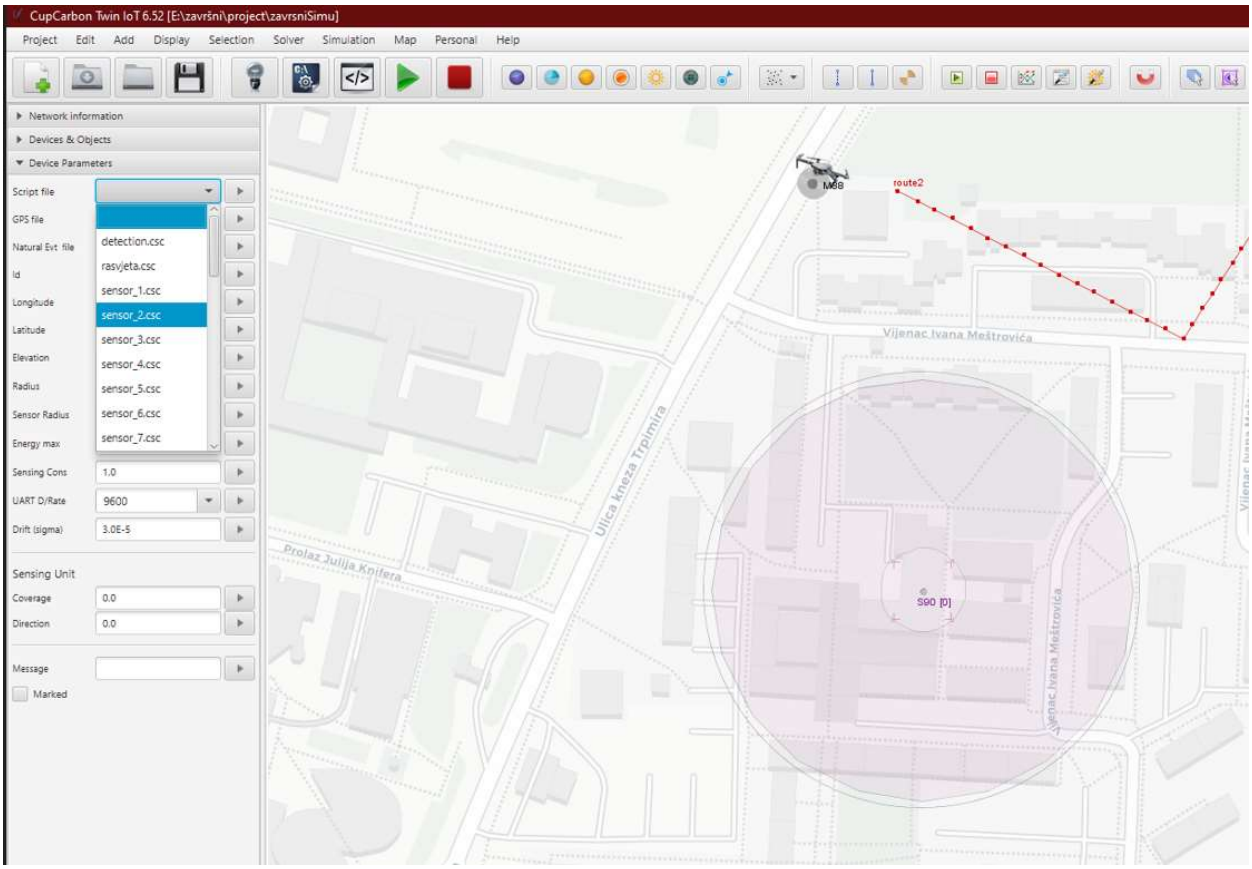

Sl. 5.10. Dodavanje skripte na senzor

Senzorima je potrebno dodijeliti određenu skriptu i dodijeliti im vlastiti id sukladno skripti. Slika 5.10. prikazuje dodjeljivanje skripte u senzor.

5.4. PRIKAZ RADA

U konačnici kada pratimo pravila, navedena ograničenja i dodamo sve senzore, rute i Mobilnu točku moguće je napraviti simulaciju oblika prikazanog na slici 5.11. koja prikazuje rutu za koju ćemo simulirati rasvjetu na 30 različitih, ali sličnih senzora i ulične rasvjete.

