Mjerenje i analiza korištenja podatkovnih usluga i prometa u LTE mobilnoj mreži

Deak, Ema

Master's thesis / Diplomski rad

2017

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Transport and Traffic Sciences / Sveučilište u Zagrebu, Fakultet prometnih znanosti**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:119:121519

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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



Repository / Repozitorij:

Faculty of Transport and Traffic Sciences - Institutional Repository







SVEUČILIŠTE U ZAGREBU

FAKULTET PROMETNIH ZNANOSTI

Ema Deak

MJERENJE I ANALIZA KORIŠTENJA PODATKOVNIH USLUGA I PROMETA U LTE MOBILNOJ MREŽI

DIPLOMSKI RAD

Zagreb, 2017.

SVEUČILIŠTE U ZAGREBU

FAKULTET PROMETNIH ZNANOSTI

DIPLOMSKI RAD

MJERENJE I ANALIZA KORIŠTENJA PODATKOVNIH USLUGA I PROMETA U LTE MOBILNOJ MREŽI

MEASURING AND ANALYSIS MOBILE DATA SERVICE USAGE AND TRAFFIC IN LTE MOBILE NETWORKS

Mentorica: izv. prof. dr. sc. Štefica Mrvelj

Studentica: Ema Deak, 0135229527

Zagreb, srpanj 2017.

MJERENJE I ANALIZA KORIŠTENJA PODATKOVNIH USLUGA I PROMETA U LTE MOBILNOJ MREŽI

SAŽETAK

Prikupljanje podataka o prometu u LTE (*Long Term Evolution*) mreži je proces kojim se prikupljaju vremenski promjenjive informacije u standardiziranom formatu i na standardiziranim sučeljima. Postoje razni alati kojima je svrha prikupiti korisne podatke o prometu koji mogu koristiti različitim interesnim skupinama. Različite mjerne točke u mobilnoj mreži osiguravaju različitu razinu detalja u skupu podataka o prometu, pa odabir mjerenja mora biti takav da odgovara ciljevima mjerenja. Mobilna jezgrena mreža omogućava centralizirane mjerne točke da bi se osigurala realna informacija o uzorcima uporabe usluga/aplikacija u mobilnoj mreži. Za prikupljanje podataka o veličini prometa koriste se različiti pristupi, tj. razvijeno je nekoliko tipova i metoda za mjerenje prometa, stoga je svrha istražiti njihove značajke. Cilj rada je za prikupljeni skup podataka o prometu na području jedne bazne stanice napraviti statističku analizu podataka o izmjerenom prometu po raznim kriterijima (danu, satu).

KLJUČNE RIJEČI: LTE; mjerenje prometa; podatkovni promet; metode mjerenja prometa; klasifikacija prometa; analiza prometa u ćeliji

MEASURING AND ANALYSIS MOBILE DATA SERVICE USAGE AND TRAFFIC IN LTE MOBILE NETWORKS

SUMMARY

Collecting data traffic in LTE (*Long Term Evolution*) network is a process that collects time-varying information in a standardized form and on standardized interfaces. There are a variety of tools, measuring useful data traffic that can be used by different interest groups. Different measuring points in mobile networks provide different levels of detail in the data set of traffic, so the measurement selection must be such as to match the measurement targets. The mobile core network provides centralized measuring points to provide real-time information ona sample usage of the services/applications in the mobile network. Different approaches are used to collect data traffic, i.e. several types and methods for measuring traffic are developed, so the purpose is to explore their features. The purpose of this research is to collect data traffic on a single base station to make statistical analysis of data traffic according to different criteria (day, hour).

KEY WORDS: LTE; measurement of traffic; data traffic; traffic measurement methods; traffic classification; traffic analysis in the cell

SADRŽAJ

1. Uvod 1
2. LTE mobilna mreža 3
2.1. Korisnička oprema 4
2.2. Arhitektura mreže 6
2.2.1. Pristupna mreža 7
2.2.2. Jezgrena mreža 9
2.2.3. *Roaming* arhitektura 10
3. Značajke prijenosa podataka u LTE mobilnoj mreži i klasifikacija podatkovnog prometa 12
3.1. Protokolni složaj 12
3.2. Prijenos podataka kroz mrežu 15
3.3. Klasifikacija podatkovnog prometa 16
4. Tipovi i metode mjerenja prometa 21
4.1. Tipovi mjerenja prometa 21
4.1.1. Aktivno i pasivno mjerenje 22
4.1.2. Ostali tipovi mjerenja 24
4.2. Metode identifikacije korisnika i uređaja 25
4.3. Metode identifikacije aplikacija 26
4.3.1. Metode bazirane na *port*-ovima 26
4.3.2. Napredna metoda filtriranja podataka 27
4.3.3. Ostale metode identifikacije aplikacija 27
4.4. Hardverski i softverski alati 28
4.5. Mjerenje temeljeno na lokaciji 29
5. Značajke aplikacija za mjerenje prometa i njihova ograničenja 30
5.1. Tipovi aplikacija i njihove karakteristike 30
5.2. Korišteni alat za praćenje performansi mreže 33
5.2.1. Funkcionalnosti alata s obzirom na interesne skupine 35
5.2.2. Struktura i značajke aplikacije za mjerenje prometa 36
5.2.3. Prikaz alata po segmentima 39
6. Statistička analiza podataka o izmjerenom prometu po raznim kriterijima 41
6.1. Statistička analiza podataka o prometu u ćeliji 41
6.1.1. Rezultati mjerenja u danu 42
6.1.2. Rezultati mjerenja u razdoblju od mjesec dana 48
6.2. Mogućnosti primjene dobivenih rezultata 57

7. Zaključak 59
LITERATURA 61
POPIS SLIKA 62
POPIS TABLICA 63
POPIS GRAFOVA 64
POPIS DIJAGRAMA 65
POPIS KRATICA 66

1. Uvod

Podatkovni promet slovi kao dominantna vrsta prometa u telekomunikacijskim mrežama nove generacije. Mjerenjem i prikupljanjem podataka u mreži dobiva se objektivna informacija o tome kolika je uporaba pojedine usluge/aplikacije u mreži. LTE mreža kao tehnologija kojom se šalje podatkovni promet omogućuje prikupljanje takve vrste informacija koje koriste različitim interesnim skupinama unutar lanca vrijednosti u telekomunikacijskoj industriji. Unutar mreže moguće je izmjeriti podatke koje generiraju različite aplikacije koje su iz dana u dan sve korišteniji program implementiran u mobilne terminalne uređaje, ali isto tako i računalne sustave. Jezgreni dio LTE mreže zbog svojih funkcionalnosti omogućuje postavljanje mjernih točaka na različitim mjestima u mreži koje izvlače sve informacije o stanju u mreži, te se kasnije primjenjuju u različitim istraživanjima i statističkim analizama. Svrha ovog rada usmjerena je upravo na izučavanje značajki podatkovnog prometa, kao i aplikacija kojima je moguće izvršiti mjerenje. Cilj rada je prikazati statističku analizu podataka o izmjerenom prometu na području jedne bazne stanice. Naslov diplomskog rada je: Mjerenje i analiza korištenja podatkovnih usluga i prometa u LTE mobilnoj mreži. Rad je podijeljen u sedam cjelina:

1. Uvod
2. LTE mobilna mreža
3. Značajke prijenosa podataka u LTE mobilnoj mreži i klasifikacija podatkovnog prometa
4. Tipovi i metode mjerenja
5. Značajke aplikacija za mjerenje prometa i njena ograničenja
6. Statistička analiza podataka o izmjerenom prometu po raznim kriterijima
7. Zaključak

U drugom poglavlju opisane su karakteristike LTE mreže, kategorije korisničke opreme, arhitektura mreže koja je sastavljena od pristupnog i jezgrenog dijela, te *roaming* arhitektura.

Prijenos podataka u LTE mobilnoj mreži vrši se pomoću različitih protokola koji su zaduženi za određene radnje kako bi se prijenos ispravno izvršio. Tema trećeg poglavlja

fokusirana je na spomenuti proces, kao i klasifikaciju podatkovnog prometa po raznim kriterijima.

Poglavlje *Tipovi i metode mjerenja* opisuju načine na koje je moguće provesti mjerenje u mreži po raznim kriterijima (korisnici, uređaji, aplikacije, lokacija, mrežne komponente), te gdje se postavljaju mjerne točke.

U petom poglavlju dan je prikaz postojećih aplikacija kojima se može izmjeriti promet, ali isto tako su navedeni nedostaci koji su prisutni u svakom tipu aplikacije. Također, opisan je alat za praćenje mrežnih performansi korišten za statističku analizu podataka.

Poglavlje *Statistička analiza podataka o izmjerenom prometu po raznim kriterijima* obuhvaća rezultate mjerenja mrežnih performansi u LTE mreži, praćenih po danu i u mjesecu.

2. LTE mobilna mreža

LTE (*Long Term Evolution*) mreža predstavlja posljednju implementiranu generaciju naprednih tehnologija u mobilnim komunikacijskim sustavima. Mreža četvrte generacije dizajnirana je s ciljem da omogući usluge koje funkcioniraju isključivo prijenosom paketa kroz mrežu, što nije slučaj s mrežama prethodnih generacija. IP (*Internet Protocol*) protokol preko kojeg se uspostavlja veza između korisničkog terminalnog uređaja i podatkovne mreže PDN (*Packet Data Network*) najvažnija je stavka za prijenos paketa, ali često i vrlo nepouzdana. S obzirom na to da prijenos treba biti obavljen bez ikakvih prekida do krajnje točke, tj. korisničke aplikacije, uz IP se rabe i brojni drugi protokoli kako bi se povećala pouzdanost prijenosa.

Termin LTE mreža, prema [1], odnosi se na evoluciju radio pristupa i zapravo predstavlja E-UTRAN (*Evolved-UMTS Terrestrial Radio Access Network*), koji „surađuje“ s evoluiranom paketskom jezgrenom mrežom EPC (*Evolved Packet Core network*). Drugi naziv koji se koristi u literaturi za EPC je SAE (*System Architecture Evolution*), a zajedno s LTE-om čini tzv. evoluirani paketski sustav EPS (*Evolved Packet System*). EPS se definira kao koncept čija je uloga preusmjeriti IP pakete kroz mrežu počevši od *gateway*[1]-a, pa sve do korisničkog terminalnog uređaja.

Glavni zahtjevi koje bi LTE mreža trebala zadovoljiti u odnosu na prethodne generacije mobilnih mreža su sljedeći [2]:

- smanjiti kašnjenje, u smislu uspostavljanja konekcije i samog prijenosa paketa
- povećati količinu prenesenih korisničkih podataka
- povećati brzine prijenosa na rubovima ćelija u svrhu jednake raspodjele pružanja usluga
- redukcija troškova po bitu uz poboljšanu iskoristivost spektra
- veća fleksibilnost kod iskorištavanja spektra, u novim i postojećim frekvencijskim pojasevima
- pojednostavljena mrežna arhitektura
- mobilnost između različitih radio-pristupnih tehnologija
- razumna potrošnja energije mobilnog terminalnog uređaja.

[1] Mrežni čvor računalne mreže zadužen za komunikaciju s drugim mrežama koje rade s drugim protokolima.

Specifikacije za prvi LTE od strane 3GPP (*3rd Generation Partnership Project*) donesene su i prihvaćene 2007. godine *Release*[2]-om 8 kada LTE postaje dio radio pristupnih tehnologija. S vremenom se krenulo u daljnje razvijanje sustava, te su uvedeni *Release* 9 i 10 čime LTE mreža dobiva novu dimenziju i novi pridjev u nazivu (*Advanced* – napredan). Potreba za daljnjim proučavanjem i razvitkom LTE-a javila se isključivo od strane tržišta. Naime, Sjeverna Amerika veliku pažnju posvećuje svojim javnim sustavima upozorenja, kao i metodama koje služe za pozicioniranje. Mreža četvrte generacije sa svim svojim specifičnostima i mogućnostima može vrlo precizno izmjeriti položaj, čak i na mjestima gdje GPS (*Global Positioning System*) u većini slučajeva zakaže.

Kako navodi izvor [2], prva komercijalna implementacija LTE mreže u Europi obavljena je krajem 2009. gdje je naglasak na unaprjeđenju MIMO (*Multiple Input Multiple Output*) tehnologije koja putem većeg broja odašiljačkih i prijemnih antena omogućuje veću propusnost i općenito učinkovitost same mreže.

Autori u [1] navode kako je definirana kvaliteta usluge QoS (*Quality of Service*) za krajnjeg korisnika sadržana u toku IP paketa. EPS kao cjelina pruža podršku glasovnim uslugama koje se vrše putem IMS-a (*IP Multimedia Subsystem*) koristeći VoIP (*Voice over IP*), dok LTE pruža interoperabilnost s postojećim sustavima za uobičajen prijenos govora. S obzirom na to da su u korisničkoj opremi implementirane i pokrenute brojne aplikacije koje omogućuju usluge, one isto tako imaju različite QoS zahtjeve. Aplikacije koje omogućuju VoIP ne toleriraju primjerice kašnjenje i *jitter*[3] jer se obavljaju u stvarnom vremenu, za razliku od pregledavanja *web* stranica ili preuzimanja datoteka gdje kašnjenje nije toliko bitno.

Ovo poglavlje razrađeno je na manje cjeline u kojima će fokus biti na korisničkim terminalnim uređajima i arhitekturi mreže kako bi se na što bolji način prikazao sustav funkcioniranja LTE mreže.

2.1. Korisnička oprema

Korisnička oprema je neizostavan dio ekosustava u informacijsko-komunikacijskim tehnologijama. Korisnik mora posjedovati određeni terminalni uređaj kako bi mogao razmjenjivati informacije putem mreže, bilo da se radi o mrežama prethodnih generacija, ili novoj LTE mreži o kojoj je riječ u ovome radu.

[2]Standardi koji razvojnim programerima osiguravaju stabilnu platformu za razne implementacije.
[3]Vremenska razlika između dolaska uzastopnih paketa iste sesije.

Korisničku opremu čini nekoliko pojedinačnih komponenti koje tvore smislenu, funkcionalnu cjelinu [3]. USIM (*Universal Subscriber Identity Module*) je aplikacija implementirana u pametnu karticu, tzv. UICC (*Universal Integrated Circuit Card*), a koristi se za identifikaciju i autentikaciju korisnika, kao i sigurnosne ključeve u svrhu zaštite transmisije putem radio sučelja. Korisnička oprema je zapravo platforma za aplikacije koje omogućuju uspostavu, održavanje i prekid komunikacije kroz mrežu. Korisnik je povezan s korisničkom opremom tzv. korisničkim sučeljem i tako može koristiti aplikacije za uspostavljanje govornih poziva putem VoIP-a i sl. Razvojem novih tehnologija, dolazi i do razvoja korisničke opreme što za sobom povlači povećanje tržišta takvih proizvoda, ali i različitosti koje proizvodi nose sa sobom.

LTE mreža trebala bi biti konstruirana tako da može podržati različite kategorije korisničke opreme, s različitim kapacitetima. Isto tako je bitno da oprema udovolji kategorijama korisnika koji su prisutni na tržištu. Neke od karakteristika koje su bitne kod korisničke opreme navedene u [2] su: brzina prijenosa podataka, dimenzije i fizička obilježja uređaja, cijena i trajanje baterije. U istom izvoru navode se osobine opreme koja bi se trebala koristiti u LTE mreži:

- Mogućnost prijenosa podataka najvećom mogućom brzinom koja je potrebna za rad nekih aplikacija, no to obično povlači za sobom veliki memorijski prostor za obradu tolike količine podataka što automatski znači veća cijena uređaja.
- Korisnička oprema potrebna za povezivanje često je implementirana u obliku uređaja većih dimenzija kao što su prijenosna računala. Takva oprema često nema prihvatljivu potrošnju energije ili dovoljan broj antena koji će možda biti potreban da sve funkcionira kako treba. S druge strane postoje mali ručni terminali koji su dimenzijama *user-friendly*, međutim imaju vrlo malo prostora za ugradnju dovoljnog broja antena ili veće baterije.

Bitno je na tržištu ponuditi što veći broj kategorija korisničke opreme kako bi podržala zahtijevane funkcionalnosti, ali isto tako i udovoljila zahtjevima različitih skupina korisnika. S druge strane, ponuda velikog broja različitih uređaja povlači za sobom nedostatke koji u određenim situacijama mogu predstavljati problem. Povezivanjem korisničke opreme na mrežu, konekcija nije uvijek ostvarena zbog ograničenosti koje oprema možda ima u odnosu na mrežu na koju se potrebno povezati. Isto tako, nedostatak se javlja u obliku troškova

uloženih u testiranje interoperabilnosti. Prihvaćanjem LTE mreže kao 3GPP standarda, uvode se specifikacije (*Release* 8, 9, 10) vezane uz tu mrežu.

Specifikacije se između ostalog dotiču i korisničke opreme koja je prema izvoru [2] podijeljena u pet kategorija po različitim kriterijima, prikazano u tablici 1.