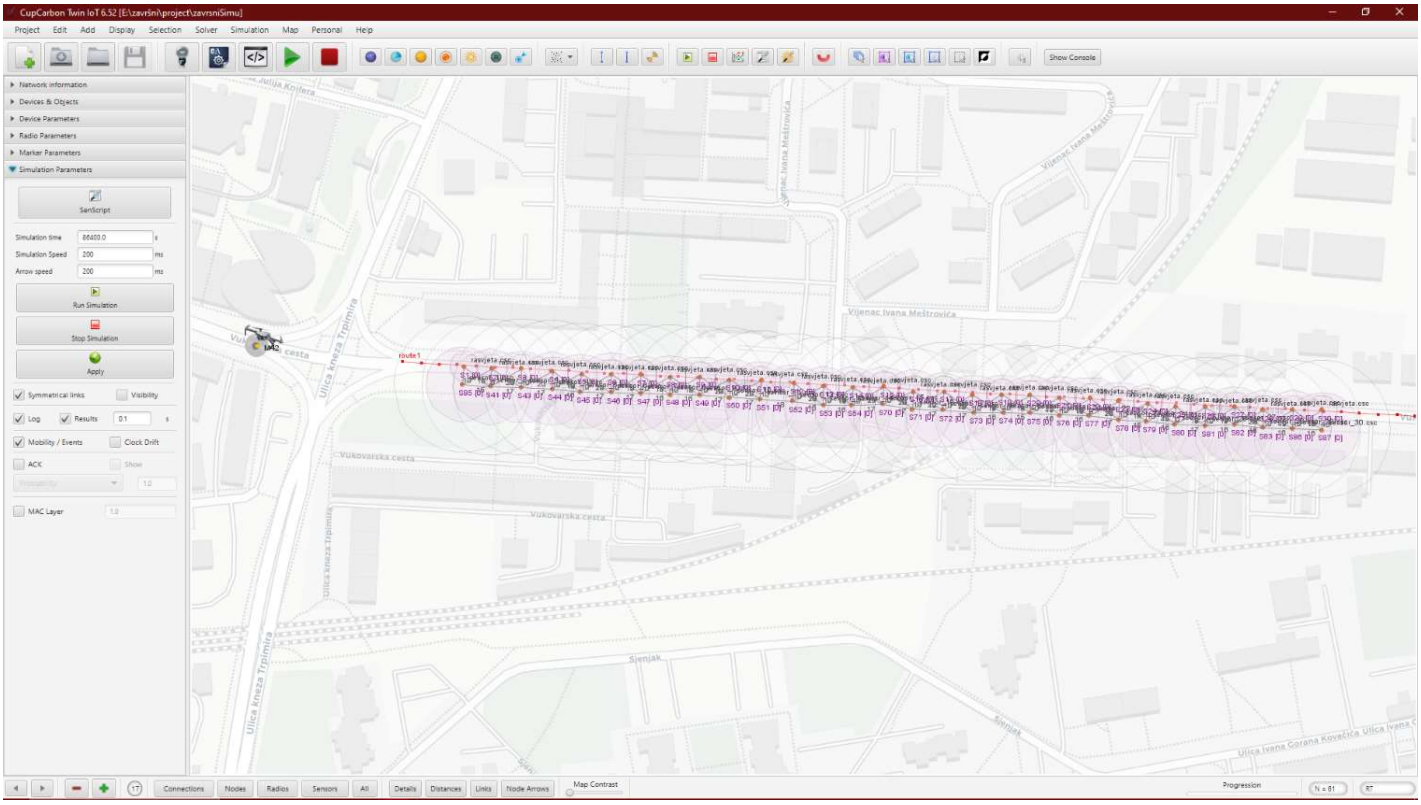

Sl. 5.11. Izgled gotove simulacije

Sada kada imamo sve parametre, potrebno je pokretanje te simulacije prikazano na slici 5.11., za pokretanje simulacije potrebno je kliknuti na *Simulation Parameters*, tu treba označiti *Log*, *Results* i *Mobility/Events* – da bi se omogućilo kretanje mobilne točke, spremila događanja kroz pokrenutu simulaciju i rezultate, koji je u ovom slučaju potrošnja energije na pojedinoj svjetiljci. Također, može se koristiti parametrima *Simulation Speed* za malo bržu obradu simulacije (u mili sekundama) i *Arrow Speed* to je brzina za slanje podataka sa senzora na senzor (u ovom slučaju sa senzora za detekciju na rasvjetu). Nakon što Mobilna točka „odveze“ svoju rutu potrebno je zaustaviti simulaciju klikom na gumb *Stop Simulation*.

Nakon što simulaciju zaustavimo moguće je vidjeti rezultate potrošnje energije na odabranom senzoru.

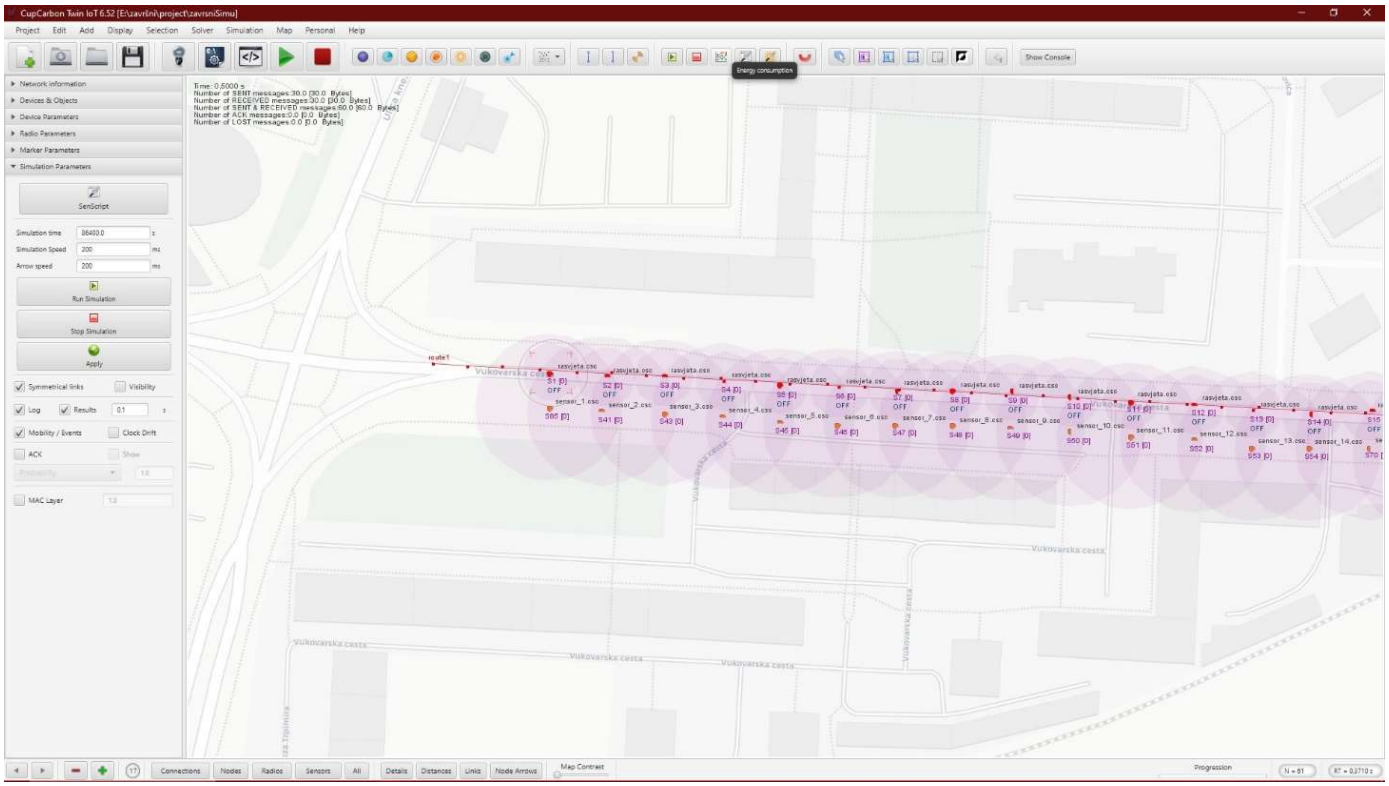

Sl. 5.12. Tipka za prikaz grafa energije

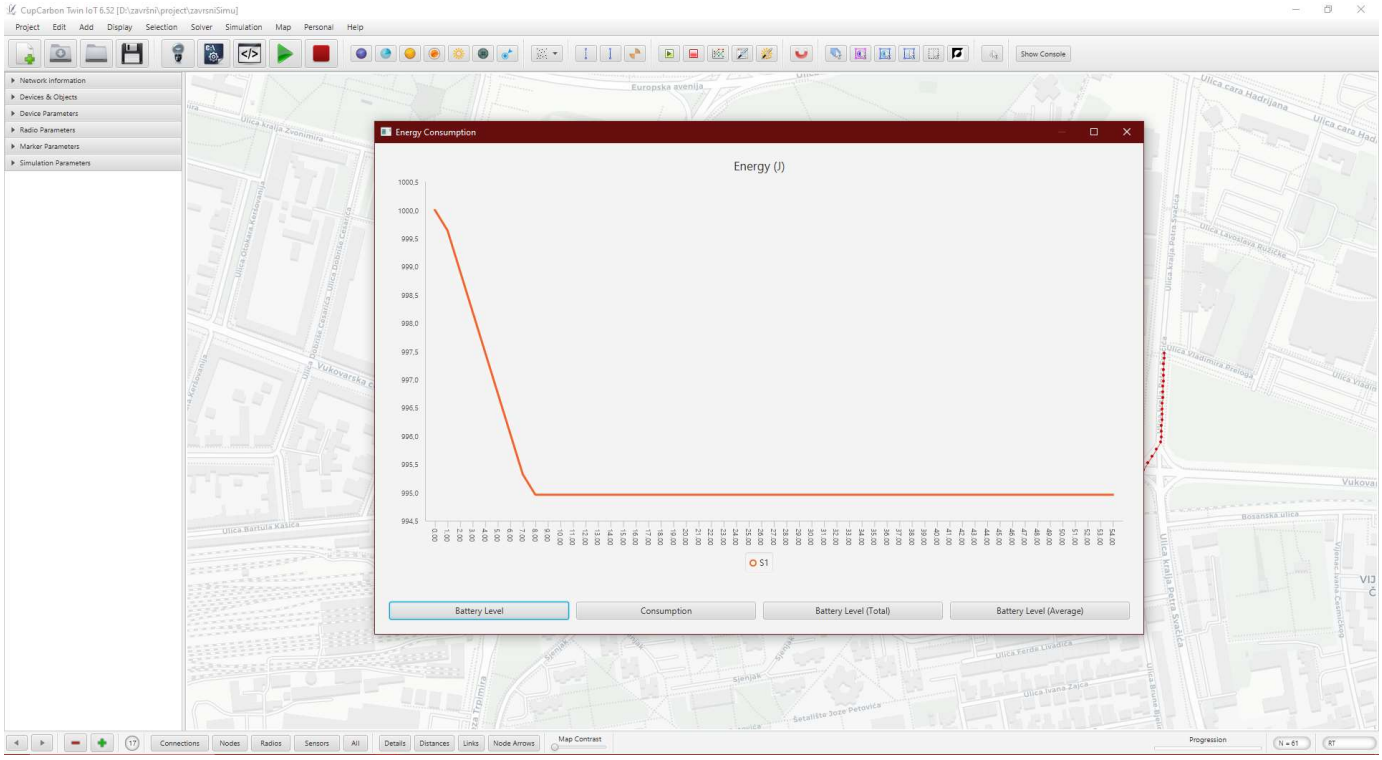

Sl. 5.13. Graf potrošnje energije nakon simulacije

Na primjeru slike 5.12. odabran je senzor pod id-em 1 (S1) i pritiskom na tipku *Energy consumption* dobiva se graf na slici 5.13. koji prikazuje potrošnju energije na S1 senzoru kroz simulaciju koja je trajala 55 sekundi.

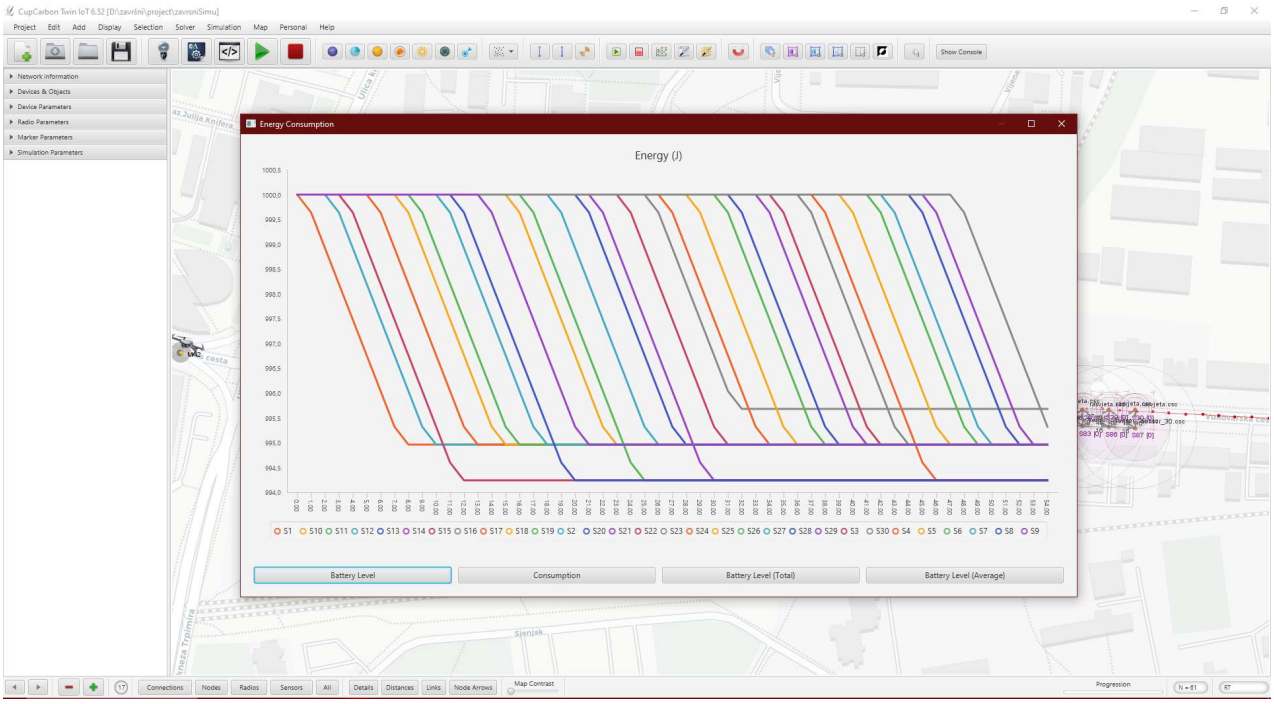

Sl. 5.14. Više senzora (tj. svjetala)

Slika 5.14. prikazuje izgled grafa kroz simulaciju u kojoj se koristi 30 senzora. Ono što se može primijetiti je kako rasvjeta funkcionira kada npr. neko vozilo prolazi pored senzora. Isto tako može se primijetiti kako je u jednom trenutku uključena i radi, a kasnije se isključuje kako prolazi kroz različite senzore (svjetlo). Također obrađena je i simulacija kod koje je rasvjeta konstantno uključena, odnosno kakvo je trenutno stanje na ulicama te se dobiva graf prikazan slikom 5.13. i 5.15..