Tablica 1. Kategorizacija korisničke opreme

	Kategorija				
	1	2	3	4	5
Podržana brzina u silaznoj vezi (Mb/s)	10	50	100	150	300
Podržana brzina u uzlaznoj vezi (Mb/s)	5	25	50	50	75
Broj potrebnih prijamnih antena	2	2	2	2	4
Broj podržanih MIMO slojeva u silaznoj vezi	1	2	2	2	4
Podrška za 64QAM modulaciju u silaznoj vezi	+	+	+	+	+
Podrška za 64QAM modulaciju u uzlaznoj vezi	-	-	-	-	+
Memorijski zahtjev potreban za procese na fizičkom sloju	1	4.9	4.9	7.3	14.6

Izvor: [2]

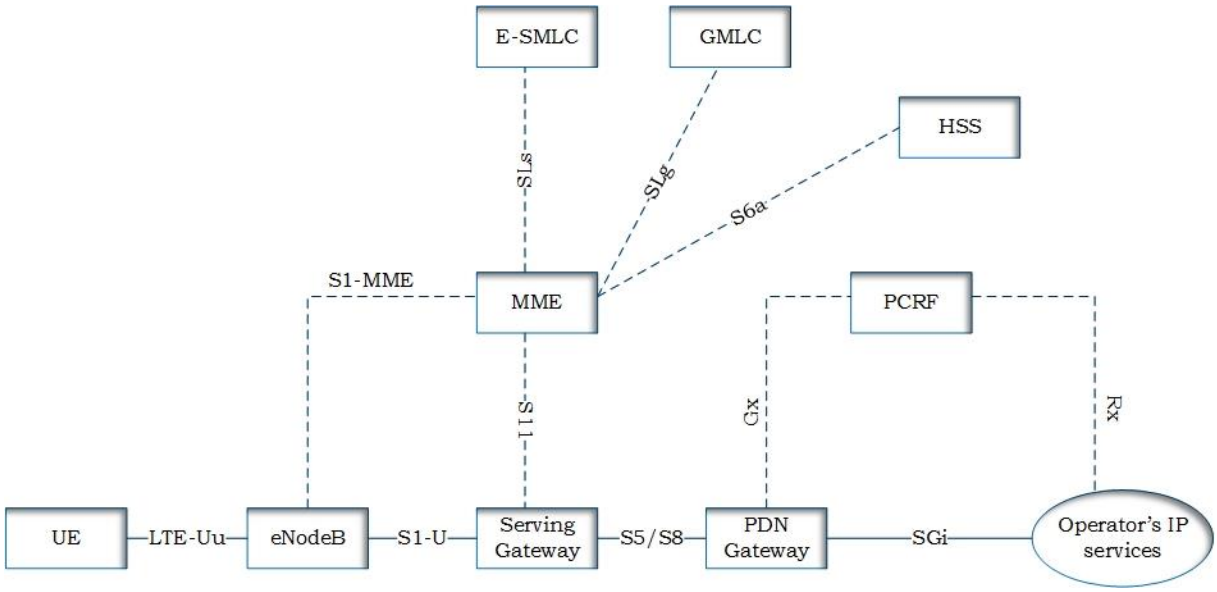
Karakteristike uređaja prikazane u tablici 1 sadržane su u *Release*-u 8 i 9, a moguće je iščitati da se porastom broja kategorije, povećavaju i „moći“ korisničke opreme što se tiče brzina, antena, modulacija i memorije. *Release* 10 je zapravo nadogradnja *Release*-a 8 i 9, sadrži tri kategorije uređaja iz razloga kako bi se izbjegla fragmentacija prilikom implementiranja korisničke opreme, a ujedno i prekomjerne varijante na tržištu [2].

2.2. Arhitektura mreže

Kao i svaka druga mreža, tako i LTE mora pružiti zadovoljavajuću sigurnost i privatnost za korisnika, ali isto tako mora biti zaštićena od zlonamjernih radnji koje su sve češće razvojem novih tehnologija. Kako bi se postigli spomenuti zahtjevi koji se nadmeću, a istovremeno i omogućio prijenos podataka, u mrežnoj arhitekturi spominju se elementi koji imaju različite uloge.

Slika 1 prikazuje elemente i standardizirana sučelja, koji čine jezgrenu mrežu (EPC) i pristupnu mrežu (E-UTRAN). Jezgrena mreža sastavljena je od više logičkih čvorova, dok pristupnu mrežu čini tzv. evoluirani čvor *eNodeB* koji se povezuje s korisničkom opremom UE

(*User Equipment*). Svi elementi su međusobno povezani standardiziranim sučeljima čime je ostvarena interoperabilnost za različite proizvođače opreme.



Slika 1. Arhitektura LTE mreže

Izvor: [1]

Arhitektura LTE mreže temelji se na poboljšanom radio pristupu u odnosu na ranije generacije mobilnih mreža, a da također bude ekonomski prihvatljiva. Prema [2], slojevita arhitektura sastavljena je od samo jednog tipa čvora *eNodeB* koji predstavlja baznu stanicu. Kako bi se omogućile usluge bazirane na prijenosu paketa u mreži, potrebno je rabiti učinkovite protokole i voditi računa o interoperabilnosti što se tiče otvorenosti sučelja i proizvodnje opreme. Učinkoviti mehanizmi koji omogućuju upravljanje i održavanje, te jednostavna implementacija i konfiguracija su bitni čimbenici kod konstruiranja mrežne arhitekture. Detaljan opis mrežnih elemenata koji su podijeljeni u pristupnu i jezgrenu mrežu slijedi u nastavku.

2.2.1. Pristupna mreža

Pristupnu mrežu E-UTRAN čine čvorovi *eNodeB* koji su međusobno povezani S1 sučeljem, odnosno S1-MME (*The Mobility Management Entity*) sučeljem do MME i S1-U sučeljem do *Serving Gatewaya*-a (S-GW). AS (*Access Stratum*) protokoli se rabe između *eNodeB* i korisničke opreme. E-UTRAN obavlja sve radio funkcije kao što su:

- *Radio Resource Management* pokriva područje vezano uz radio nositelje. U taj kontekst spada: kontrola radio nositelja, kontrola radio prijema, kontrola radio mobilnosti, raspoređivanje resursa prema korisničkoj opremi u silaznoj i uzlaznoj vezi.
- Kompresija zaglavlja pomaže osigurati učinkovitu uporabu radijskog sučelja. Radi se o kompresiji zaglavlja IP paketa, koji u suprotnom mogu predstavljati značajan višak pri samom prijenosu, osobito kada su u pitanju mali paketi, npr. prijenos govora.
- Sigurnost predstavlja vrlo bitnu stavku kod paketskog toka kroz mrežu, prema tome svi podaci koji se šalju radijskim sučeljem su enkriptirani.
- Pozicioniranje je važno zbog pronalaženja pozicije korisničke opreme. E-UTRAN treba dostaviti odgovarajuće informacije E-SMLC-u (*Evolved Serving Mobile Location Centre*) kako bi taj element mogao otkriti poziciju.
- Povezanost obuhvaća signalizaciju prema MME i put kojim signal nositelj ide prema S-GW-u.

Svaka od navedenih funkcija smještena je u *eNodeB* čvorovima, a svaki čvor može upravljati većim brojem ćelija. U usporedbi s mrežama prethodnih generacija, *eNodeB* u LTE mreži je zapravo ono što je kontrolor baznih stanica u 2G (*2nd Generation*) i 3G (*3rd Generation*). Omogućena je interakcija različitih protokolnih slojeva koji su smješteni unutar pristupne mreže, a samim time ostvarena je redukcija prigušenja i povećana učinkovitost. Kontrola koju vrši *eNodeB* važna je jer eliminira potrebu za visokom propusnošću i intenzivne obrade podataka, što u konačnici znači manje troškove i izbjegavanje „pucanja“ veze na određenim točkama u mreži. S obzirom na to da LTE mreža ne podržava meko prekapčanje, ne postoji središnji kontrolni *eNodeB* i to ponekad može predstavljati problem. Kretanjem korisnika, a samim time i korisničke opreme, sve informacije vezane uz korisničku opremu moraju biti prebačene s jednog *eNodeB*-a na drugi, a da se pri tome izbjegne gubitak dijela ili cijele informacije koja se prenosi [1].

Sučelje koje spaja pristupnu i jezgrenu mrežu naziva se S1, poznato i kao S1-*flex*. Pod tim pojmom podrazumijeva se da čvorovi jezgrene mreže (MME/S-GW) poslužuju određeno zemljopisno područje i pri tome su povezani na mrežu koju čine *eNodeB* čvorovi koji također djeluju na tom istom zemljopisnom području. Ovakvom kombinacijom spomenutih elemenata pristupne i jezgrene mreže raspodijeljeno je opterećenje mreže i uklonjene su točke „pucanja“ veze.

2.2.2. Jezgrena mreža

Jezgrena mreža ili *Core Network* zadužena je prije svega za kontrolu korisničke opreme i utvrđivanje signala nositelja. Sastavljena je od skupine elemenata, a kao najvažniji se izdvajaju sljedeći [2]:

- PDN *Gateway* (P-GW)
- *Serving Gateway* (S-GW)
- *Mobility Management Entity* (MME)
- *Evolved Serving Mobile Location Centre* (E-SMLC).

Osim navedenih, ostali elementi su: *Gateway Mobile Location Centre* (GMLC), *Home Subscriber Server* (HSS) i *Policy Control and Charging Rules Function* (PCRF). U nastavku će biti opisane glavne zadaće svakog od elemenata.

PCRF je odgovoran za politiku kontrole odlučivanja, isto kao i za kontrolu toka. Kvaliteta isporučene usluge također je vezana uz PCRF, a mora biti u skladu s korisničkom pretplatom. Što se tiče QoS-a, bitno je učinkovito rasporediti pakete u odgovarajuće klase, što utječe na brzinu kojom se prenose.

GMLC sadrži funkcionalnosti koje predstavljaju podršku za ostvarivanje lokacijskih usluga. Nakon uspostavljene autorizacije, šalje se zahtjev prema MME i GMLC dobiva konačnu informaciju o lokaciji.

HSS se može definirati kao baza korisničkih podataka u kojoj su sadržane brojne korisne informacije. U toj bazi vidljiv je tarifni model na temelju kojeg se dalje obavlja isporuka određene kvalitete usluge, ali i ograničenje pristupa kada je riječ primjerice o *roaming*[4]-u. Uz spomenuto, baza još sadrži informacije o PDN mreži na koju se korisnik može povezati. Isto tako, moguće je vidjeti na koji MME je korisnik trenutno povezan ili registriran. Baza komunicira s autentikacijskim centrom AuC (*Authentication Centre*) koji vodi računa o sigurnosti, tj. autentikaciji i sigurnosnim ključevima.

P-GW dodjeljuje IP adresu korisničkoj opremi, ostvaruje odgovarajuću QoS i promatra tok paketa u skladu s PCRF elementom. Kvaliteta usluge koju bi korisnik trebao doživjeti s obzirom na pretplatu koju ima u svom korisničkom profilu, filtrira se kroz IP pakete u silaznoj vezi. Dakle, P-GW izvršava definiranu QoS kroz zajamčenu brzinu prijenosa. Osim navedenih funkcionalnosti, omogućuje međusobni rad s tehnologijama koje nisu standardizirane prema

[4]Usluga putem koje se mobilni terminalni uređaj spaja na mrežu na koju korisnik nije pretplaćen.

3GPP kao npr. CDMA2000 (*Code Division Multiple Access*) i Wi-MAX (*Worldwide Interoperability for Microwave Access*).

S-GW je element u mreži kroz koji prođu svi IP paketi, tj. područje kroz koje paketi „putuju“ između korisničke opreme i *eNodeB* čvorova. Također čuva informacije dok je korisnička oprema u stanju mirovanja i privremeno zadržava podatke u silaznoj vezi sve dok MME ponovno ne uspostavi konekciju do korisničke opreme putem signala nositelja. Osim navedenih karakteristika, S-GW je administracijski čimbenik u mreži, što znači da prikuplja podatke koji se dalje obrađuju u svrhu naplate (količina poslanih i primljenih podataka i sl.), te međusobni rad s nekim drugim 3GPP tehnologijama kao što su GPRS (*General Packet Radio Service*) i UMTS (*Universal Mobile Telecommunications System*).

MME se definira kao kontrolni čvor putem kojeg se vrši signalizacija između korisničke opreme i jezgrene mreže. Protokoli koji djeluju između korisničke opreme i jezgrene mreže poznati su kao *Non-Access Stratum* (NAS) protokoli, a procedure koje pokreću vezane su uz brže uspostavljanje veze u odnosu na prethodne generacije mobilnih mreža. MME podržava različite funkcionalnosti kako slijedi:

- Upravljanje signalom nositeljem uključuje uspostavu, održavanje i prekid signala, a upravljanje sesijom putem NAS protokola.
- Upravljanje konekcijom obuhvaća uspostavu konekcije i sigurnost između mreže i korisničke opreme, te je povezano s konekcijskim slojem ili slojem upravljanja mobilnošću kroz NAS protokole.
- Međusobno povezivanje s drugim mrežama što se odnosi na predaju glasovnih poziva između mreža.

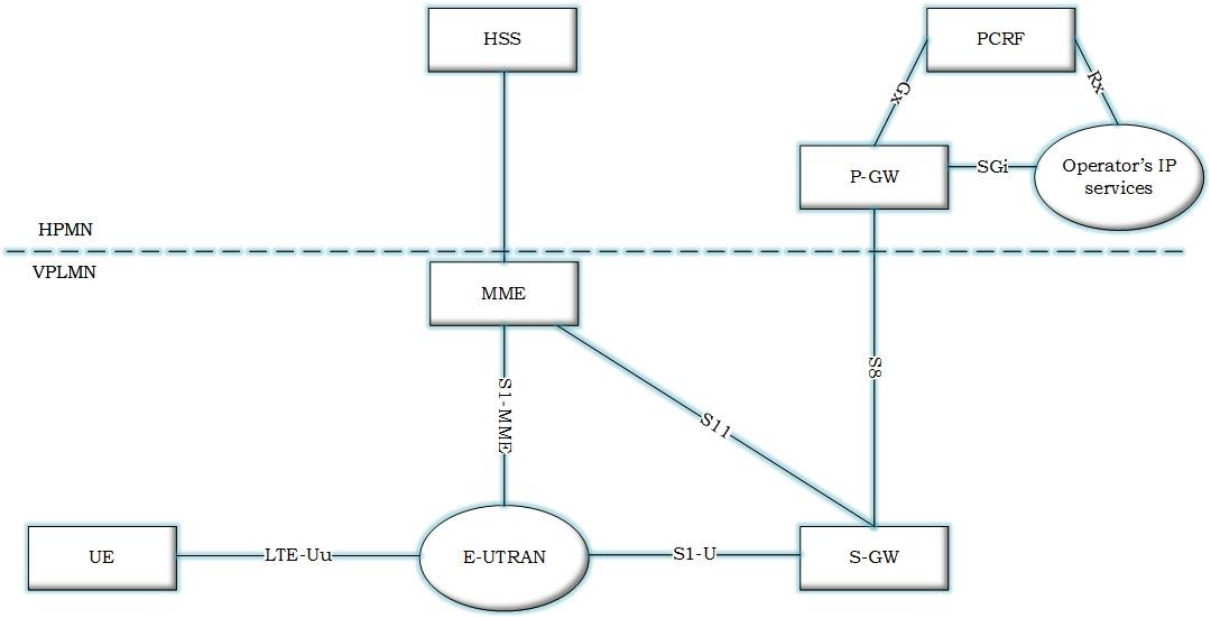
E-SMLC je zadužen za koordinaciju i planiranje resursa koji su neophodni kako bi se locirala korisnička oprema koja je povezana na E-UTRAN. Putem E-SMLC-a može se izračunati konačni položaj baziran na podacima koje zaprima i brzini kretanja korisničke opreme koji utječu na točnost procjene pozicije.

2.2.3. *Roaming* arhitektura

Mreža koja je u posjedu jednog operatora i jedne države naziva se PLMN (*Public Land Mobile Network*). Korisnici se mogu povezati i na PLMN na koji nisu direktno pretplaćeni i tada se kaže da su u *roaming*-u [1]. *Roaming* postoji u mrežama ranijih generacija, pa tako nije zaobišao i najnoviju LTE mrežu.

Prilikom objašnjavanja *roaming* arhitekture, glavni pojmovi koje treba razlikovati su „domaća“HPMN (*Home* PMN) i „gostujuća“ VPLMN (*Visitor* PLMN) mreža. Sami nazivi govore na koju mrežu je korisnik pretplaćen, a na koju se može „prebaciti“. Korisnik koji je u *roaming*-u spojen je na E-UTRAN, MME i S-GW elemente „gostujuće“ mreže. P-GW je element koji može biti korišten i u „domaćoj“ i u „gostujućoj“ mreži.

U slučaju da je korisnik na „domaćem“ P-GW-u u mogućnosti je koristiti usluge operatora na kojeg je pretplaćen bez obzira na to nalazi li se u tom trenutku u „gostujućoj“ mreži. S druge strane, P-GW „gostujuće“ mreže dopušta lokalne prekide prilikom spajanja na Internet u *roaming*-u.



Slika 2. Prikaz HPMN i VPLM u *roaming*-u

Izvor: [1]

Na slici 2 je prikazana *roaming* arhitektura gdje se vidi podjela elemenata u „domaćoj“ i „gostujućoj“ mreži u slučaju kada je P-GW smješten u „domaćoj“ mreži, opisano u tekstu iznad.