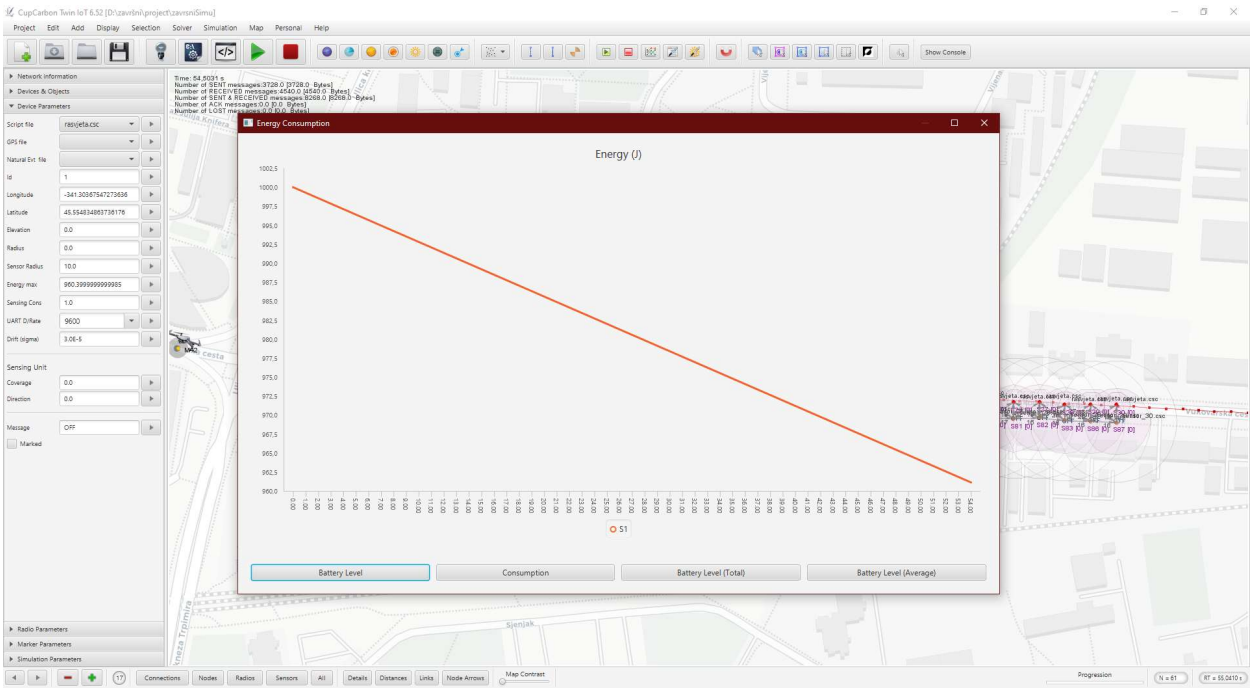

Sl. 5.15. Rasvjeta je konstantno upaljena

Ono što treba napomenuti je da graf koji je prikazan slikom 5.15., se odnosi samo na jedno svjetlo, dok na ulicama obično ima više svjetala (i samom gradu), što daje bolju predodžbu o ukupnoj potrošnji s obzirom na rasvjetu koja samo radi kad i dok detektira vozilo. Nakon što je odrađena simulaciju, program će spremiti podatke o svakoj rasvjeti i njenoj potrošnji kroz tok simulacije. Datoteka je „.csv“ oblika, te ju je potrebno otvoriti u programu Microsoft Excel, za prikaz rezultata. Datoteka se nalazi unutar projektne mape, mape *Results*. U ovom slučaju datoteku je bilo potrebno generirati dva puta, odnosno simulacija je morala biti pokrenuta dva puta jer je bilo potrebno napraviti usporedbu rada pametne rasvjete i tradicionalne, koja radi konstantno.

5.5. REZULTATI

Tablični oblik rezultata je uzet iz datoteke u formatu „.cvs“. Energetska potrošnja izražena je u džulima [J].

U radu korišteno je 30 različitih senzora, kao rezultat odabran je za prikaz 3 senzora (1, 15, 30) koja prikazuju potrošnju na temelju detekcije nadolazećeg vozila. Također prikazan je graf koji predstavlja tradicionalno rasvjetu odnosno svjetlo koje radi konstantno. Neovisno o senzoru odabran je samo jedan senzor, pošto svi rade kroz cijeli tok simulacije.

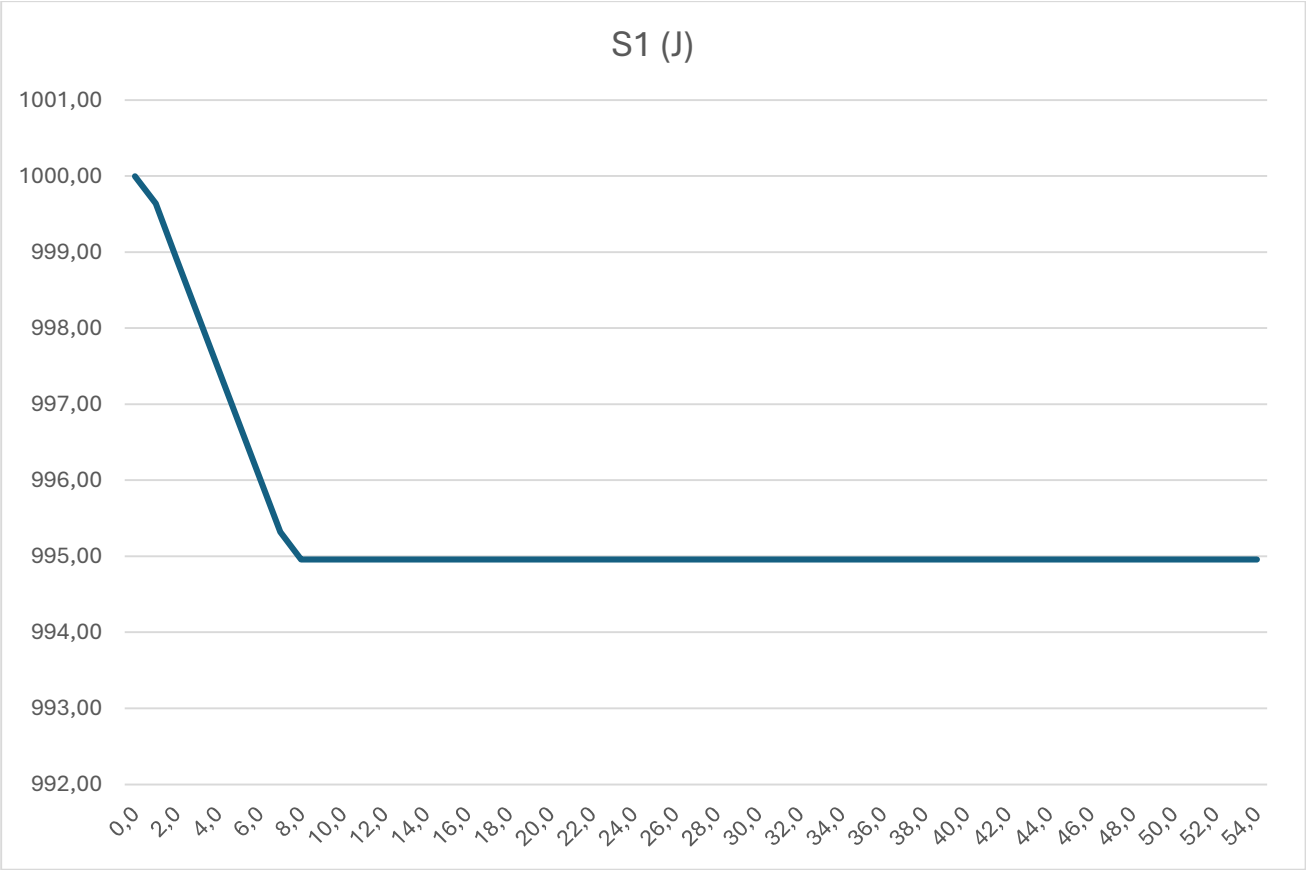

Sl. 5.16. Graf svjetiljke 1

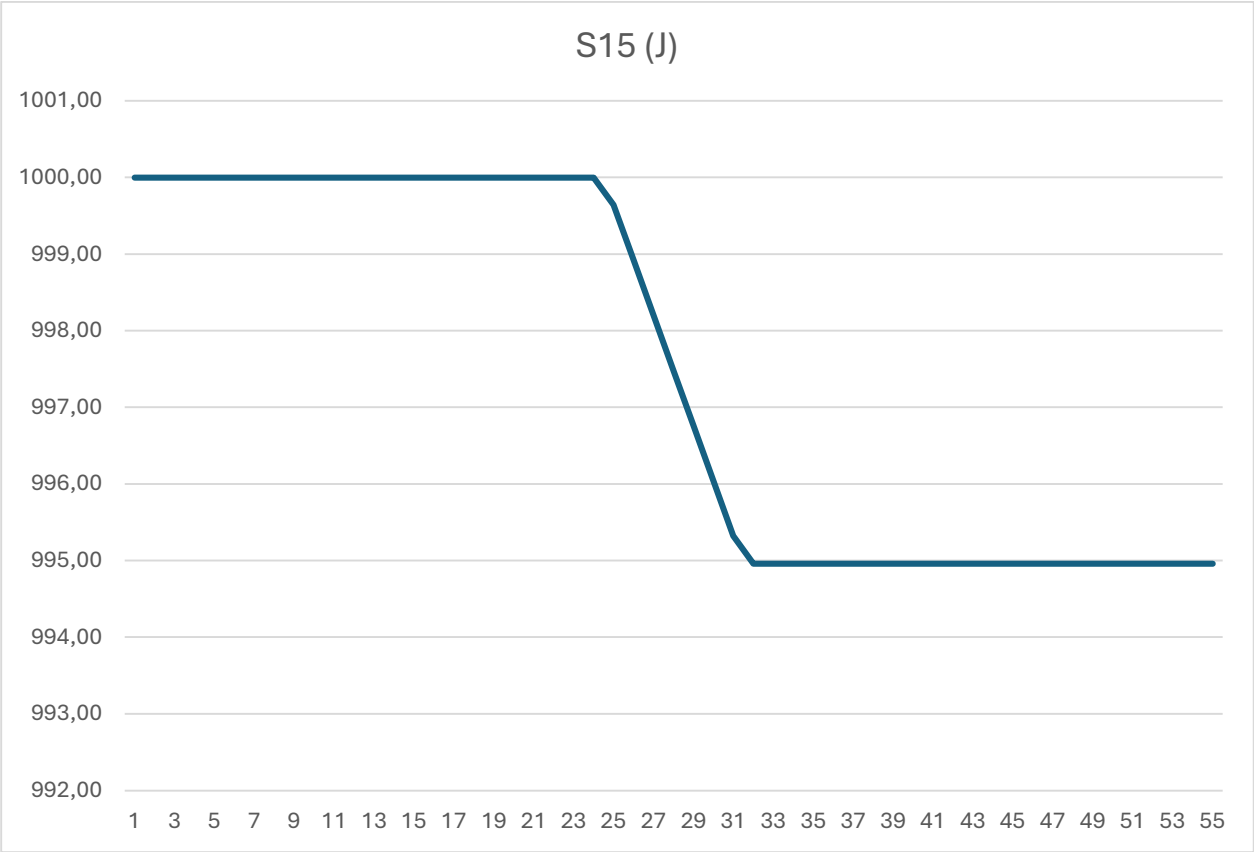

Sl. 5.17. Prikaz grafa svjetiljke 15

Grafovi prikazani na slikama 5.16. i 5.17. prikazuju potrošnju energije rasvjete. Ono što se uočava je to da svjetiljka na senzoru 15 nije radila prve 23 sekunde, onda je radila sljedećih 6 sekundi i onda se opet ugasila. Dok, svjetiljka na senzoru 1, radila je prvih 8 sekundi, i onda se ugasila do kraja simulacije.

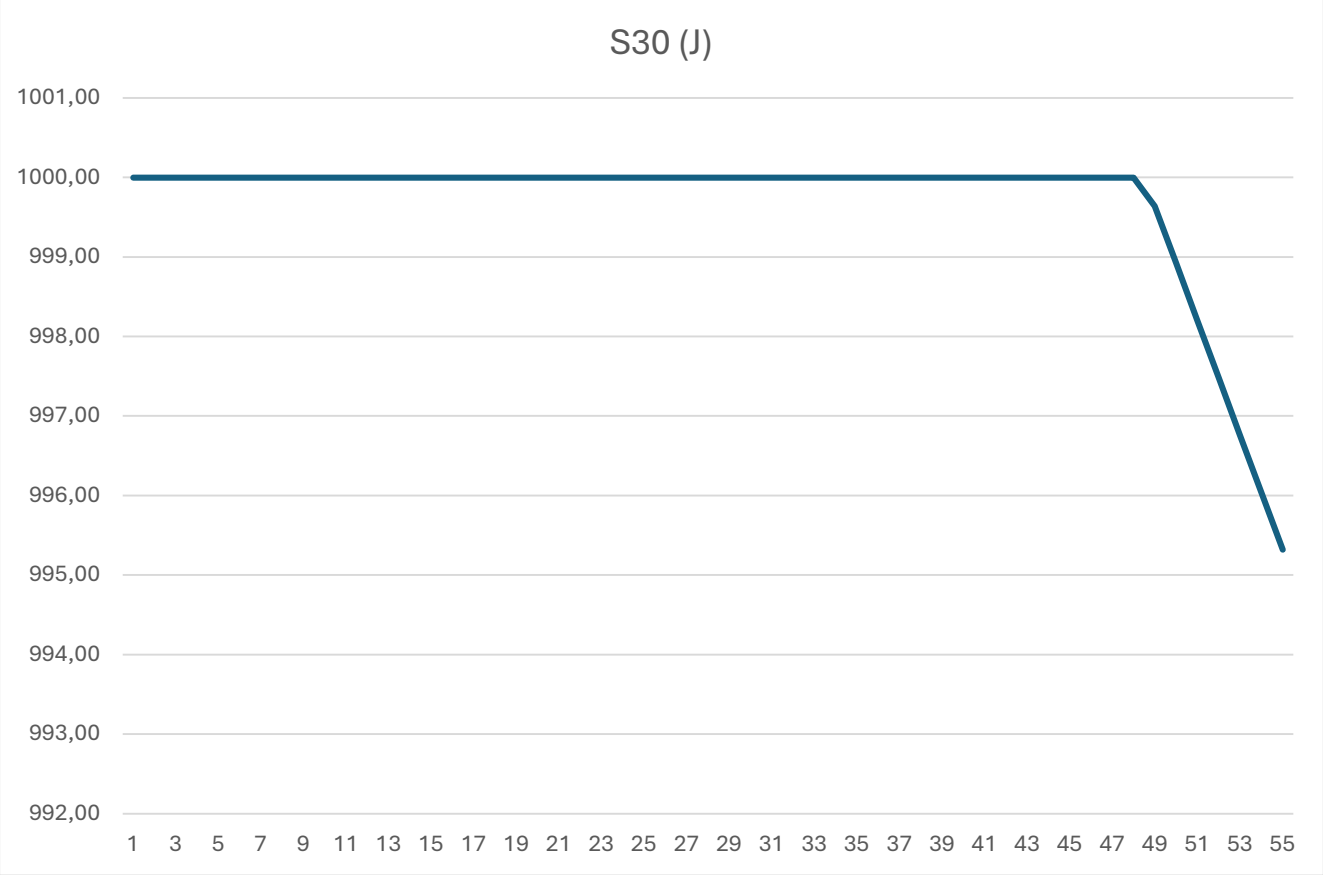

Sl. 5.18. Prikaz grafa svjetiljke 30

Graf prikazan primjerom slike 5.18. prikazuje potrošnju energije na zadnjoj svjetiljci unutar simulacije, moguće je primijetiti da svjetiljka skoro da i nije radila, sve do zadnjih par sekundi. To nam daje u način na koji ovaj sustav može funkcionirati na bazi jedne ulice, te kako bi mogao doprinijeti uštedi energije.