3. Značajke prijenosa podataka u LTE mobilnoj mreži i klasifikacija podatkovnog prometa

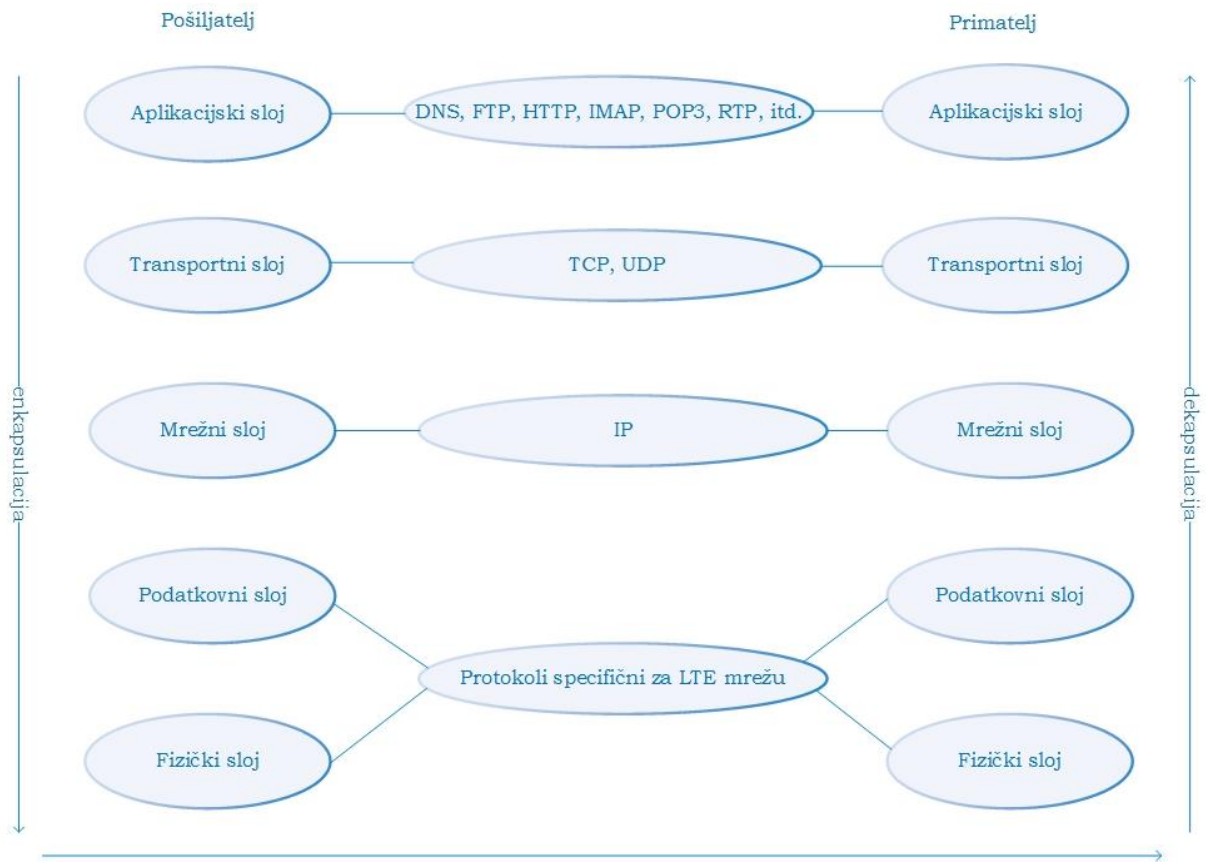
Prijenos podataka putem LTE mobilne mreže koji se vrši preko IP protokola složeniji je od prijenosa podataka koji se također obavlja preko Interneta, ali fiksnom pristupnom mrežom. Današnji mobilni terminalni uređaji koriste TCP/IP protokolni složaj, međutim LTE mreža zahtijeva i poštivanje protokola specificiranih od strane 3GPP-a [3]. Mobilni pristup Internetu zahtijeva poboljšanu pristupnu mrežu za razliku od fiksnog pristupa, i zbog toga se koriste dodatni protokoli. Dodatni protokoli omogućuju mjerenje i interpretaciju prometa na različitim točkama u mreži.

3.1. Protokolni složaj

Kako bi se na što jednostavniji način opisao proces prijenosa podataka u nekoj komunikacijskoj mreži, pa tako i u internetskoj mreži, potrebno je prikazati model. Model se koristi za opis arhitekture mreže, ali i prikaz komunikacije između protokola, te ostalih elemenata koji čine mrežu. Struktura protokola internetske mreže podijeljena je u pet slojeva, prikazano na slici 3, a to su: fizički, podatkovni, mrežni, transportni i aplikacijski sloj.

Protokoli koji su pridruženi pojedinim slojevima koriste se za međusobno povezivanje kako bi se komunikacija mogla ostvariti. Proces komuniciranja zahtijeva čitav niz radnji, opisanih u izvoru [3]. Prijenos podataka od pošiljatelja do primatelja i obratno odvija se enkapsulacijom odnosno dekapsulacijom. Enkapsulacija znači proces slanja podataka niz OSI model, od pošiljatelja prema primatelju. Prilikom slanja podataka enkapsulacijom se podacima višeg sloja dodaje zaglavlje sloja kroz koji podaci prolaze. Spuštanjem s aplikacijskog do transportnog sloja podaci sačinjavaju segment. Nakon toga, u mrežnom sloju se enkapsuliraju u pakete gdje svaki paket dobiva svoju izvorišnu i odredišnu (tzv. logičku IP) adresu. Dolaskom do podatkovnog sloja, paket prelazi u okvir gdje mu se ponovno dodaje izvorišna i odredišna adresa, ali ovaj put fizička, tzv. MAC (*Media Access Control*) adresa. Kada okvir dođe do fizičkog sloja potrebno ga je pretvoriti u oblik koji je pogodan za slanje prijenosnim medijem koji se koristi u komunikaciji. Nakon što podaci stignu na odredište, vrši se dekapsulacija podataka, a to je proces suprotan prethodno opisanoj enkapsulaciji. Podaci se prosljeđuju od najnižeg (fizičkog) prema najvišem (aplikacijskom) sloju i pri tome im se uklanjaju sva zaglavlja slojeva kroz koje su prošli. Takvim postupkom

podaci poprimaju izvorni oblik u kojem su bili poslani, a to omogućuje da se na aplikacijskom sloju primatelju prikažu u onom obliku kako ih je zapravo vidio pošiljatelj.



Slika 3.Protokolni složaj internetske mreže

Izvor: [3]

Nakon što je pojašnjeno kako slojevi funkcioniraju, potrebno je objasniti protokole koji djeluju na određenom sloju. Kao što je prikazano na slici 3, fizički sloj i sloj veze podataka nemaju definirane protokole, već su oni implementirani i usvojeni s obzirom na to o kojoj mreži je riječ i na koji način treba povezati cjelokupni prijenos podataka. Dakle, protokoli na tim slojevima vode računa o povezanosti.

IP protokol karakterističan je za mrežni sloj modela, a glavna zadaća koju obavlja je adresiranje, tj. dodjeljuje adrese fiksne duljine od 32 bita *host*[5]-ovima u mreži. Protokol mrežnog sloja slovi kao nepouzdan prilikom prijenosa podataka u IP datagramima kroz mrežu. Kada se za protokol kaže da je nepouzdan, to znači da ne provjerava greške, niti prati

[5]Terminal u mreži.

slijed datagrama od izvorišta do odredišta. S obzirom na to da postoje ograničenja u različitim mrežama što se tiče maksimalne veličine paketa, datagrami mogu biti fragmentirani u manje pakete. Nakon prijenosa oni se ponovno sastavljaju u originalni datagram, a sve navedene operacije također obavlja IP protokol.

U usporedbi s IP protokolom koji isporučuje podatke od *host*-a do *host*-a, protokoli koji djeluju na transportnom sloju isporučuju podatke od aplikacije do aplikacije. UDP (*User Data Protocol*) je nepouzdan protokol transportnog sloja koji ne jamči kontrolu toka, provjeru grešaka, kao ni redoslijed slanja segmenata kroz mrežu. UDP je zapravo jednostavan protokol s malim zaglavljem u kojem su sadržane samo nužne informacije koje aplikacija treba dobiti. Protokol koji je uz UDP specifičan za transportni sloj je TCP (*Transmission Control Protocol*). Za razliku od UDP-a, TCP je konekcijski orijentiran i pouzdan. TCP provjerava svaku konekciju zasebno, vrši retransmisiju paketa ako je to potrebno, te obavlja kontrolu toka. Što se tiče zaglavlja, u njemu su sadržani izvorišni i odredišni *port*[6]-ovi, kao i polje gdje se računa kontrolna suma. Osim navedenog, postoje i druga polja u kojima je naznačen redoslijed odlaska i dolaska paketa i tzv. zastavice koje se također odnose na pouzdanost i povezanost u mreži [4].

Posljednji, aplikacijski sloj definira se kao sloj koji je najbliži krajnjem korisniku. Njegova funkcija je omogućiti korisniku da se uspješno poveže na mrežu putem korisničkog sučelja, podrške za usluge i pristup datotekama. Aplikacija kao takva pristupa nekoj usluzi putem Interneta i pri tome se poziva na protokole transportnog sloja koji obavlja zadatke koji su ranije opisani. Aplikacijski sloj je nešto složeniji od ostalih slojeva kada je riječ o protokolima. Naime, on obuhvaća čitav niz različitih protokola koji zapravo potpomažu aplikacijama u radu, a s obzirom na raznolikost aplikacija, internetski promet je moguće proučavati s različitih aspekata.

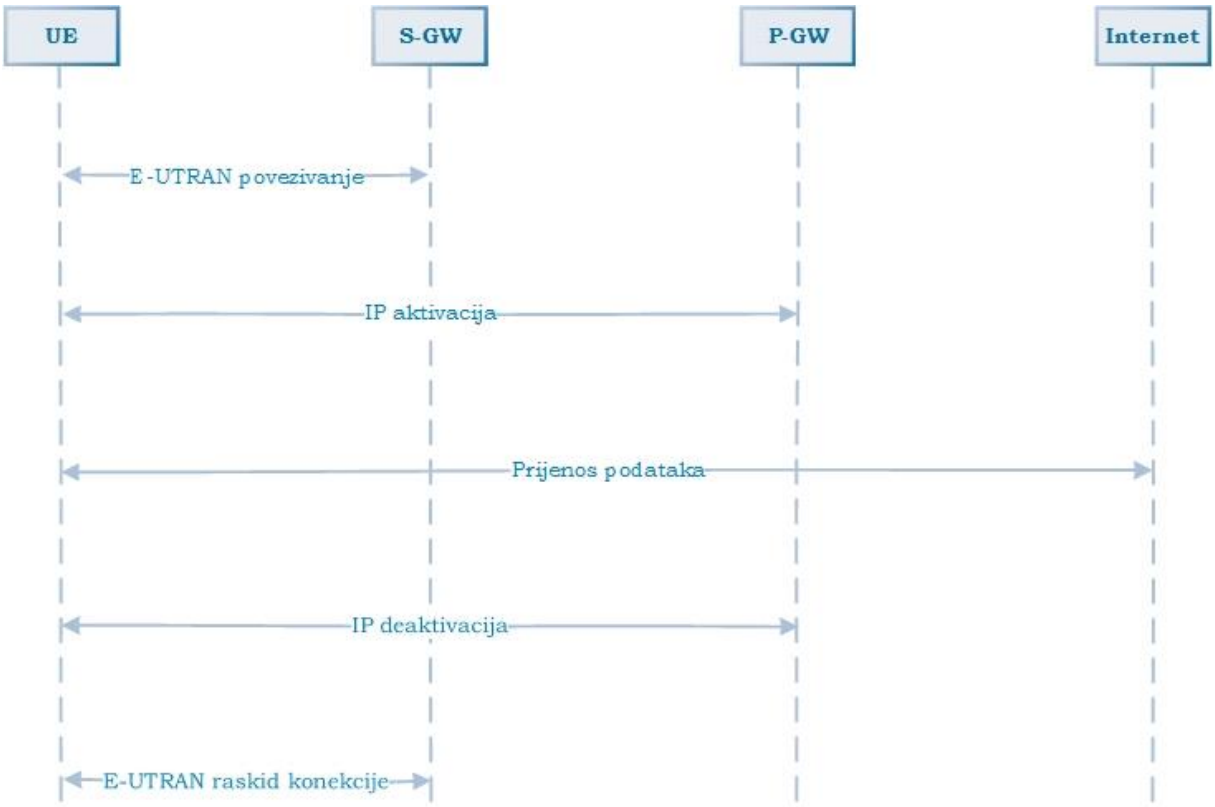
Protokoli koji prema [5] imaju najširu primjenu su HTTP (*Hypertext Transfer Protocol*) i DNS (*Domain Name System*). HTTP protokol je korišten od strane preglednika i *web* servera, dok DNS služi za mapiranje IP adresa i čitanje domena. Osim navedenih, na aplikacijskom sloju su još najkorišteniji sljedeći protokoli: SMTP (*Simple Mail Transfer Protocol*) koji se brine za siguran i pouzdan prijenos poruka elektroničke pošte, POP3 (*Post Office Protocol version 3*) i IMAP (*Internet Message Access Protocol*) koji dohvaćaju elektroničku poštu sa servera na onim mrežama koje koriste IP, FTP (*File Transfer Protocol*) koji prebacuje datoteke

[6]Početna/krajnja točka u komunikacijskom kanalu.

s jednog *host*-a na drugi i RTSP (*Real Time Streaming Protocol*) kao primjer protokola koji je odgovoran za prijenos podataka strujanjem.

3.2. Prijenos podataka kroz mrežu

U samom prijenosu podataka, prema izvoru [3], sudjeluje nekoliko elemenata koji ostvaruju komunikaciju. Kao što je prikazano UML (*Unified Modeling Language*) dijagramom međudjelovanja, prvi i neophodni element za početak procesa prijenosa podataka je mobilni terminalni uređaj ili neka druga vrsta korisničke opreme. Korisnička oprema kao takva zadužena je za povezivanje pristupne E-UTRAN mreže na S-GW koji vrši provjeru uređaja, odnosno korisnika.



Dijagram 1. Proces prijenosa podataka

Izvor: [3]

Nakon što se utvrdi da je uređaj ovlašten za korištenje, dodjeljuje mu se P-TMSI (*Packet-Temporary Mobile Subscriber Identity*), privremena identifikacija pretplatnika u mobilnoj mreži. Mobilni terminalni uređaj nakon te procedure zahtjeva dodjelu IP adrese koju obavlja P-GW, prethodno odabran od S-GW-a. Kada uređaj dobije svoju IP adresu, on

postaje vidljiv u mreži putem te adrese. Moguća je dodjela više IP adresa jednom uređaju, u smislu da svaka aplikacija na tom uređaju ima posebnu adresu od kojih je onda svaka povezana na različiti P-GW.

Unutar LTE mreže između P-GW-ova promet je tuneliran pomoću protokola (E-UTRAN *Tunneling Protocol*) zaduženog za tuneliranje. U praksi bi to značilo da je promet enkapsuliran u zaglavlju tog protokola između S-GW i P-GW mrežnih elemenata. Nakon što se izvrši dekapsulacija, tj. promet prilagodi za daljnje slanje, on „putuje“ u obliku običnog IP prometa. Protokol vrši usmjeravanje korisničkih podataka kroz mrežu čime oni stižu na odredište. Važno je naglasiti da unutar IP konteksta postoji naziv pristupne točke (*Access Point Name*) kao referenca na P-GW, što znači da sam korisnik ne treba voditi računa o tome koje točno S-GW-ove i P-GW-ove treba koristiti.

Kada je određena ispravna pristupna točka, ona obavlja DNS funkcionalnosti u jezgrenoj mreži nakon čega se vraća IP adresa aktivnog P-GW-a, a samim time i S-GW-a koji obrađuju odgovarajuće zemljopisno područje. Naziv pristupne mreže sastoji se od dva dijela: mrežni identifikator i identifikator operatora. Oba identifikatora su odgovorna za prepoznavanje vanjske mreže na koju je P-GW konektiran i na koji PLMN je lociran. Dakle, naziv pristupne točke trebao bi biti u čitljivom obliku, što jednostavnijem za korisnika. Ostale pristupne točke kao što je primjerice WAP (*Wireless Application Protocol*) djeluju na sličan način, samo što se sam naziv pristupne točke razlikuje od korisnika do korisnika prilikom povezivanja s uslugama određenog operatora [3].

3.3. Klasifikacija podatkovnog prometa

Klasifikacija prometa jedan je od važnih temelja u mrežnim politikama i poslovnim modelima koji se nude na tržištu. Pružatelj internetskih usluga ne može konstruirati nove usluge, optimizirati korištenje resursa i izvršiti pravilnu i realnu naplatu ako ne prati promet u mreži. Promet se uglavnom prati kroz razne slučajeve uporabe kako bi se na što ispravniji način prikazala klasifikacija istog. Izvor [6] navodi kako sustav tolerira manja odstupanja, ali veće pogreške prilikom utvrđivanja vrste prometa obično osjeti krajnji korisnik kroz pogrešnu naplatu i sl. Takve greške za sobom povlače posljedice koje mogu biti negativne za pružatelja usluga, kao što je gubitak korisnika. Iz navedenih razloga postoje brojne tehnike kojima se identificira promet kroz mrežu i izdvajaju bitne informacije potrebne za daljnju analizu. Pružatelji internetskih usluga moraju razumjeti tehnologiju i proces prijenosa podataka kroz

mrežu, što podrazumijeva i detaljnije poznavanje klasa prometa kako bi krajnjem korisniku mogli pružiti i naplatiti uslugu u skladu s realnim očekivanjima.

Promet se klasificira tako da se odredi koliki je zapravo podatkovni promet u mreži, a zatim se dohvaćaju informacije kao što su: video rezolucija, vrsta prijenosnog medija, te kako korisnici doživljavaju uslugu (npr. QoS). Također je važno napomenuti da se svi ti segmenti ne mogu promatrati jednoliko. Primjerice, rezolucija ne zahtijeva jednaku razinu analize kao i korisnički doživljaj opisan kroz QoS.

IP promet može biti podijeljen prema skupinama u kojima se nalaze protokoli, aplikacije i sl. s približno istim značajkama, ali isto tako nisu isključena međusobna preklapanja. Sve stavke koje su niže navedene ne isključuju mogućnost pripadanja u više klasa. Skupine prema kojima se dijeli podatkovni promet su sljedeće:

- protokoli: predstavljaju skup pravila i formata kojima se definira na koji način mrežni elementi dijele informacije (UDP, TCP, HTTP, FTP, RTMP i sl.)
- aplikacije: uključuju onaj promet koji se vrši uz pomoć određene softverske podrške (*Skype*, *Viber*, *WhatsApp* i sl.)
- *web* stranice: odnose se na one *web* stranice koje su dio određene *web* domene i razmjenjuju sadržaj s određenom *web* domenom
- usluge: u ovom kontekstu općenit pojam koji može obuhvaćati *web* stranice kao što su društvene mreže (*Facebook*), *cloud*[7] usluge ili primjerice uslugu pohrane podataka
- poslužitelj: obično postoje različiti pružatelji internetskih usluga, ali koriste iste protokole kako bi isporučili uslugu. Npr. više različitih pružatelja video usluga koristi upravo RTMP (*Real-Time Messaging Protocol*), dok za isporuku glasovnih usluga koriste SIP (*Session Initiation Protocol*).

Izvor [6] prema kojem je napravljena prethodno opisana podjela navodi primjere gdje se određena vrsta prometa preklapa i samim time pripada u više klasa. *BitTorrent* je softverska platforma koja koristi *BitTorrent* protokol u istoimenoj mreži, a sve u svrhu dijeljenja i razmjene datoteka. S druge strane postoji RTMP zadužen za prijenos internetskog prometa koji se odvija u stvarnom vremenu. RTMP se nalazi unutar HTTP-a, a on je pak vrsta TCP protokola. Kako bi se izbjeglo pogrešno svrstavanje prometa, potrebno je shvatiti značenje određenih protokola i aplikacija u pravom kontekstu. Osim što se vrste podatkovnog

[7]Računalstvo u oblaku.

prometa mogu preklapati, mogu biti podijeljene i u podklase, pa npr. video sadržaj može biti HD (*High-definition*) i ne-HD.

Obično su podklase dodane kako bi se razjasnio kontekst, a ne kao nekakve tehničke razlike i sl. Pojmovi koji su važni u kontekstu klasifikacije podatkovnog prometa su:

- zbirka: popis identificiranih i mjerenih vrsta prometa
- vrsta sadržaja: video, tekst, slika, zvuk itd.
- pogrešno-pozitivno: pogrešna „pozitivna“ identifikacija određenog tipa prometa
- pogrešno-negativno: pogrešna „negativna“ identifikacija određenog tipa prometa
- neprepoznatljiv promet: nije ga moguće identificirati kao pripadnika bilo koje vrste prometa
- OTT (*Over-The-Top*): promet koji zaobilazi mrežu operatora
- podatkovni promet i kontrolni promet: podatkovni promet čini sadržaj koji se stvarno prenosi i razmjenjuje, dok kontrolni promet vodi računa o tim radnjama, tj. kontrolira podatkovni promet
- potpis: izraz koji se odnosi na pakete koji se šalju mrežom, tehnika kojom se prate promjene stanja unutar podatkovnog i kontrolnog prometa kako bi se mogli izdvojiti potrebni podaci za daljnju analizu.

U različitim izvorima mogu se naći različite podjele podatkovnog prometa ovisno o tome što se postavlja kao kriterij. U ovom radu prikazane su dvije podjele u kategorije, odnosno klase (tablica 2 i tablica 3).

Tablica 2. Pregled mogućih kategorija prometa

Kategorija prometa	Opis	**Primjer**[8]
Skladišta	Prijenos velike količine podataka i online usluge za pohranu podataka	**FTP, NNTP, PDBox, Rapidshare, Mega, Dropbox**
Igre	Konzole i PC igre	**Nintendo Wii, Xbox Live, Playstation Network, World of Warcraft**
Trgovina aplikacijama	Trgovine za aplikacije, preuzimanje sadržaja i ažuriranje softvera	**Google Play Store, Apple iTunes, Windows Update**
Administracija	Protokoli korišteni za administriranje mreže	**DNS, ICMP, NTP, SNMP**
Dijeljenje datoteka	Aplikacije za dijeljenje datoteka, *peer-to-peer*[9] ili izravne	**BitTorrent, eDonkey, Ares, Pando, Foxy**

[8]Značenja kratica opisana na kraju rada.
[9]Umrežavanje računala bez poslužitelja.

Komunikacije	Aplikacije, usluge i protokoli vezani uz e-mail, čavrljanje, prijenos glasa i videa	**Skype, ICQ, SIP, MGCP, IRC, FaceTime, WhatsApp, Gmail, SMTP**
Stvarnovremenske aplikacije	Aplikacije i protokoli koji omogućuju zabavne sadržaje na zahtjev	**Pandora, Rdio, Songza, RTSP, RTMP, RTP, PPStream, Octoshape, Slingbox, Netlflix, Hulu, HBO Go, BBC iPlayer, SkyGo**
Tuneliranje	Protokoli i usluge koji omogućuju udaljeni pristup mrežnim resursima, ili enkripciju ili enkapsulaciju	**SSL, SSH, L2TP, Remote Desktop, VNC, PC Anywhere**
Društvene mreže	*Web* stranice i usluge fokusirane na interakciju i dijeljenje	**Facebook, Twitter, Habbo, Bebo**
***Web* pregledavanje**	*Web* protokoli i specifične *web* stranice	**HTTP, WAP browsing**

Izvor: [6]

Kao što je vidljivo, promet je podijeljen na kategorije koje se koriste u svakodnevnom životu, bilo da ih koriste privatni korisnici i/ili poslovni. U mrežni promet se uz svakodnevne aktivnosti broji i administracija mreže koja uključuje protokole koji zapravo omogućuju svu tu razmjenu ostalih podataka.

Osim prikazane tablice, promet može biti klasificiran i na sljedeći način, kako je navedeno u izvoru [3]:

Tablica 3. Pregled mogućih klasa prometa

Klasa prometa	Opis
***Web* pregledavanje**	Posjećivanje *web* stranica koristeći *web* preglednik
***Web* aplikacije**	Korištenje aplikacija za pristup *web* sučelju
Crawler	Program koji sustavno pregledava *World Wide Web* kako bi skupio podatke za analizu
Preuzimanje datoteka	Preuzimanje datoteka putem HTTP-a
Webmail	*e-mail* usluge bazirane na *web*-u
Oglašavanje	Oglašavanje putem *web* stranica ili ugradnjom u softver
Multimedija	Strujanje medija ili pregledavanje datoteka medija na *web* stranicama
SW ažuriranje	Ažuriranje softvera preko HTTP-a
Vijesti	*Really Simple Syndication* (RSS) vijesti
Link validator	Automatski link validatori
Kalendar	Kalendarske aplikacije bazirane na *web*-u
Napad	Maliciozni promet preko HTTP-a
IM	*Windows Live Messenger*

Kontroliranje	Kontrola mreže

Izvor: [3]

Iako se klasifikacija podatkovnog prometa koristi za opisivanje određene vrste prometa koja prođe kroz mrežu, teorija se ponekad može zanemariti jer se neke stvari koje su teorijski objašnjene, ne mogu u potpunosti poistovjetiti s onime što se zapravo događa. Identifikacija prometa se vrši dubinskim pregledom paketa i tada se iz kontrolnog prometa mogu izdvojiti dodatne informacije.

Postoje razne metode kojima je moguće izvršiti identifikaciju podatkovnog prometa kao što su matematičke ili metode dešifriranja. Jedna od zanimljivijih metoda je heuristika, gdje se zapravo nagađa kontekst samih podataka. Heuristička tehnika se koristi kada nema potpunih informacija i kada se razmjenjuju velike količine podataka između većeg broja korisnika, npr. *peer-to-peer* dijeljenje datoteka. Heuristika kao metoda je zapravo vrlo koristan dodatak drugim tehnikama identifikacije prometa.

Prepoznavanje prometa moguće je izvršiti i putem IP adresa koje su povezane s određenim *web* stranicama i uslugama. Bez obzira kojim metodama i na koji način se klasificira promet, operator mora znati na koji način će analizirati prikupljene informacije, kolikim kapacitetom raspolaže kada se vrši klasifikacija prometa i može li prevladati sve tehničke zahtjeve koji se nameću pri takvim radnjama [6].

4. Tipovi i metode mjerenja prometa

Mjerenja podatkovnog prometa provode se iz više razloga i ciljeva. Obično se provode kako bi se pratilo, kontroliralo i okarakteriziralo stanje u mreži. Nadgledanje i upravljanje mrežom bitne su radnje osobito za mrežnog operatora. Ovakvim proučavanjem mreže iznose se tehničke i komercijalne informacije o tome kakav promet se zapravo prenosi u mreži. Isto tako, ponašanje korisnika i što oni koriste zanima mnoge entitete koji sudjeluju u telekomunikacijskoj industriji: akademska zajednica, regulativna i korporativna tijela [3]. U ovom radu naglasak će ostati na tehničkom aspektu proučavanja prometa.

Metode mjerenja prometa moguće je razvrstati po raznim kriterijima, isto kao i identificirati korisnike, uređaje i aplikacije. Mjerne točke u mobilnim mrežama važne su kako bi se izvadile suvisle informacije iz svake od tih točaka i dalje vršila analiza. Razvijeni su brojni alati i rješenja kako bi se iz mreže izvukle sve potrebne informacije o prometu. Izvor [5] navodi neke od ciljeva promatranja cjelokupnog prometnog stanja u mreži:

- sastavljanje korisničke baze podataka u svrhu promatranja statistike
- vođenje računa o pitanjima privatnosti i povjerljivosti na dogovarajući način
- promatranje IP paketa kako bi se mogla provesti istraživanja stohastičkih procesa
- praćenje primjene aplikacija i prometnog toka, te modeliranje izvornog prometa
- prikupljanje specifičnih informacija u kontekstu mobilnosti i sesija.

4.1. Tipovi mjerenja prometa

Tipovi ili postavljanje točaka mjerenja utječu na same ciljeve mjerenja. S obzirom na to da se mjerenje prometa može provesti u raznim dijelovima mreže, izmjereni podaci moraju biti reprezentativni u odnosu na svrhu u koju se proučavaju. Iz tog je razloga važno odabrati mjesto mjerenja u mreži i detaljnost samih podataka. Lociranost opisuje na kojem dijelu mreže se promet mjeri. Kao što je ranije navedeno, mjerenje se može obaviti na različitim čvorovima ili linkovima u mreži, ali isto tako na jednoj ili više lokacija. Detaljiziranje podataka definira mjerne podatke koji služe svrsi, ovisno o kontekstu u kojem će biti upotrjebljeni.

Karakteristike uporabe internetskog prometa mogu biti izmjerene već poznatim metodama kao što je brojanje *byte*[10]-ova i distribucija aplikacija. Međutim, sam obujam prometa kao takav nije uvijek najbolji pokazatelj stanja u mreži, te je potrebno koristiti druge

[10]Mjerna jedinica za količinu podataka.

metode kako bi se stvorila objektivna slika mjerenja. Npr. vremenska skala promatra određeni vremenski period i kontinuitet istovremeno.

Podatkovni promet mjeri se uz pomoć mjernog hardvera koji mora biti fizički pričvršćen na točku u mreži u kojoj se želi obaviti mjerenje. U praksi postoje dva načina na koji je moguće povezati mjerni hardver na točku mjerenja:

- prva metoda je tzv. „prisluškivanje mreže“ što uključuje pasivno razdvajanje optičkog ili bakrenog linka
- drugom metodom se „zrcale“ *port*-ovi, odnosno jedan ili više *port*-ova u *switch*[11]-u se „zrcale“ na drugi *port* koji je povezan s mjernim uređajem.

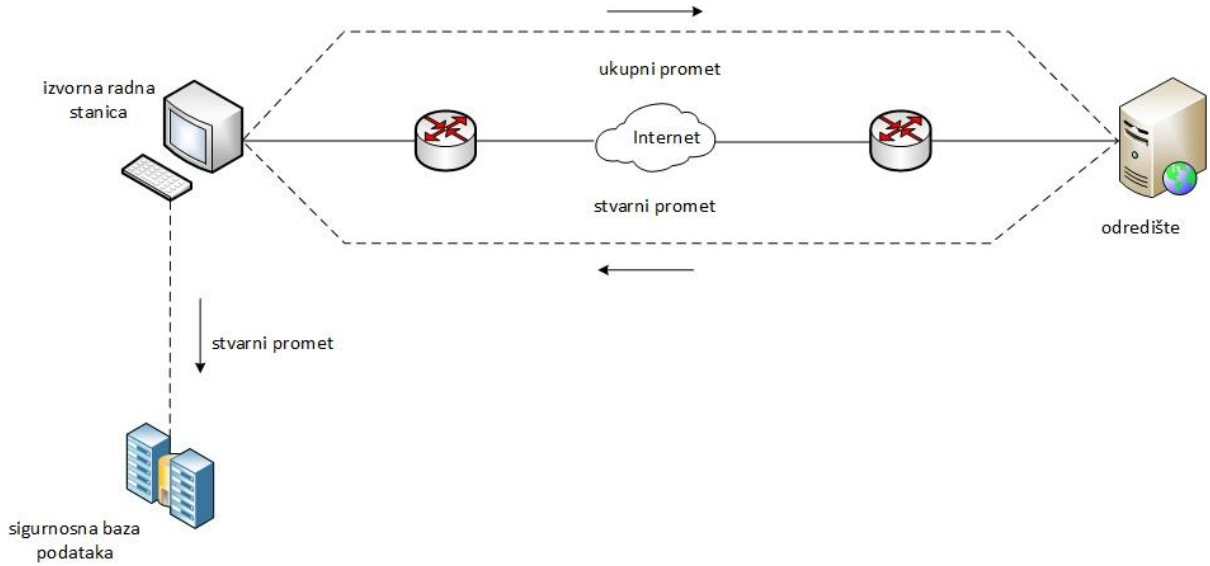
Metoda „zrcaljenja“ *port*-ova zahtijeva da *switch* posjeduje određene funkcionalnosti kako bi se to moglo izvršiti, što je ujedno i nedostatak ovakvog načina mjerenja, dok se metoda „prisluškivanja mreže“ može primijeniti na gotovo svim mrežama [3].

4.1.1. Aktivno i pasivno mjerenje

Mjerenje prometa se može podijeliti na aktivno i pasivno mjerenje. U aktivnim mjerenjima uvijek postoji neki promet koji je višak i on se šalje na analizu. Primjeri takvih mjerenja su: latencija[12], *jitter* i gubitak paketa.S obzirom na to da je cilj prikazati objektivne rezultate prometa, aktivna mjerenja mogu „poljuljati“ konačni rezultat. Zbog toga je potrebno provesti pasivno mjerenje u kojem ne postoji dodatni promet, i takva mjerenja su zapravo poželjna u mreži [3].

Aktivno mjerenje primjenjuje se samo u slučaju kada se ne može izvršiti pasivno mjerenje. Na slici 4 je prikazan princip aktivnog mjerenja prometa. Između izvorne radne stanice i odredišta generira se ukupan promet koji uz korisne podatke sadrži male UDP pakete u kojima ima vrlo malo ili gotovo ništa korisnog sadržaja. U takvim mjerenjima se ustvari skupljaju dodatne informacije potrebne za razumijevanje toka prometa od kraja do kraja. Nakon dolaska paketa na odredište rezimira se promet koji je zaista važan za daljnje analize i skladišti se u bazu.

[11]Mrežni uređaj za upravljanje prometnim tokom.
[12]Više o latenciji na: https://www.lifewire.com/latency-on-computer-networks-818119

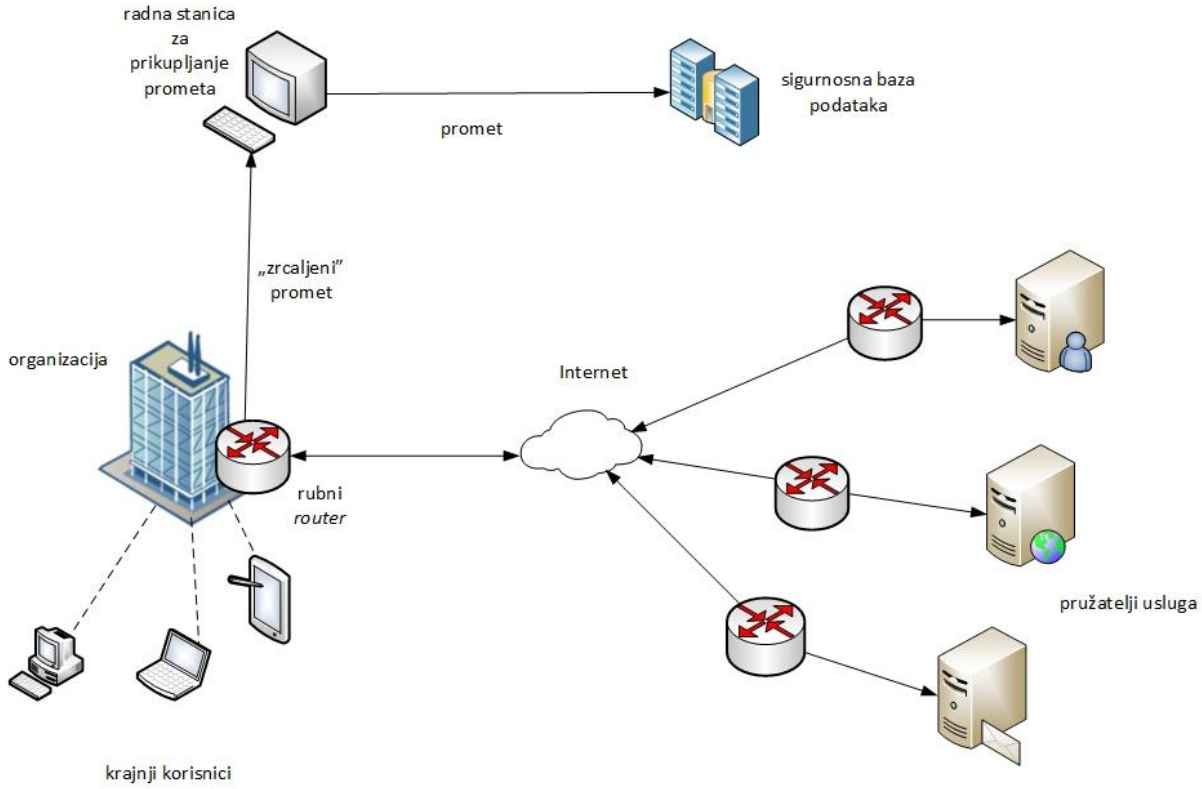


Slika 4. Proces aktivnog mjerenja prometa

Izvor: [7]

Slikom 5, sukladno prikazu dostupnom u [7], prikazano je pasivno mjerenje i struktura je nešto složenija od aktivnog mjerenja. Sav promet prolazi kroz *router*[13]-e ili *host*-ove i on se pri tome ne mijenja, te minimalno ometa rad mreže. Pasivno mjerenje izvršava se povezivanjem na *router* rubne mreže. Dolazni i odlazni promet koji je generiran u rubnoj mreži se replicira prema radnoj stanici koja prikuplja promet nakon čega je on pohranjen u bazu. Umjesto prikupljanja velike količine podataka, pasivno mjerenje pohranjuje samo izrazito važne informacije sadržane u zaglavljima protokola transportnog i aplikacijskog sloja. Ako se prikupi veća količina podataka, potrebno je izvršiti kompresiju čime se smanjuju dobiveni skupovi informacija. Zbog svih navedenih karakteristika, pasivno mjerenje se koristi za prikaz stvarnog stanja mrežnog prometa.