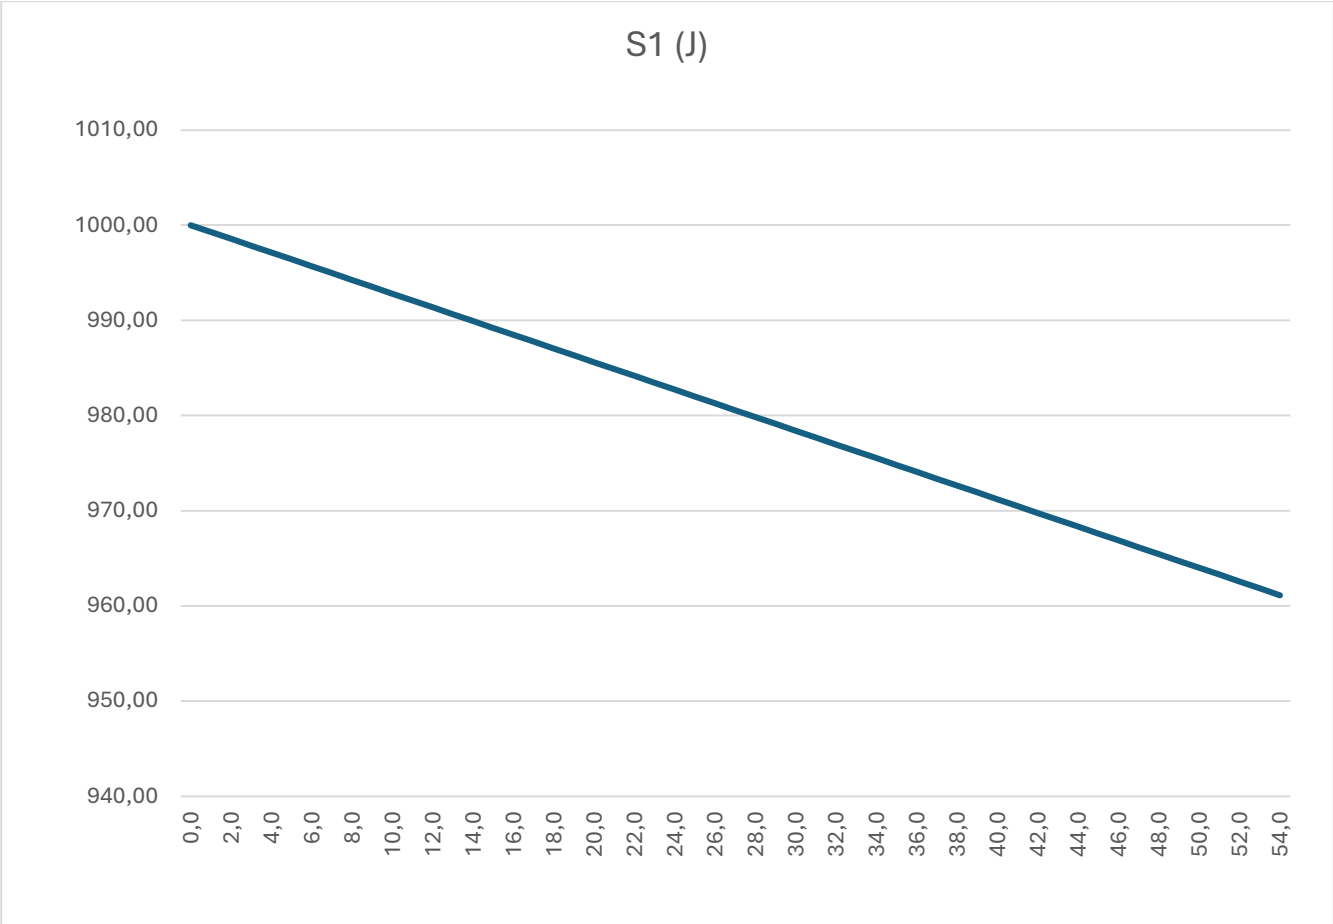

Sl. 5.19. Prikaz konstantno upaljene svjetiljke

Graf na slici 5.19. prikazuje potrošnju tradicionalne svjetiljke kroz tok simulacije, nije bilo potrebno prikazati 3 različita slučaja pošto svaka svjetiljka radi cijeli tok, pa su grafovi za svaku pojedinu svjetiljku isti. Ono što se može primijetiti, za razliku od prijašnjih grafova, je ta konstanta potrošnja energije.

Time (Sec)	S1 (J)	S2 (J)	S3 (J)	S14 (J)	S15 (J)	S16 (J)	S28 (J)	S29(J)	S30 (J)
0,0	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00
1,0	999,28	999,28	999,28	999,28	999,28	999,28	999,28	999,28	999,28
2,0	998,56	998,56	998,56	998,56	998,56	998,56	998,56	998,56	998,56
3,0	997,84	997,84	997,84	997,84	997,84	997,84	997,84	997,84	997,84
4,0	997,12	997,12	997,12	997,12	997,12	997,12	997,12	997,12	997,12
5,0	996,40	996,40	996,40	996,40	996,40	996,40	996,40	996,40	996,40
6,0	995,68	995,68	995,68	995,68	995,68	995,68	995,68	995,68	995,68
7,0	994,96	994,96	994,96	994,96	994,96	994,96	994,96	994,96	994,96
8,0	994,24	994,24	994,24	994,24	994,24	994,24	994,24	994,24	994,24
9,0	993,52	993,52	993,52	993,52	993,52	993,52	993,52	993,52	993,52
10,0	992,80	992,80	992,80	992,80	992,80	992,80	992,80	992,80	992,80
11,0	992,08	992,08	992,08	992,08	992,08	992,08	992,08	992,08	992,08
12,0	991,36	991,36	991,36	991,36	991,36	991,36	991,36	991,36	991,36
13,0	990,64	990,64	990,64	990,64	990,64	990,64	990,64	990,64	990,64
14,0	989,92	989,92	989,92	989,92	989,92	989,92	989,92	989,92	989,92
15,0	989,20	989,20	989,20	989,20	989,20	989,20	989,20	989,20	989,20
16,0	988,48	988,48	988,48	988,48	988,48	988,48	988,48	988,48	988,48
17,0	987,76	987,76	987,76	987,76	987,76	987,76	987,76	987,76	987,76
18,0	987,04	987,04	987,04	987,04	987,04	987,04	987,04	987,04	987,04
19,0	986,32	986,32	986,32	986,32	986,32	986,32	986,32	986,32	986,32
20,0	985,60	985,60	985,60	985,60	985,60	985,60	985,60	985,60	985,60
21,0	984,88	984,88	984,88	984,88	984,88	984,88	984,88	984,88	984,88
22,0	984,16	984,16	984,16	984,16	984,16	984,16	984,16	984,16	984,16
23,0	983,44	983,44	983,44	983,44	983,44	983,44	983,44	983,44	983,44
24,0	982,72	982,72	982,72	982,72	982,72	982,72	982,72	982,72	982,72
25,0	982,00	982,00	982,00	982,00	982,00	982,00	982,00	982,00	982,00
26,0	981,28	981,28	981,28	981,28	981,28	981,28	981,28	981,28	981,28
27,0	980,56	980,56	980,56	980,56	980,56	980,56	980,56	980,56	980,56
28,0	979,84	979,84	979,84	979,84	979,84	979,84	979,84	979,84	979,84
29,0	979,12	979,12	979,12	979,12	979,12	979,12	979,12	979,12	979,12
30,0	978,40	978,40	978,40	978,40	978,40	978,40	978,40	978,40	978,40
31,0	977,68	977,68	977,68	977,68	977,68	977,68	977,68	977,68	977,68
32,0	976,96	976,96	976,96	976,96	976,96	976,96	976,96	976,96	976,96
33,0	976,24	976,24	976,24	976,24	976,24	976,24	976,24	976,24	976,24
34,0	975,52	975,52	975,52	975,52	975,52	975,52	975,52	975,52	975,52
35,0	974,80	974,80	974,80	974,80	974,80	974,80	974,80	974,80	974,80
36,0	974,08	974,08	974,08	974,08	974,08	974,08	974,08	974,08	974,08
37,0	973,36	973,36	973,36	973,36	973,36	973,36	973,36	973,36	973,36
38,0	972,64	972,64	972,64	972,64	972,64	972,64	972,64	972,64	972,64
39,0	971,92	971,92	971,92	971,92	971,92	971,92	971,92	971,92	971,92
40,0	971,20	971,20	971,20	971,20	971,20	971,20	971,20	971,20	971,20
41,0	970,48	970,48	970,48	970,48	970,48	970,48	970,48	970,48	970,48
42,0	969,76	969,76	969,76	969,76	969,76	969,76	969,76	969,76	969,76