[13]Mrežni uređaj koji šalje pakete na temelju mrežne adrese.



Slika 5. Proces pasivnog mjerenja prometa

Izvor: [7]

4.1.2. Ostali tipovi mjerenja

Analiza mjerenja može biti izvršena *online* ili *offline*, ovisno o tome jesu li izmjereni rezultati namijenjeni za neke daljnje analize ili predstavljaju direktno izvješće za analize u stvarnom vremenu. Budući da podaci o izmjerenom prometu u mreži zahtijevaju visoku razinu obrade, promet se u većini slučajeva mjeri direktno na određenoj lokaciji, dok se sama analiza vrši kasnije. Iz prikupljenih mjerenja često se izvlače detaljnije informacije kao što su: zaglavlja protokola, polja u zaglavljima, korisnost protokola ili jednostavno svi podaci koje je moguće prikupiti.

Podaci vezani uz pakete prikupljaju se iz zaglavlja protokola smještenih na mrežnom i transportnom sloju. S obzirom na to da se u mrežama koje omogućuju velike brzine prijenosa, pa samim time i LTE mreži prenosi velika količina podatkovnog prometa, podaci su prikupljeni upravo iz zaglavlja. Isto tako, sama zaglavlja nerijetko sadrže velike količine podataka o prometu. Jedan od načina učinkovitog prikupljanja podataka s obzirom na količinu je praćenje toka paketa putem raznih alata koji su razvijeni u tu svrhu.

Ako se provode mjerenja na razini aplikacije, također se mjeri korisnost prijenosnog protokola koji djeluje na transportnom sloju što opet za sobom povlači veću količinu podataka za obradu. Zaglavlja protokola na aplikacijskom sloju imaju različite duljine, pa se određena količina podataka bilježi na samom početku, odnosno ili podaci iz zaglavlja ili svi podaci koje je moguće spremiti. Ako se podaci procesiraju u stvarnom vremenu, tada se samo značajnija polja unutar zaglavlja spremaju za daljnju uporabu, smanjujući pri tome količinu manje važnih podataka [3].

4.2. Metode identifikacije korisnika i uređaja

Kada je riječ o IP prometu, postoji samo nekoliko načina koji omogućuju identifikaciju jedinstvenog korisnika i uređaja. Prepoznavanje je moguće izvršiti direktno iz IP adrese ako je ona statična, ali ne ako ima karakteristike dinamičnosti. Dinamične IP adrese prevladavaju u današnjim mobilnim mrežama, međutim ne predstavljaju pouzdan oslonac za identifikaciju. U mobilnim mrežama nove generacije, autentikacija korisnika provodi se u jezgrenom dijelu mreže, točnije na onim mjernim točkama na kojima su dostupne informacije o korisniku. Takva mjerenja se više ne definiraju kao isključivo mjerenja IP prometa, već se koriste razne kombinacije. U tu svrhu rabe se specifični mrežni protokoli, ali i dodatni alati. Identifikacija operativnog sustava mobilnog terminalnog uređaja također se obavlja uz pomoć postojećih razvijenih rješenja koja daju tražene informacije o uređaju. Iako su metode identifikacije relativno jednostavne, često se kombinira više rješenja u svrhu postizanja preciznosti pri samoj identifikaciji pojedinačnih korisnika.

U slučaju kada nije moguće provesti jedinstvenu identifikaciju korisnika ili uređaja, alternativna opcija je uzimanje tzv. TCP „uzoraka“ koji mogu biti uzeti izravno iz TCP i IP zaglavlja. Sljedeća mogućnost je korištenje korisničkog polja HTTP protokola u kojem su sadržane informacije o korištenom pregledniku, operativnom sustavu, a često i o samom uređaju. Ova metoda vezana je isključivo za HTTP promet i postoji mogućnost pojave komplikacija prilikom suradnje s drugim protokolima.

Princip identifikacije operativnog sustava jest da svaki od njih ima svoj vlastiti „potpis“ u TCP/IP složaju koji omogućuje posebnu identifikaciju svakog od njih. Nakon što se izvrše mjerenja, podaci se analiziraju tako da se uspoređuju IP i TCP zaglavlja i iz njih izvlače „potpisi“ pojedinih operativnih sustava. Operativni sustavi imaju zajednička polja, a neka od njih su: vrijeme života TTL (*Time to Live*), veličina prozora, polje zastavice, maksimalna

veličina segmenta, početna veličina paketa i selektivna potvrda. Sva navedena polja mogu tvoriti različite kombinacije koje se specifične za svaki operativni sustav iz kojih se zatim vrši identifikacija. Iako je rukovanje i prikupljanje TCP „potpisa“ prilično jednostavno i može biti obavljeno od strane krajnjeg korisnika, aplikacije ili nekog mrežnog čvora kao što je *gateway* ili vatrozid, postoje ograničenja [3].

Ovakve radnje u mreži nisu zamišljene da budu izvršene od strane korisnika jer su potrebna detaljnija znanja o tome na koji način izvršiti identifikaciju. Za početak mora postojati baza podataka o poznatim „potpisima“ kako bi uopće bilo moguće usporediti mrežni promet. Uz bazu podataka kao najvažnije stavke se navode vrijeme i resursi s obzirom na to da ažuriranje „potpisa“ zahtjeva određeni vremenski period isto kao i pristup najnovijim uređajima koji omogućuju obavljanje ovakvih vrsta analiza u mreži.

4.3. Metode identifikacije aplikacija

Osim opisanih metoda, postoje i one koje stavljaju naglasak na mogućnost identifikacije aplikacija iz podataka koji su prikupljeni mjerenjem prometa.

4.3.1. Metode bazirane na *port*-ovima

Jedan od jednostavnijih načina identifikacije aplikacije je korištenje dobro poznatih brojeva *port*-a određenih protokola. Prednost ovakve vrste prepoznavanja je jednostavan postupak i jednostavna implementacija. Mnoge aplikacije koriste registrirane *port*-ove, npr. HTTP koristi *port* 80, dok POP3 koristi *port* 110. Brojevi *port*-ova se svrstavaju u 3 kategorije. Dobro poznati *port*-ovi čine jedan rang, registrirani *port*-ovi drugi rang, dok treći rang okuplja privatne *port*-ove koji nisu dodijeljeni ni jednoj specifičnoj aplikaciji. Identifikacija aplikacije temeljena na *port*-u može se obaviti pomoću skripti i komercijalnih ili besplatnih alata. Metode koje koriste *port*-ove s vremenom postaju sve manje popularne iz razloga jer se pojavljuju neizvjesnosti pri dobivanju informacija o aplikaciji na razini transportnog sloja.

Mnoge aplikacije koriste dinamičke *port*-ove i dolazi do maskiranja prometa koji je u tom slučaju prepoznat kao *web* promet zato što vatrozidi ponekad ne propuštaju sve protokole specifične za aplikacije, osim HTTP-a koji je iznimka. Uz navedene nedostatke, prevoditelji mrežnih adresa i *gateway*-i mogu sakriti izvorne informacije o *port*-u, pa je ova metoda pogodna za identifikaciju aplikacija koje imaju uobičajenu primjenu.

Pojedini izvori [3] tvrde da je metoda s *port*-ovima previše netočna u radu s novim aplikacijama i da je u tom slučaju zapravo upitna stvarna identifikacija internetskog prometa. Točnost metoda moguće je povećati prikupljanjem dodatnih informacija o *port*-ovima, međutim to za sobom povlači dodatni manualni rad, što nije praktično u ovakvim mjerenjima.

4.3.2. Napredna metoda filtriranja podataka

Jedna od alternativa za kvalitetniju identifikaciju na razini *port*-a je pregled kolika je TCP/IP korisnost, odnosno pregled podataka vezanih uz aplikacijsku razinu. Ovakva metoda naziva se napredna metoda filtriranja podataka DPI (*Deep Packet Inspection*) i funkcionira na principu da se radi usporedba aplikacija koje su pronađene upravo onda kada je ispitivanje započelo i onih aplikacija koje su već prethodno identificirane. U praksi, ovakva rješenja se nazivaju hibridnim rješenjima gdje je moguće koristiti i informacije na razini transportnog sloja. Pregledom TCP/IP složaja je povećana točnost identifikacije aplikacije u usporedbi s prethodno opisanom metodom na temelju portova. Osim toga, DPI pristup temeljen je na pregledu pojedinačnih paketa što također pridonosi i poboljšanju identifikacije *peer-to-peer* veza.

Kao i svaka druga metoda, tako i navedena DPI ima nedostataka. Kako bi se postiglo ispravno mjerenje, nerijetko treba ispitati skoro sva opterećenja u mreži kako bi metoda bila primijenjena na odgovarajući način. Ovakva inspekcija je vrlo intenzivna što se tiče iskorištenja resursa, pa se samim time povlače pitanja o potrebnoj širini pojasa i radu sa šifriranim prometom. Uz navedene nedostatke, mogu se javiti problemi vezani uz pravna i privatna pitanja zato što se prilikom analize aplikacije mogu izvlačiti osjetljivi podaci. Kao što je ranije navedeno, pojavom novih aplikacija povećava se manualni rad, te su zbog toga razvijena neka automatska rješenja koja se baš nisu pokazala najboljima za primjenu u praksi. Naime, automatizacijom je moguće identificirati isključivo konvencionalne aplikacije [3].

4.3.3. Ostale metode identifikacije aplikacija

Sljedeće metode koje su vezane uz aplikacije koriste statističke informacije koje se prikupljaju na mrežnom i transportnom sloju, a te informacije se mogu odnositi na npr. duljinu paketa, vrijeme dolaska između paketa i sl.

Jedna od metoda prati ponašanje *host*-ova, tj. njihovu međusobnu interakciju i na temelju toga se definiraju aplikacije, uključujući i *port*-ove. Kako bi se izvršila identifikacija, pregledava se više prometnih tokova između *host*-ova u određenom vremenskom intervalu i proučava se ponašanje *host*-ova za to vrijeme. Bitno je postaviti mjernu točku na odgovarajuće mjesto u mreži kako bi se obuhvatio sav promet koji zapravo prođe između dva terminala. Ono što se često javlja kao pogreška je što se od velike količine prikupljenog prometa neki promet navodi kao nepoznat i ne služi kao korisna informacija za daljnje proučavanje. Kako bi se izbjegla ovakva situacija, u praksi se moraju provesti dvije metode kada se proučavaju *host*-ovi, jedna dodatna za nepoznat dio prometa.

Druga metoda koja se temelji na prometnom toku koristi informacije kao što su: broj i veličina paketa po toku, vremenski interval između dolaska paketa na odredište i sl. Količina podataka koja je potrebna za ovakvu klasifikaciju može varirati; jednostavniji tipovi ovakvih metoda mogu predstavljati poboljšanu verziju metoda temeljenih na *port*-ovima, u smislu dodatnih funkcionalnosti, dok složenije metode zahtijevaju detaljniju obradu podataka i uporabu većih memorijskih kapaciteta za obradu [3].

4.4. Hardverski i softverski alati

Alati za mjerenje internetskog prometa u članku [7] klasificirani su na alate koji se temelje na hardveru i alate koji se temelje na softveru. Kada je riječ o hardverskim alatima, postoji specijalna oprema koja analizira mrežu i tako izvlači mjerenja i sam promet u mreži. Tzv. *off-the-shelf*[14] mrežni analizatori koriste mjerne uređaje kao npr. mrežne kartice velikih brzina. S druge strane, softverski alati se više fokusiraju na analizu prometa u stvarnom vremenu i vizualizaciju internetskog prometa. Takvi programi uglavnom su korišteni od strane mrežnih operatora kako bi im omogućili upravljanje i rješavanje eventualnih problema s umrežavanjem. Iako imaju brojne prednosti, oni ipak nisu najbolje rješenje za potrebe istraživanja. *Wireshark*[15] i *Bro4*[16] samo su neki od softverskih alata koji pronalaze široku primjenu u istraživanjima koja se vežu uz mjerenje internetskog prometa.

[14]Lako dostupna oprema.
[15]Više na: https://www.wireshark.org/
[16]Više na: https://www.bro.org/

4.5. Mjerenje temeljeno na lokaciji

Mjerenje prometa može se izvršiti na različitim lokacijama unutar mreže. Moguće ih je provesti na pojedinačnim krajnjim elementima u kojima jednostavna implementacija određenog softvera omogućuje prikupljanje dolaznog i odlaznog prometa. Iako rezultati ovakvih mjerenja imaju ograničenu uporabu, posebice ako je manja i sama veličina uzorka, ona su vrlo dobra polazna točka za izvođenje studija. Osim za proučavanje količine i vrste prometa koji prođe kroz mrežu, studije se često provode kako bi se razumjele karakteristike novih pristupnih tehnologija.

Izvor [7] navodi da mjerenja internetskog prometa također mogu biti provedena na mrežama u sklopu kampusa ili poduzeća. Takva mreža sastavljena je od nekoliko stotina/tisuća korisnika ovisno o veličini organizacije i obično se rade podjele korisnika u posebne kategorije (npr. studenti, profesori). U mrežama koje nisu globalnog karaktera, već više djeluju kao intranet, lakše je izmjeriti promet upravo iz tog razloga jer je mreža održavana od strane jedne organizacije. Lakše je dobiti odobrenje za prikupljanje prometa u kojem su možda sadržane i privatne informacije, nego u samom jezgrenom dijelu mreže na koji je spojena zapravo rubna mreža organizacije. Internetska mjerenja u jezgrenoj mreži teže je provesti prvenstveno zbog administrativnih, privatnih i vlasničkih prava. Podaci koji su prikupljeni u jezgrenom dijelu obuhvaćaju stotine tisuća korisnika, ali isto tako daju reprezentativnu sliku izvršenog prometa upravo zbog raznolikosti korisnika.

Pored opisanih metoda, razvijeni su i drugi pristupi kojima se mjeri podatkovni promet. Često se kombiniraju različite metode tako da se provede više iteracijskih krugova u kojima su prisutne odgovarajuće metode. Identifikacija se u ovom slučaju vrši na temelju informacija na razini aplikacije, statistici vezanoj uz prometni tok, statistici vezanoj uz povezivanje *host*-ova, informacije o nazivu *host*-a i ponašanju transportnog sloja prilikom prijenosa prometa kroz mrežu čime su obuhvaćene sve opisane metode [3].

5. Značajke aplikacija za mjerenje prometa i njihova ograničenja

Razvojem modernih informacijsko-komunikacijskih tehnologija na tržištu, povećava se podatkovni promet u mobilnim mrežama, a samim time i prihodi dobiveni od istog. Mrežni operatori kao važna karika lanca vrijednosti počinju surađivati s razvijateljima aplikacija i tako dolazi do povezivanja kupaca, mobilnih aplikacija i pružatelja usluga u jednu cjelinu. Mobilne aplikacije donose čitav niz noviteta i funkcionalnosti u ICT (*Information and communication technology*) svijet što mrežnim operatorima omogućuje povećanje prihoda dobivenih porastom podatkovnog prometa. Izvor [8] smatra da je dobitak od prihoda potrebno uložiti u poboljšanje ili razvoj novih mrežnih elemenata čime je omogućen daljnji razvoj suvremenih aplikativnih rješenja koja zahtijevaju odgovarajuću platformu za svoj rad.

Optimizacija iskustvene kvalitete usluge QoE (*Quality of Experience*) mobilnih aplikacija zahtjeva detaljnije poznavanje mreže i njenih performansi. Parametri koje je potrebno proučavati unutar mreže kako bi se to ostvarilo su: snaga signala, dostupnost najnovijim tehnologijama, kružno kašnjenje RTT (*Round-trip Time*) i odgovarajuća propusnost individualnih ćelija na promatranoj lokaciji. Ovakve informacije često nisu dostupne, pa su razvijeni alati i softveri koji mjere promet i ponašanje aplikacija, te tako daju programerima povratnu informaciju u svrhu poboljšanja postojećih rješenja. Iskustvena kvaliteta usluge obuhvaća: vrstu isporučenog sadržaja, korisničku lokaciju, korisnički uređaj i uvjete u mreži [9].

5.1. Tipovi aplikacija i njihove karakteristike

Kako u svim modernim tehnologijama, tako i u ICT-u inovacija igra veliku ulogu kada je riječ o aplikacijama. Programeri nastoje koristiti komunikacijske protokole sa sofisticiranim tehnikama isporuke podataka koje podržavaju komunikaciju u okviru različitih uvjeta u mreži koji mogu nastupiti. Za ostvarivanje besprijekornog rada aplikacije, potrebni su detaljni podaci o mrežnim performansama kojima često nije lako pristupiti i zapravo predstavljaju izazov.

U tablici u nastavku prikazani su neki od tipova aplikacija, a sama podjela aplikacija u skupine bitna je za proširenje ponude na tržištu. Svakom tipu aplikacije pridružene su prepreke koje mogu predstavljati problem, isto kao i optimizacijske tehnike koje su karakteristične za pojedini tip. Upravo navedenim optimizacijskim tehnikama ublažava se

osjetljivost aplikacija na razne varijacije i nepredvidivosti u mreži. Istraživanja vezana uz tipove aplikacija koja su prezentirana u izvoru [8] provedena su na mobilnim terminalnim uređajima.

Tablica 4. Tipovi mobilnih aplikacija

Tip aplikacije	Prepreke	Optimizacijske tehnike
Strujanje medija	- visoki *jitter* - slaba propusnost	-prilagođenje veličini spremnika - slojevito kodiranje
Aplikacije za trgovinu	- visoka latencija - sigurnost	- prilagodljiv protokolni dizajn - minimiziranje komunikacija
Igre u proširenoj stvarnosti	- variranje latencije kroz sustav	- „održavanje“ transmisije
Baze podataka	- prekid radio veze	- specifične vremenske vrijednosti sustava
***Web* pretraživanje**	- niska propusnost - veliko opterećenje	- predmemoriranje uređaja -odstupanje/čekanje aplikacija

Izvor: [8]

Strujanje medija je osjetljivo na visoki *jitter* i slabu propusnost. Programeri koji konstruiraju aplikacije mogu utjecati na *jitter* tako da posvete pažnju veličini međuspremnika koja je ključna za dobru primjenu aplikacije. U slučaju da je međuspremnik premali obično dolazi do prekida reprodukcije, za razliku od prevelikog spremnika koji može odgoditi početak reprodukcije videa ili jednostavno biti neupotrebljiv u uređajima s određenim memorijskim kapacitetom. Ovakva vrsta aplikacija pokazuje osjetljivost i na slabu propusnost. Ako se u mreži podaci ne dostave pravovremeno, reprodukciju nije moguće izvršiti u stvarnom vremenu i multimedijska datoteka mora biti preuzeta u cijelosti prije nego što se počne s reprodukcijom. Kako bi se izbjegla ovakva situacija, strujanje medija je često kodirano pomoću slojeva. Dodatna propusnost omogućuje korištenje više slojeva, a svaki dodatni sloj povećava kvalitetu reprodukcije multimedijske datoteke koja se pregledava. Slojevita struktura omogućuje aplikaciji da se prilagodi u slučaju da je prisutna slaba propusnost, međutim programeri trebaju procijeniti slojevitost tako da bude prikladno za uređaje i mrežu koji se koriste. Finija struktura prema tome predstavlja dodatno opterećenje uređaja, dok grublja struktura može rezultirati nedovoljnim iskorištenjem kapaciteta mreže, kao i degradiranu izvedbu aplikacije.

Aplikacije za trgovinu pod utjecajem su visoke latencije, tj. znatnog kašnjenja signala koje je uzrokovano strukturom protokola. Latencija smanjuje učinkovitost i atraktivnost aplikacije u današnjem užurbanom načinu života. S druge strane, takvi protokoli su nužni za dobro korisničko iskustvo prilikom upotrebe aplikacije. Dizajneri aplikacija trebali bi pronaći ravnotežu prilikom dizajniranja softvera kako bi korisnicima omogućio najbolje moguće iskustvo u razumnom vremenskom intervalu. Količina podataka koja se prenosi treba biti ograničena kako bi se prijenos obavio u zahtijevanom vremenu, smanjila latencija i omogućila dovoljna propusnost za rad mobilnih terminalnih uređaja i mrežnih aplikacija. Osim latencije, mobilne aplikacije također trebaju ispuniti očekivanja korisnika što se tiče sigurnosti i privatnosti. Prepoznate su i definirane brojne ranjivosti uređaja i mreže koje mogu obuhvatiti i aplikacije bez obzira ako se one ne koriste u određenom trenutku. Takva situacija nekad može korisniku dati lažni osjećaj sigurnosti. Dok su enkripcijski mehanizmi u mreži prilično intenzivno razvijeni i upotrjebljeni, dizajneri aplikacija ih često ograničavaju upravo zbog vremena čekanja.

Igre u proširenoj stvarnosti su relativno nova pojava u mobilnim aplikacijama. Za razliku od klasičnih mobilnih igara instaliranih na mobilni softver, igre u proširenoj stvarnosti se odvijaju *online* u stvarnom vremenu. Cilj je igračima prikazati stvarno stanje igre u ključnom trenutku, ali isto tako ograničiti igranje ovakvih igara ako potraju duže vremensko razdoblje. Najpoznatiji primjer ovakve aplikacije je *Pokémon Go* koja radi na temelju mobilnog lociranja podataka o lokaciji igrača i smješta ga na kartu. Igra se na otvorenom prostoru gdje su dostupni signali, ali i objekti (npr. znamenitosti) pri čemu se zapravo kroz materijalni svijet ostvaruje virtualno okruženje igre. Zahtjev predstavljen pred programere je ograničiti latenciju između različitih mobilnih terminalnih uređaja, mrežnih operatora, mrežnih tehnologija i zemljopisnih područja.

Mobilne aplikacije koje pristupaju bazama podataka imaju dodatne zahtjeve koje trebaju ispuniti. Kvaliteta korisničkog iskustva ovisi o reakciji aplikacije prilikom primjene. Koristeći ovakav tip aplikacija, korisnici mogu neko vrijeme biti neaktivni na mreži, npr. u situacijama kada se vrši ažuriranje aplikacije. Nakon duljeg vremena neaktivnosti, suvremeni bežični uređaji su podešeni tako da ulaze u mod u kojem štede energiju i time zapravo isključuju radio vezu. Svakim sljedećim povezivanjem javlja se kašnjenje sve dok se ponovno ne uspostavi radio veza. U nekim slučajevima, mreža može na neko vrijeme ukinuti resurse dodijeljene određenom uređaju i tada se kašnjenje dodatno povećava. Aplikacije vezane uz

baze podataka mogu ograničiti takva kašnjenja tako da održe mrežnu i radio alokaciju aktivnom s tzv. „lažnom“ transmisijom u slučaju da korisnik odmah reagira. Prije nego se izvrši ovakva transmisija, treba odlučiti može li se ona uopće primijeniti s obzirom na karakteristike aplikacije, odnosno kako se ona ponaša prilikom izvršavanja i/ili ažuriranja. Sve su to izazovi koji se nameću pred programere koji dizajniraju aplikaciju i oni trebaju biti upoznati s mogućnostima određenih uređaja i mreža.

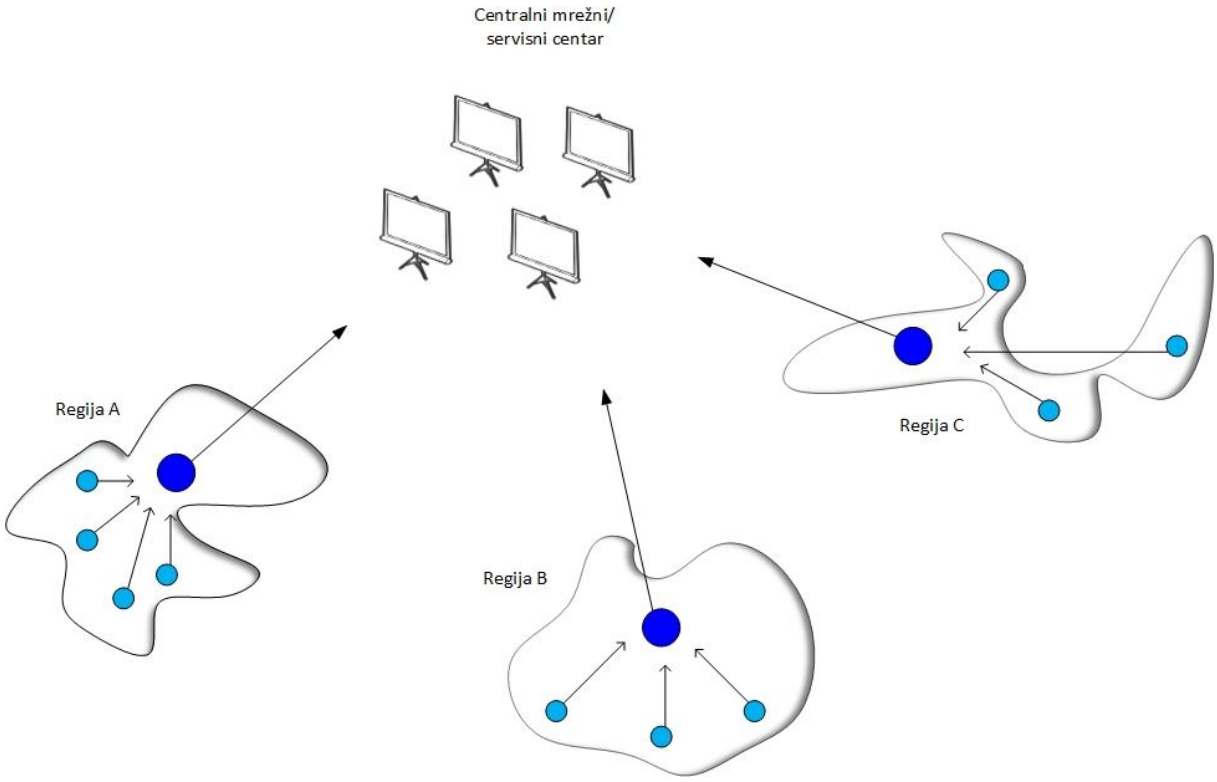
Web pregledavanje koje se obavlja kroz aplikaciju također ima zahtjeve u mobilnom okruženju koje treba ispuniti. Širina pojasa može varirati i/ili biti ograničena na mobilnim terminalnim uređajima i zbog toga prikaz *web* stranica treba prilagoditi karakteristikama pojedinog uređaja i performansama mreže. Kako u strujanju medija, tako i ovdje postoje razne tehnike kodiranja koje mogu poboljšati korisničko iskustvo. Prilikom obavljanja nekakvih zahtjevnijih aktivnosti koristeći *web* stranice, treba riješiti problem zagušenja koji se može javiti. Npr. prilikom preuzimanja najnovije verzije popularnog sadržaja među korisnicima, zagušenje je pojava koja se nerijetko javlja, a rezultira degradacijom korisničkog iskustva. Kako bi se spriječile takve situacije, opet odgovornost preuzimaju programeri koji i u ovom slučaju trebaju voditi računa o karakteristikama uređaja i mreža u svrhu što kraćeg vremena čekanja i poboljšanja korisničkog iskustva [8].

Kako bi aplikacija radila na ispravan način, potrebno je pogoditi odgovarajući aplikacijski kôd koji će odgovarati tipovima platformi i mreža na koje će se implementirati. Često takve radnje nisu jednostavne i potrebno je poznavanje performansi spomenutih platformi i mreže. Optimizacija aplikacijskog kôda provodi se na temelju točnih mjerenja i karakteristika mobilnih mreža nove generacije namijenjenih prijenosu podatkovnog prometa. Mjerenja kako se navodi u [9] obuhvaćaju niz parametra koji se uzimaju u obzir, a to su: broj pružatelja usluga, raznolikost korištenih protokola i mrežna arhitektura. Provedeno je nekoliko studija koje su bile usmjerene na potrebu optimizacije mrežne infrastrukture i uvida u mrežne performanse s korisničke perspektive. Studije su bile fokusirane na GSM (*Global System for Mobile Communications*) mrežu i CDMA tehnologiju.

5.2. Korišteni alat za praćenje performansi mreže

Aplikacija koja je korištena za dobivanje statističke analize podataka obrađuje preplavljenost i složenost podataka koji se prenose današnjih mobilnim širokopojasnim mrežama. Program je osmišljen tako da prikuplja ogromnu količinu podataka na različitim

mjernim točkama kako bi se na jasan način prikazalo stanje u mreži. S mogućnostima koje aplikacija pruža, operatori mogu osigurati odgovarajuću kvalitetu, za odgovarajuće korisnike, u odgovarajuće vrijeme. Korištenje aplikacije igra važnu ulogu u svakodnevnim operacijama mreže, jer omogućava otkrivanje mogućih problema prije nego što se oni pojave. Učinkovitost takvog rješenja ogleda se u tome da se podaci iz različitih izvora centraliziraju na jedno mjesto gdje se mogu spojiti i dobiva se jedinstven pogled na operacije koje se zbivaju unutar mreže. Opisani proces prikupljanja podataka prikazan je slikom 6. Na određenom regionalnom području postoji nekoliko mjernih točaka koje predstavljaju bazne stanice čiji se rezultati sumiraju u jednu zajedničku točku na području regije. Takvi rezultati se šalju u mrežni/servisni centar gdje se obrađuju i analiziraju za potrebe dostave operatoru koji ima ovlast za korištenje alata.



Slika 6. Shema rada dobavljača alata za mjerenje za sustav mobilnih mreža

Izvor: [10]

Razvojem telekomunikacijskih tehnologija više nije dovoljno samo nadgledati mrežu, već se fokusirati i na one segmente koji su bitni za pružanje visoko personaliziranih usluga korisnicima. To zahtijeva da operator ima mogućnost povezati podatke od same mreže pa

sve do razine pretplatnika. Alat koji je korišten za mjerenja na području jedne bazne stanice BTS1 služi za dobivanje pouzdanih informacija o izvedbi mreže, a u svrhu što boljeg poslovanja operatora. Kombiniranjem informacija kao što su: naplata, briga o korisniku i podaci o mreži omogućeno je postizanje potpunog prikaza svakog korisnika.

Osim prikupljanja i pohrane podataka iz cijele mreže, u konačni prikaz se pohranjuju i drugi relevantni podaci poput statistike grešaka, servisne informacije i sl. Upravljanje mrežom nije nužno vezano za analizu samo određenih podataka, već je bitna centralizacija svih vrsta podataka. Jedan od tipičnih primjera kod rada aplikacije je kombiniranje i uspoređivanje podataka prikupljenih na listu kako bi se utvrdilo odgovara li konfigurirani mrežni kapacitet količini prenesenog prometa. Podaci o mrežnim performansama tada su od izrazite važnosti, ali ih nije preporučljivo čuvati neobrađene duži vremenski period. Upravo iz tog razloga, sirovi, neobrađeni podaci se prikupljaju kako bi bilo moguće izvršiti učinkovitu analizu. Korišteni alat može dugoročno pohranjivati prikupljene podatke o mrežnim performansama i koristiti ih u izračunu ključnih pokazatelja uspješnosti i izvješćima. Razdoblja čuvanja sirovih informacija također se mogu prilagoditi potrebama operatora.

Dizajn aplikacije zamišljen je kao platforma prilagođena inovacijama koja podržava više proizvođača i više tehnologija. To je izrazito važno kada postoje kombinacije fiksno-mobilno gdje se tehnologija zapravo nalazi u fazi konsolidacije[17]. Isto tako, prisutna je podrška za široku paletu mrežnih elemenata različitih proizvođača, čime je postignuta interoperabilnost. Alat je multitehnologijski sustav koji pokriva 2G, 3G, LTE, transportnu, jezgrenu, fiksnu i IP mrežu. Još jedna bitna karakteristika odnosi se na operativne i kapitalne troškove u kojima se ostvaruju uštede na sljedeće načine: optimizacijom resursa, automatizacijom procesa i poboljšanom operativnom učinkovitošću. Vađenjem točnih izvješća o izvedbi, vrijeme planiranja optimizacije mreže smanjeno je za 10% do 50%. S druge strane ostvarivo je bolje planiranje opreme, precizno viđenje performansi mrežnih resursa, predvidljivost evolucije mreže i potrebe za proširenjem kapaciteta u mreži [10].

5.2.1. Funkcionalnosti alata s obzirom na interesne skupine

Upravljanje mrežnim performansama je vrlo kompleksan zadatak i obično je podijeljen između nekoliko interesnih skupina koje su navedene u tablici 5.

[17]Proces spajanja financijskih izvješća.

Tablica 5. Prikaz korisničkih grupa koje koriste alat

Korisničke grupe	Ciljevi korištenja alata
Planiranje i optimizacija	- praćenje kapaciteta mreže - praćenje kvalitete mreže - provjera pokrivenosti radijske mreže
Rad mreže i održavanje	- otkrivanje i rješavanje grešaka - uočavanje potencijalno problematičnih područja - praćenje statistike mreže - praćenje mrežnih proširenja i nadogradnji sustava
Menadžment	- dobivanje sažetih izvješća o kvaliteti mreže koji se koriste za procjenu poslovnih utjecaja - predviđanje budućih trendova
Briga o korisniku	- informiranje pretplatnika o trenutnim problemima - brže odgovaranje na pritužbe
Marketing	- dobivanje relevantnih podataka o ponašanju korisnika prema podacima vezanim uz korištenje mreže - planiranje novih usluga

Izvor: [10]

Tablični prikaz samo je okvirni pregled kojim područjima poslovanja alat može koristiti, iako je izvorno razvijen s ciljem zadovoljavanja navedenih zahtjeva korisničkih skupina.

5.2.2. Struktura i značajke aplikacije za mjerenje prometa

Kako bi se na što jednostavniji način izvršila mjerenja, a nakon toga dobila realna slika prometnog stanja u mreži, platforma je sastavljena od četiri osnovne komponente koje su odgovorne za sljedeće radnje:

- prikupljanje i obrada podataka
- dugoročno pohranjivanje podataka i particioniranje
- samoupravljanje
- upravljanje korisnicima.

Podaci se prikupljaju iz više sustava i smještaju u jednu centraliziranu bazu podataka. Obradu podataka je također korisno napraviti u ovom koraku s obzirom na to da je obrada zapravo dio postupka prikupljanja podataka. Dijelovi informacija mogu imati različite nazive brojača i različite raspone vrijednosti u mrežnim elementima različitih dobavljača, pa je zbog

toga važno pretvoriti podatke u neovisni XML (*eXtensible Markup Language*) format prije nego što su skladišteni u bazu. Nakon ekstraktiranja podataka, oni su skupljeni u tablice gdje se dalje obrađuju pomoću komponente za agregiranje. Agregiranje ili sažimanje podataka vrši se na temelju postojećih kriterija koji su bitni za operatore kako bi oni mogli vidjeti što se događa u različitim dijelovima mreže u određenom vremenskom intervalu. Prema zadanim postavkama, komponenta za agregiranje procjenjuje opterećenje vršnog sata za najčešće korištene vrste mjerenja, npr. koji dan i koji tjedan je vrijednost prometa kroz mrežu na najvišoj razini.

Baza podataka može biti skalirana i konfigurirati vrijeme pohrane za sirove i agregirane podatke kako bi se ispunili zahtjevi određene mreže. Shema baze podataka podijeljena je na dva modula: modul podrške koji podržava analizu podataka s obzirom na određenu mrežnu tehnologiju ili neki neovisni dio informacija, te podatkovni modul odgovoran za adresiranje podataka kada se nadograđuje shema baze. Alat za praćenje performansi mreže koristi *Oracle*[18] bazu podataka koja se navodi kao dobar izbor za pohranu velikih tablica. Tablice je isto moguće razvrstati po različitim značajkama, npr. vrijeme pri čemu pretraživanje traženih podataka postaje puno brže nego kada nema mogućnosti razvrstavanja.

Samoupravljanje u ovom kontekstu uključuje nadzor nad resursima operativnog sustava i baze podataka, te čišćenje baze podataka. Postoje alarmi koji se aktiviraju u određenim situacijama i pomažu da se pravovremeno poduzmu odgovarajuće radnje. Aktivnosti koje mogu pokrenuti alarme su npr. neuspješno povezivanje baza podataka, objedinjeni procesi agregacije, topologijske neusklađenosti, sintaktičke pogreške i sl. Osim toga, alati odgovorni za izvješća prate trajanje obrade podataka i agregacije što nadalje pomaže u planiranju nadogradnje hardvera ili promjene strategije agregacije.