43,0	969,04	969,04	969,04	969,04	969,04	969,04	969,04	969,04	969,04
44,0	968,32	968,32	968,32	968,32	968,32	968,32	968,32	968,32	968,32
45,0	967,60	967,60	967,60	967,60	967,60	967,60	967,60	967,60	967,60
46,0	966,88	966,88	966,88	966,88	966,88	966,88	966,88	966,88	966,88
47,0	966,16	966,16	966,16	966,16	966,16	966,16	966,16	966,16	966,16
48,0	965,44	965,44	965,44	965,44	965,44	965,44	965,44	965,44	965,44
49,0	964,72	964,72	964,72	964,72	964,72	964,72	964,72	964,72	964,72
50,0	964,00	964,00	964,00	964,00	964,00	964,00	964,00	964,00	964,00
51,0	963,28	963,28	963,28	963,28	963,28	963,28	963,28	963,28	963,28
52,0	962,56	962,56	962,56	962,56	962,56	962,56	962,56	962,56	962,56
53,0	961,84	961,84	961,84	961,84	961,84	961,84	961,84	961,84	961,84
54,0	961,12	961,12	961,12	961,12	961,12	961,12	961,12	961,12	961,12

Tablica 5.1. Prikaz tradicionalne rasvjete

Time (Sec)	S1 (J)	S2 (J)	S3 (J)	S14 (J)	S15 (J)	S16 (J)	S28 (J)	S29(J)	S30 (J)
0,0	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00
1,0	999,64	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00
2,0	998,92	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00
3,0	998,20	999,64	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00
4,0	997,48	998,92	999,64	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00
5,0	996,76	998,20	998,92	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00
6,0	996,04	997,48	998,20	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00
7,0	995,32	996,76	997,48	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00
8,0	994,96	996,04	996,76	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00
9,0	994,96	995,32	996,04	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00
10,0	994,96	994,96	995,32	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00
11,0	994,96	994,96	994,60	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00
12,0	994,96	994,96	994,24	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00
13,0	994,96	994,96	994,24	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00
14,0	994,96	994,96	994,24	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00
15,0	994,96	994,96	994,24	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00
16,0	994,96	994,96	994,24	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00
17,0	994,96	994,96	994,24	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00
18,0	994,96	994,96	994,24	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00
19,0	994,96	994,96	994,24	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00
20,0	994,96	994,96	994,24	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00
21,0	994,96	994,96	994,24	1000,00	1000,00	1000,00	1000,00	1000,00	1000,00
22,0	994,96	994,96	994,24	999,64	1000,00	1000,00	1000,00	1000,00	1000,00
23,0	994,96	994,96	994,24	998,92	1000,00	1000,00	1000,00	1000,00	1000,00
24,0	994,96	994,96	994,24	998,20	999,64	1000,00	1000,00	1000,00	1000,00
25,0	994,96	994,96	994,24	997,48	998,92	1000,00	1000,00	1000,00	1000,00
26,0	994,96	994,96	994,24	996,76	998,20	999,64	1000,00	1000,00	1000,00

27,0	994,96	994,96	994,24	996,04	997,48	998,92	1000,00	1000,00	1000,00
28,0	994,96	994,96	994,24	995,32	996,76	998,20	1000,00	1000,00	1000,00
29,0	994,96	994,96	994,24	994,60	996,04	997,48	1000,00	1000,00	1000,00
30,0	994,96	994,96	994,24	994,24	995,32	996,76	1000,00	1000,00	1000,00
31,0	994,96	994,96	994,24	994,24	994,96	996,04	1000,00	1000,00	1000,00
32,0	994,96	994,96	994,24	994,24	994,96	995,68	1000,00	1000,00	1000,00
33,0	994,96	994,96	994,24	994,24	994,96	995,68	1000,00	1000,00	1000,00
34,0	994,96	994,96	994,24	994,24	994,96	995,68	1000,00	1000,00	1000,00
35,0	994,96	994,96	994,24	994,24	994,96	995,68	1000,00	1000,00	1000,00
36,0	994,96	994,96	994,24	994,24	994,96	995,68	1000,00	1000,00	1000,00
37,0	994,96	994,96	994,24	994,24	994,96	995,68	1000,00	1000,00	1000,00
38,0	994,96	994,96	994,24	994,24	994,96	995,68	1000,00	1000,00	1000,00
39,0	994,96	994,96	994,24	994,24	994,96	995,68	1000,00	1000,00	1000,00
40,0	994,96	994,96	994,24	994,24	994,96	995,68	1000,00	1000,00	1000,00
41,0	994,96	994,96	994,24	994,24	994,96	995,68	1000,00	1000,00	1000,00
42,0	994,96	994,96	994,24	994,24	994,96	995,68	1000,00	1000,00	1000,00
43,0	994,96	994,96	994,24	994,24	994,96	995,68	1000,00	1000,00	1000,00
44,0	994,96	994,96	994,24	994,24	994,96	995,68	1000,00	1000,00	1000,00
45,0	994,96	994,96	994,24	994,24	994,96	995,68	999,64	1000,00	1000,00
46,0	994,96	994,96	994,24	994,24	994,96	995,68	998,92	999,64	1000,00
47,0	994,96	994,96	994,24	994,24	994,96	995,68	998,20	998,92	1000,00
48,0	994,96	994,96	994,24	994,24	994,96	995,68	997,48	998,20	999,64
49,0	994,96	994,96	994,24	994,24	994,96	995,68	996,76	997,48	998,92
50,0	994,96	994,96	994,24	994,24	994,96	995,68	996,04	996,76	998,20
51,0	994,96	994,96	994,24	994,24	994,96	995,68	995,32	996,04	997,48
52,0	994,96	994,96	994,24	994,24	994,96	995,68	994,96	995,32	996,76
53,0	994,96	994,96	994,24	994,24	994,96	995,68	994,96	994,96	996,04
54,0	994,96	994,96	994,24	994,24	994,96	995,68	994,96	994,96	995,32

Tablica 5.2. Prikaz rasvjete s detekcijom

Tablica 5.1. i 5.2. prikazuju energetsku potrošnju na 9 senzora (prva, srednja i zadnja tri). U tablici 5.1. uočen je stalni pad energije, što pokazuje na konstantnu potrošnju energije. Suprotno tome, tablica 5.2. prikazuje ponašanje pametne rasvjete: energija opada do određenog trenutka, nakon čega prestaje padati, što znači da se svjetlo u tom trenutku isključuje, a potrošnja energije zaustavlja.