Po pitanju korisničke administracije, alat podržava jednokratnu prijavu na sve aplikacije za izvješća. Autorizacija korisnika može se konfigurirati na razini aplikacije putem segmenta odgovornog za dozvolu.

Telekomunikacijska mreža sadrži velike količine podataka koji se moraju prikupiti za vršenje određenih operacija u mreži. Za svaku mrežnu domenu, alat nudi tehnološke module koji uključuju sljedeće:

[18]Više na: https://www.oracle.com/index.html

- neobrađeni podaci koji uključuju sve izvode iz mrežnih elemenata i dostupni su za izvješća
- agregacija podataka pri čemu se podaci prikupljaju u npr. vremenu ili drugim dimenzijama koje su definirane u tehnološkom modulu i pohranjene u bazi podataka
- sati vršnog opterećenja izračunati na dnevnoj i tjednoj bazi za određenu tehnologiju/dobavljača.

Prema potrebama korisnika podaci se mogu pohraniti na sirovoj ili sažetoj razini, gdje se sažeti podaci mogu pohraniti na vremenski period od nekoliko godina, ovisno o kapacitetima i raspoloživosti baze.

Kao što je navedeno u prethodnim odlomcima, aplikacija je osmišljena tako da može podržati različite tehnologije i opremu. Tehnološki moduli alata za praćenje performansi mreže dostupni su za sljedeće domene:

- LTE
- 3G RAN (UTRAN) / WCDMA
- BSS (*Base Station System*) / GSM
- NSS (*Network Switching Subsystem*) / R4 (*Release 4*)
- *Packet Core* (PaCo) / EPC (SGSN (*Serving GPRS Support Node*), GGSN (*Gateway GPRS Support Node*))
- VAS (*Value Added System*)
- MGW (*Media Gateway*)
- IMS i FMC (*Fixed Mobile Convergence*)
- SDM (*Subscriber Data Management*)
- MBH (*Mobile Backhaul*)
- IP.

Alat za praćenje mrežnih performansi, prema izvoru [10] nije ograničen samo na podržavanje mrežnih tehnologija tvrtke od koje je razvijen. Razvijen je tako da tehnologije trećih strana podržavaju sve potrebne aktivnosti na isti način kao i tehnologije izvorne tvrtke. U pravilu bi to značilo da je alat u stanju pružiti podršku za različite izvedbe mrežnih elemenata, tehnologija i sl.

5.2.3. Prikaz alata po segmentima

Kako bi se spriječili mogući problemi u mreži, važno je dobro razumijevanje podataka i segmenata kojima se izvlače pokazatelji uspješnosti mreže. Pomoću korištenog alata, operator može pregledavati i analizirati performanse mreže, pogreške i konfiguracije podataka koji dolaze iz različitih izvora. Sirovi podaci postaju smisleni onda kada se izvrši agregacija i kada su prikazani grafički i tekstualno. Ključni pokazatelji uspješnosti (KPI – *Key Performance Indicators*) najvažniji su pokazatelji uspješnosti mreže. Omogućuju operatoru da otkrije prve znakove degradacije performansi, spriječi razvoj kritičnih mrežnih problema, otklanja specifične elemente i analizira trendove izvedbe.

Slika 7 prikazuje prozore alata, tj. prikaz cjelokupnog „portala“. Kao što je navedeno ranije, alat pruža širok raspon funkcionalnosti i sučelja koja prikazuju različita izvješća namijenjena za sve skupine korisnika.



Slika 7. Prikaz sučelja alata za analizu prometa

Izvor: [10]

KPI i *Report Creator* predstavljaju segment koji obuhvaća sljedeće: definicije izvješća, definicije ključnih pokazatelja uspješnosti i javne/privatne dozvole.

Report Navigator zadužen je za: izvršavanje izvješća, uređivanje izvješća, planiranje izvješća i eksportiranje izvješća u različitim formatima.

Predefined content prozor daje grafički prikaz ključnih pokazatelja uspješnosti i izvješća, ali isto tako korisnik treba biti pretplaćen na tzv. operativni portal kako bi se dohvatila najnovija ažuriranja.

Customized workflow and content omogućuje prilagodljivost alata unutarnjim procesima poslovanja, te isporuku rezultata u obliku usluge ili prilagodljivom formatu.

Multiple report views daje izvješća u različitim oblicima: kontrolne ploče, više vrsta grafikona, geografski prikazi, tablice i sl.

Pristup navedenim stavkama, odnosno ključnim pokazateljima uspješnosti i izvješćima izvršava se pomoću centraliziranog portala za izvješćivanje koji se navodi kao fleksibilan, *user-friendly* i lagan za konfiguriranje [10].

6. Statistička analiza podataka o izmjerenom prometu po raznim kriterijima

Telekomunikacijski operatori za analizu prometa koriste alate koji su obično produkt tvrtke s kojom sklapaju ugovor o korištenju. Alati za praćenje mrežnih performansi omogućuju operatorima da pristupe podacima koji se šalju njihovom mrežom i tako pronalaze bolje načine pružanja telefonskih, internetskih i televizijskih usluga. S obzirom na skokovit razvoj ICT-a, nije iznenađujuća činjenica što pružatelji telekomunikacijskih usluga ulažu značajna sredstva za kvalitetne programe koji analiziraju podatke. Vrijednost analize podataka ovisi o sposobnosti softvera kojim se obavljaju mjerenja i analize. Softver u tom slučaju može primjerice izvući podatak kolika je prosječna isporuka video sadržaja korisniku i tako dati jasnu sliku telekom operatoru kako se njihovi resursi (npr. optički vodovi, sateliti) mogu iskoristiti za poboljšanje isporuke takvog sadržaja i sl.

U počecima razvoja telekomunikacijske industrije, operator je trebao uložiti značajna novčana sredstva kako bi uspostavio efikasnu infrastrukturu na zamišljenom području pokrivanja. Takva područja obično zauzimaju teritorij neke države, pa je jasno da postoje i varijacije u naseljenosti urbanih i ruralnih područja što je izrazito bitno kod planiranja mrežnih kapaciteta. Iako istraživači svakodnevno razvijaju nove informacijsko-komunikacijske tehnologije koje omogućavaju brži i učinkovitiji prijenos informacija, ekonomski je neisplativo postojeću infrastrukturu zamijeniti naprednijim sredstvima i elementima. Upravo iz tog razloga bitno je detaljno praćenje podataka kroz mrežu u stvarnom vremenu pri čemu se može povući paralela s opterećenošću, odnosno neiskorištenošću mrežnih kapaciteta na promatranom području.

Analiziranjem podataka o izmjerenom prometu po raznim kriterijima, telekom operatori mogu značajno smanjiti gubitak kada dođe do preopterećenosti mreže. Alat koji je korišten za potrebe pisanja ovog rada omogućuje operatoru da osim vođenja statistike o samom mrežnom prometu, također poboljša iskustva korisnika. Prikupljanjem informacija poboljšava se sposobnost prepoznavanja mogućnosti za nove, inovativne usluge na tržištu.

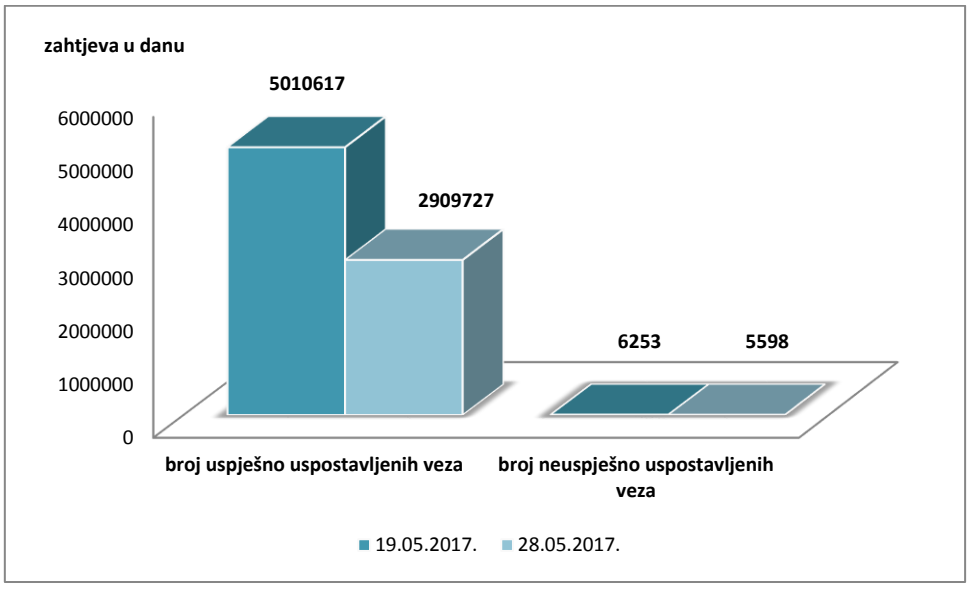
6.1. Statistička analiza podataka o prometu u ćeliji

Alatom koji je korišten za praćenje mrežnih performansi dobivene su vrijednosti koje prikazuju stanje u mreži po različitim kriterijima i značajkama. Mjerenje za potrebe ovog rada

je obavljeno u mreži mobilnog operatora za područje jedne bazne stanice za koju će se dalje u tekstu koristi naziv BTS1.

6.1.1. Rezultati mjerenja u danu

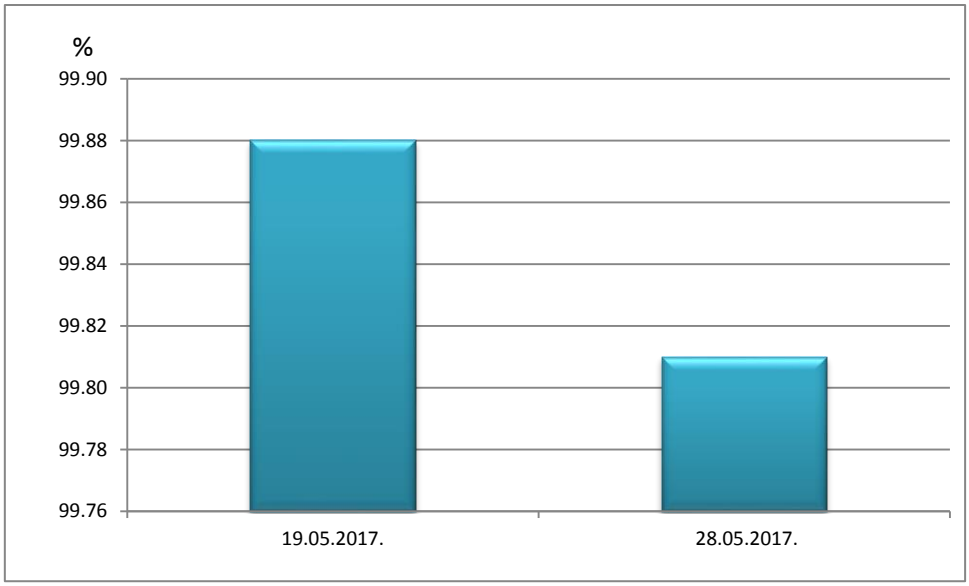
Radi preglednijeg prikaza rezultata, napravljena je paralelna usporedba mrežnih performansi u danu kada je bilo najveće opterećenje u mreži (19.05.2017.) i danu kada je bilo najmanje opterećenje u mreži (28.05.2017.), uzimajući u obzir činjenicu da su mjerenja praćena u razdoblju od 06.05.2017. – 04.06.2017. U nastavku ovog rada neće biti prikazana sva mjerenja koja alat može generirati, već sljedeća: uspješnost uspostavljanja veze, dostupnost kapaciteta ćelije, latencija i spektralna učinkovitost. Što se tiče mjerenja vezanih uz korisnike i korisničku opremu, prikazat će se: propusnost po korisničkoj opremi, broj aktivnih korisnika, aktivna korisnička oprema i udaljenost korisničke opreme.



Graf 1. Uspješnost uspostavljanja veze

Izvor: [10]

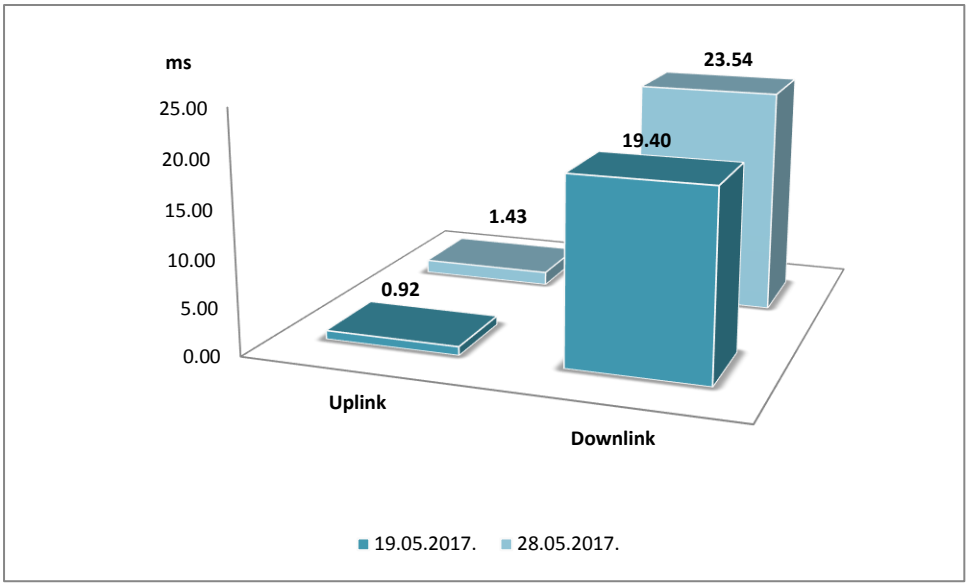
Grafom 1 prikazan je ukupan broj zahtjeva u danu (poziva, poruka itd.) za spajanjem na mrežu, na području jedne bazne stanice BTS1. U danu kada su korisnici najviše puta pokušali uspostaviti vezu, zabilježena je brojka od 5 016 870 pokušaja, od čega je ostvareno 5 010 617 pokušaja. U danu kada je bio najmanji broj pokušaja, 2 915 325, ostvarena je 2 909 727 konekcija. Također je prikazan broj zahtjeva kada nije bilo moguće uspostaviti konekciju, pa on u prvom slučaju (19.05.2017.) iznosi 6 253, a u drugom slučaju (28.05.2017.) 5 598.



Graf 2. Postotak raspoloživosti kapaciteta ćelije

Izvor: [10]

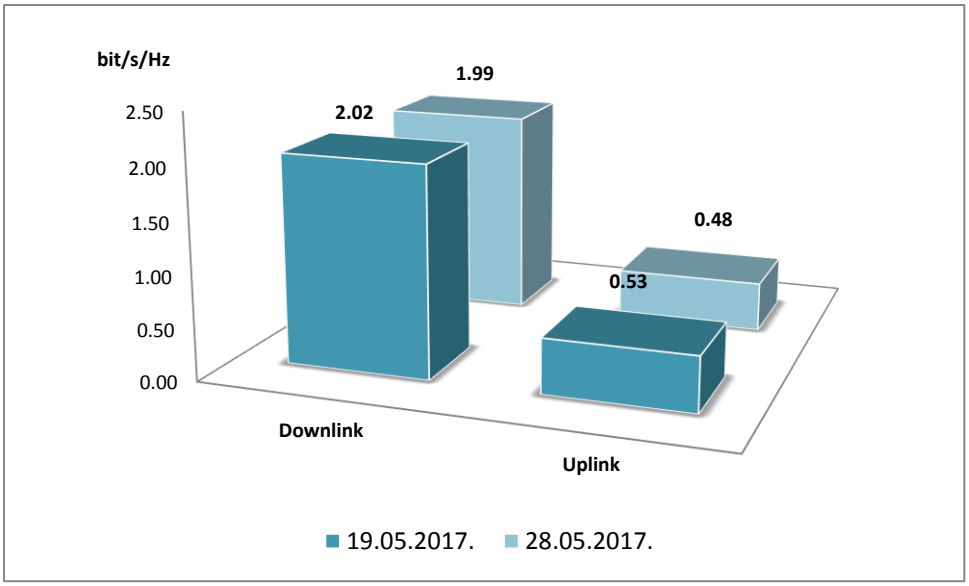
Različiti broj uspostavljenih veza u različitim danima utječe na postotak raspoloživosti kapaciteta ćelije, prikazano grafom 2. U danu kada je bilo više zahtjeva raspoloživost iznosi 99.88%, a u danu s manje zahtjeva raspoloživost je 99.81%. Priložena mjerenja, odnosno odstupanja od potpune (100%-tne) raspoloživosti u skladu su s brojem neuspjelih pokušaja uspostavljanja veze prikazanih na grafu 1. Iako je odnos broja uspostavljenih i neuspostavljenih veza u danu s najvećim brojem zahtjeva i u danu s najmanjim brojem zahtjeva neočekivan, tj. zanemarivo je malena razlika u broju neuspostavljenih veza za ta dva dana (svega 655 veza), dok razlika u boju uspostavljenih veza za dva promatrana dana iznosi 2 100 893. Razlog tomu može se tražiti u količini prometa koje su generirale pojedine uspostavljene aplikacije. Na to upućuju i podaci o raspoloživosti kapaciteta ćelije, raspoloživost je manja za dan kada je bilo manje zahtjeva za uspostavom veze.