Na kraju simulacijskog postupka, vrijednosti pokazuju značajno nižu potrošnju energije kod pametne rasvjete u usporedbi s tradicionalnom. To potvrđuje učinkovitost pametnih sustava u optimizaciji energetske potrošnje, smanjujući nepotrebno osvjetljenje kada nije potrebno, dok tradicionalni sustavi nastavljaju trošiti energiju tijekom cijelog razdoblja.

6. ZAKLJUČAK

U ovom završnom radu postavljeni su ciljevi istraživanje ključnih razlika između pametne i tradicionalne ulične rasvjete, uz detaljnu analizu prednosti koje donosi primjena takvih sustava. Rad uključuje prikaz pametne ulične rasvjete kroz simulaciju korištenjem CupCarbon programa. Glavni cilj bio je prikazati energetsku učinkovitost takvog sustava naspram tradicionalnog. Implementacije pametne ulične rasvjete predstavlja korak prema održivijem i ekonomičnijem upravljanju resursima. Kroz simulaciju i analizu, rad prikazuje kako ovakvi sustavi mogu doprinijeti boljoj energetskoj učinkovitosti.

Zaključno, ovaj rad naglašava mogućnosti pametne ulične rasvjete, ne samo u kontekstu energetske uštede, već i kao dio šireg trenda digitalizacije urbanih i ruralnih sredina, pružajući uvid u moguće uštede kroz analizu potrošnje.

LITERATURA

[1] „Cities: Urbanization and Rising Energy Demand“ [online]. Dostupno na: https://studentenergy.org/other/cities-urbanization/. [Pristupljeno: 16.9.2024.].

[2] „SML3-How Smart Lighting Saves The Environment - IEEE Smart Lighting“ [online]. Dostupno na: https://smartlighting.ieee.org/topics-ai/sml3-how-smart-lighting-saves-the-environment. [Pristupljeno: 16.9.2024.].

[3] Promo, „Zamjena zastarjele rasvjete može uštedjeti Hrvatskoj 25 milijuna eura svake godine“ [online], 12-svi-2021.

[4] G., Colclough, L., Peeters, C., Protopapadaki, J., Borsboom, „Smart lighting in cities“.

[5] K. H., Bachanek, B., Tundys, T., Wiśniewski, E., Puzio, A., Maroušková, „Intelligent Street Lighting in a Smart City Concepts—A Direction to Energy Saving in Cities: An Overview and Case Study“, *Energies*, izd. 11, sv. 14, str. 3018, sij. 2021.

[6] „Smart Lighting System for Efficient Street Lighting“ [online]. Dostupno na: https://www.uwu.ac.lk/wp-content/uploads/2020/Chapter-3-JTVA-v2-i1.pdf. [Pristupljeno: 14.9.2024.].

[7] „Check the information on Barcelona’s car parks in smou | SMOU“ [online]. Dostupno na: https://www.smou.cat/en/news/parking-spaces-availability. [Pristupljeno: 17.9.2024.].

[8] „Noise pollution is one of the biggest health risks in city life | Research and Innovation“ [online], 24-svi-2018. Dostupno na: https://projects.research-and-innovation.ec.europa.eu/en/horizon-magazine/noise-pollution-one-biggest-health-risks-city-life. [Pristupljeno: 14.9.2024.].

[9] United Nations, „World population projected to reach 9.8 billion in 2050, and 11.2 billion in 2100“ [online], United Nations, Dostupno na: https://www.un.org/en/desa/world-population-projected-reach-98-billion-2050-and-112-billion-2100. [Pristupljeno: 14.9.2024.].

[10] „G8 Hokkaido Toyako Summit Leaders Declaration“ [online]. Dostupno na: https://www.mofa.go.jp/policy/economy/summit/2008/doc/doc080714__en.html. [Pristupljeno: 14.9.2024.].

[11] „Smart cities - European Commission“ [online]. Dostupno na: https://commission.europa.eu/eu-regional-and-urban-development/topics/cities-and-urban-development/city-initiatives/smart-cities_en. [Pristupljeno: 14.9.2024.].

[12] „From pioneer to leader: deployment of smart LED-based street lighting in Los Angeles“ [online]. Dostupno na: https://iclei.org/e-library/from-pioneer-to-leader-deployment-of-smart-led-based-street-lighting-in-los-angeles/. [Pristupljeno: 16.9.2024.].

[13] Leadsun, „Why solar street lights should be used in rural and regional areas“ [online], 03-velj-2022. Dostupno na: https://leadsun.com.au/why-solar-street-lights-should-be-used-in-rural-and-regional-areas/. [Pristupljeno: 16.9.2024.].

[14] „Data protection in the EU - European Commission“ [online], 25-srp-2024. Dostupno na: https://commission.europa.eu/law/law-topic/data-protection/data-protection-eu_en. [Pristupljeno: 14.9.2024.].

[15] „CupCarbon Digital Twin IoT“ [online]. Dostupno na: http://cupcarbon.com/. [Pristupljeno: 14.9.2024.].

[16] B., Ahcène, „cupcarbon_user_guide“.

[17] „SenScript“ [online]. Dostupno na: https://cupcarbon.com/SenScript.html. [Pristupljeno: 14.9.2024.].

[18] „What is Python? Executive Summary“ [online]. Dostupno na: https://www.python.org/doc/essays/blurb/?external_link=true. [Pristupljeno: 14.9.2024.].

[19] Narodne novine d.d., „Pravilnik o zonama rasvijetljenosti, dopuštenim vrijednostima rasvjetljavanja i načinima upravljanja rasvjetnim sustavima“, u *Ministarstvo gospodarstva i održivog razvoja*, 2020, str. 2442.

[20] „Koja je prava visina i razmak stupova led ulične rasvjete?“ [online], 23-velj-2023. Dostupno na: https://hr.ekilhs.com/right-height-spacing-led-street-light-posts.html. [Pristupljeno: 14.9.2024.].
[21] „Study measures how fast humans react to road hazards“ [online], 07-kol-2019. Dostupno na: https://news.mit.edu/2019/how-fast-humans-react-car-hazards-0807. [Pristupljeno: 14.9.2024.].

SAŽETAK

Naslov: *Ušteda energije uz primjenu inteligentne ulične rasvjete*

Ovaj rad predstavio je jedan on načina implementacije pametne ulične rasvjete kroz primjenu senzora za detekciju. U radu se koristilo simulacijskim programom CupCarbon. Cilj je bio prikazati rezultate takve rasvjete u usporedbi s tradicionalnom. Analizirana je energetska učinkovitost takvih sustava.

Ključne riječi: *Ušteda energije, pametna rasvjeta, CupCarbon, inteligentna ulična rasvjeta*

ABSTRACT

***Tittle**: Energy saving with the application of intelligent street lighting*

This paper presented one of the ways to implement smart street lighting through the application of detection sensors. The CupCarbon simulation program was used in the paper. The goal was to demonstrate the results of such lighting in comparison with traditional lighting. The energy efficiency of such system was analyzed.

***Keywords**: Energy savings, smart lighting, CupCarbon, intelligent street lighting*