Graf 3. Latencija

Izvor: [10]

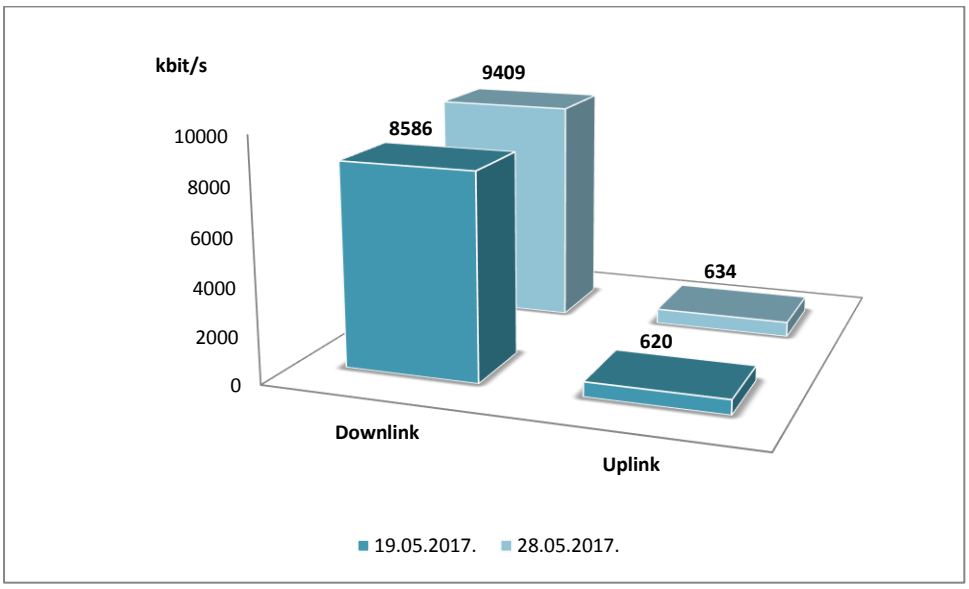
Prosječna latencija u danu kada je mreža bila najviše opterećena, iznosila je 0,92 ms u uzlaznoj vezi i 19,40 ms u silaznoj vezi. S druge strane, u danu s manjim brojem zahtjeva za spajanjem na mrežu, u uzlaznoj vezi iznosi 1,43 ms, dok je u silaznoj bila 23,54 ms. Iz navedenih rezultata mjerenja, prikazanih grafom 3, vidljivo je povećanje latencije u danu s manjim brojem zahtjeva. Razlog tomu može biti, kako je prethodno navedeno, da broj uspješno uspostavljenih zahtjeva nije generirao istu količinu prometa u navedenim danima. Kako je latencija povezana s propusnošću po korisniku, odnosno ukupnim prometnim opterećenjem ćelije, iz prikazanih podataka može se zaključiti da u danu s manjim brojem zahtjeva je bilo znatno veće prometno opterećenje. Osim prometnog opterećenja u ćeliji, na latenciju djeluje i udaljenost korisničke opreme od bazne stanice BTS1. Tako da je na prosječnu latenciju toga dana mogao djelovati i raspored korisnika u ćeliji.



Graf 4. Spektralna učinkovitost

Izvor: [10]

Prosječna spektralna učinkovitost prikazana grafom 4, kao mjera kvalitete digitalnog signala, veća je u danu s većim brojem aktivnosti i iznosi 2,02 bit/s/Hz u silaznoj, odnosno 0,53 bit/s/Hz u uzlaznoj vezi. U danu s manjim prometnim opterećenjem, rezultati mjerenja iznose: 1,99 bit/s/Hz u silaznoj i 0,48 bit/s/Hz u uzlaznoj vezi.

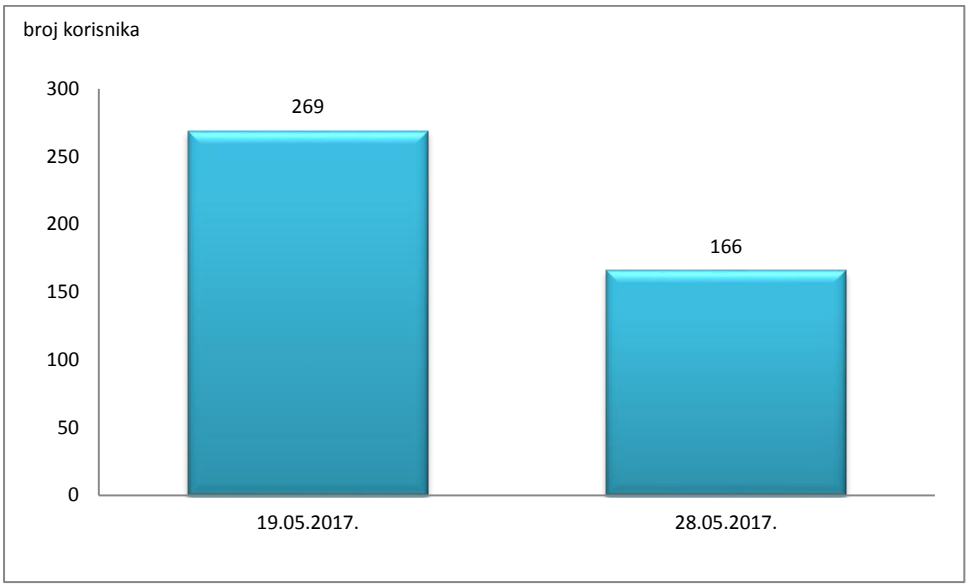


Graf 5. Prosječna propusnost po korisniku

Izvor: [10]

Graf 5 daje pregled prosječne propusnosti po korisniku u navedenim danima. Mjerenja su također prikazana s obzirom na silaznu i uzlaznu vezu. Prosječna propusnost u silaznoj vezi 19.05.2017. iznosila je 8 586 kbit/s, dok je u uzlaznoj iznosila 620 kbit/s. U

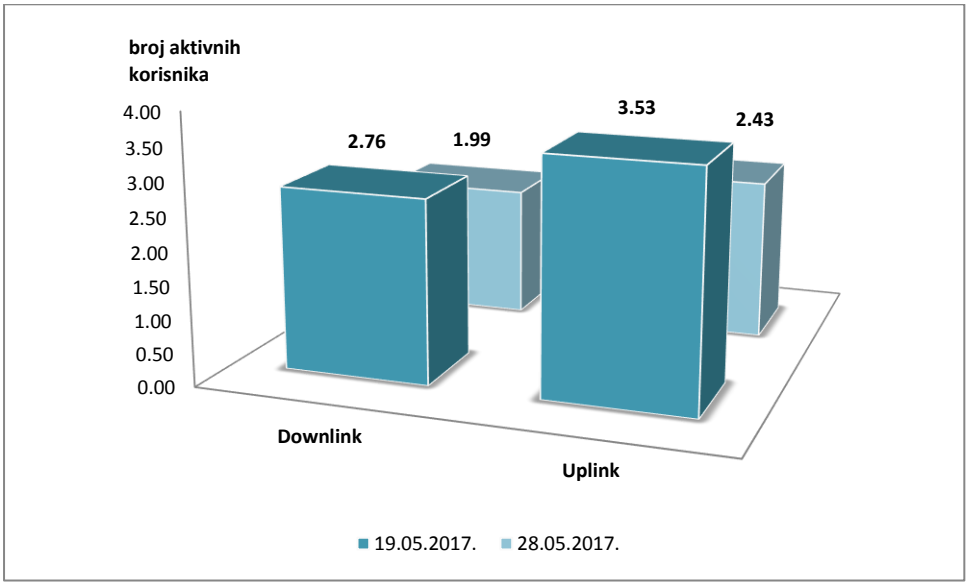
slučaju manjeg opterećenja, prosječna propusnost na *downlink-u* je očekivano bila veća i iznosila 9 409 kbit/s, a na *uplink-u* 634 kbit/s.



Graf 6. Maksimalan broj aktivnih korisnika

Izvor: [10]

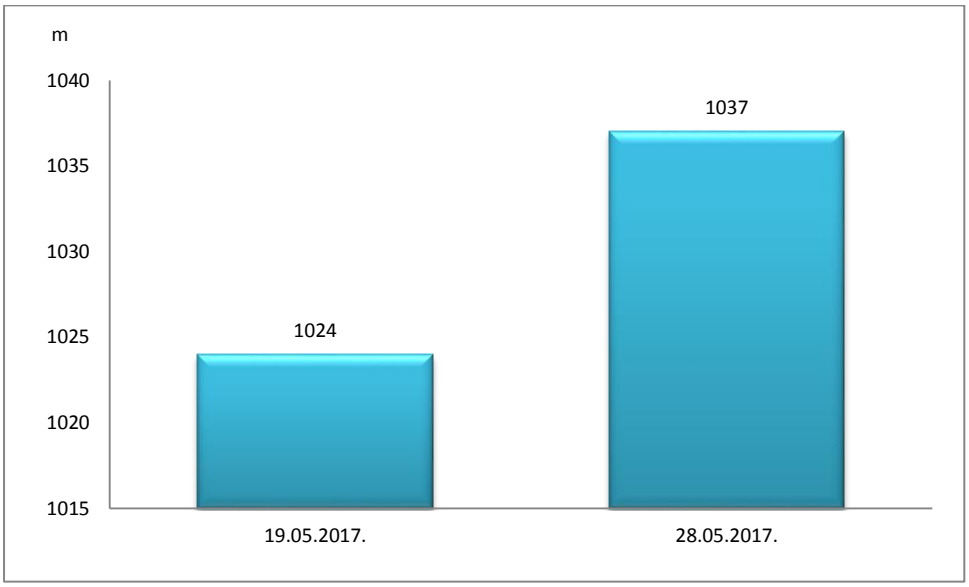
Maksimalan broj aktivnih korisnika koji je zabilježen u nekom trenutku mjerenja na području bazne stanice BTS1 varira u svakom danu. Grafom 6 prikazane su varijacije u različitim danima, te je vidljivo da je 19.05.2017. ta brojka iznosila 269, dok je 28.05.2017. iznosila 166.



Graf 7. Prosječan broj aktivnih korisnika čiji podaci su stavljeni u *buffer*

Izvor: [10]

Graf 7 prikazuje prosječan broj aktivnih korisnika čiji podaci su stavljeni u međuspremnik (*buffer*) u silaznoj i uzlaznoj vezi. Cilj mjerenja je prikazati prosječan broj aktivnih korisnika, tj. aktivne korisničke opreme čiji podaci se prenose i primaju putem aplikacija implementiranih u opremu. QCI (*QoS Class Identifier*) je mehanizam korišten u LTE mreži koji osigurava odgovarajuću kvalitetu usluge za promet koji se šalje signalom nositeljem. Različiti promet koji generira signal zahtijeva različitu kvalitetu usluge i različite QCI vrijednosti. Npr. QCI vrijednosti 9 se obično koristi za signal nositelj one korisničke opreme koja je u vlasništvu pretplatnika koji nisu prijavljeni. Prema mjerenjima na području bazne stanice BTS1, u silaznoj vezi zabilježena je brojka 2,76 aktivnih korisnika, a u uzlaznoj 3,53 aktivnih korisnika kada je riječ o danu s većim opterećenjem. S druge strane 28.05.2017. bilježi 1,99 aktivnih korisnika u silaznoj vezi i 2,43 aktivnih korisnika u uzlaznoj vezi.



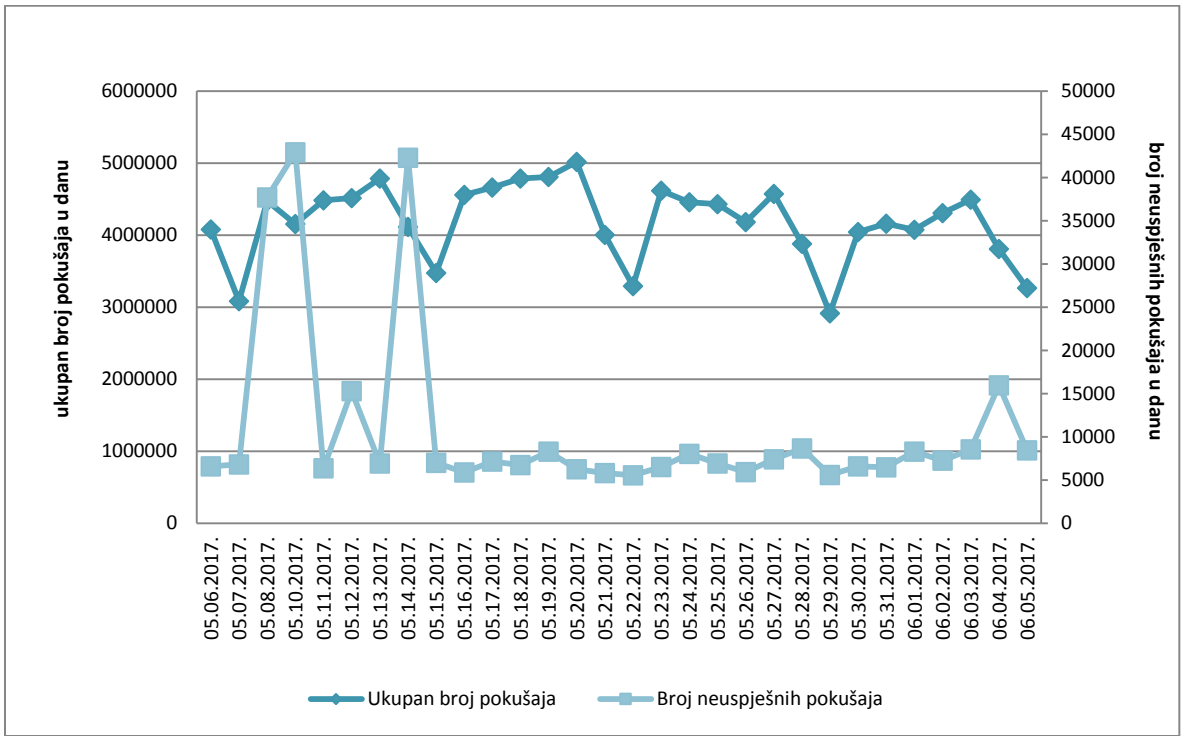
Graf 8. Prosječna udaljenost korisničke opreme

Izvor: [10]

Zadnje mjerenje koje je prikazano na grafu 8 odnosi se na prosječnu udaljenost korisničke opreme od bazne stanice BTS1. Prvog navedenog datuma udaljenost je iznosila 1 024 m, a drugog datuma 1 037 m. Prikazane udaljenosti utječu na izmjerene parametre koji su prikazani prethodnih grafovima. Omjer broja uspješno uspostavljenih veza razlikuje se u navedenim danima kada su provedena mjerenja. U danu kada je prosječna udaljenost korisničke opreme od antene bila manja, zabilježen je manji broj neuspješno uspostavljenih veza. Istog dana (19.05.2017.) zabilježena je i manja latencija, što potvrđuje prethodno navedene zaključke vezano uz latenciju i udaljenost korisničke opreme od bazne stanice.

6.1.2. Rezultati mjerenja u razdoblju od mjesec dana

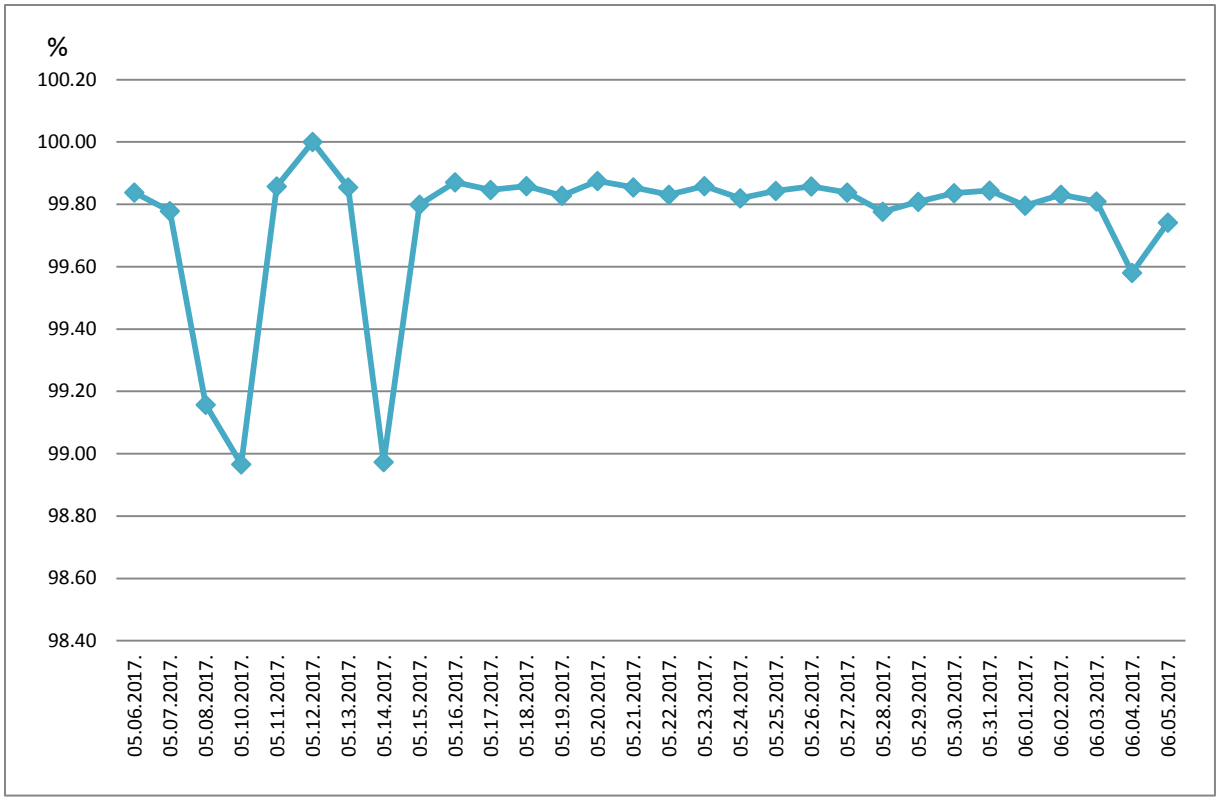
Nakon analize podataka mjerenja napravljena u dva dana, danu kada je bilo najviše zahtjeva za pristupanjem mreži i danu kada je bilo najmanje zahtjeva za pristupanjem mreži, prikazat će se rezultati mjerenja kroz mjesec dana. Ovakva mjerenja pogodna su za promatranje ponašanja mreže kroz duži vremenski period iz kojih je moguće izvući objektivno stanje u mreži.



Graf 9. Uspješnost povezivanja na mrežu

Izvor: [10]

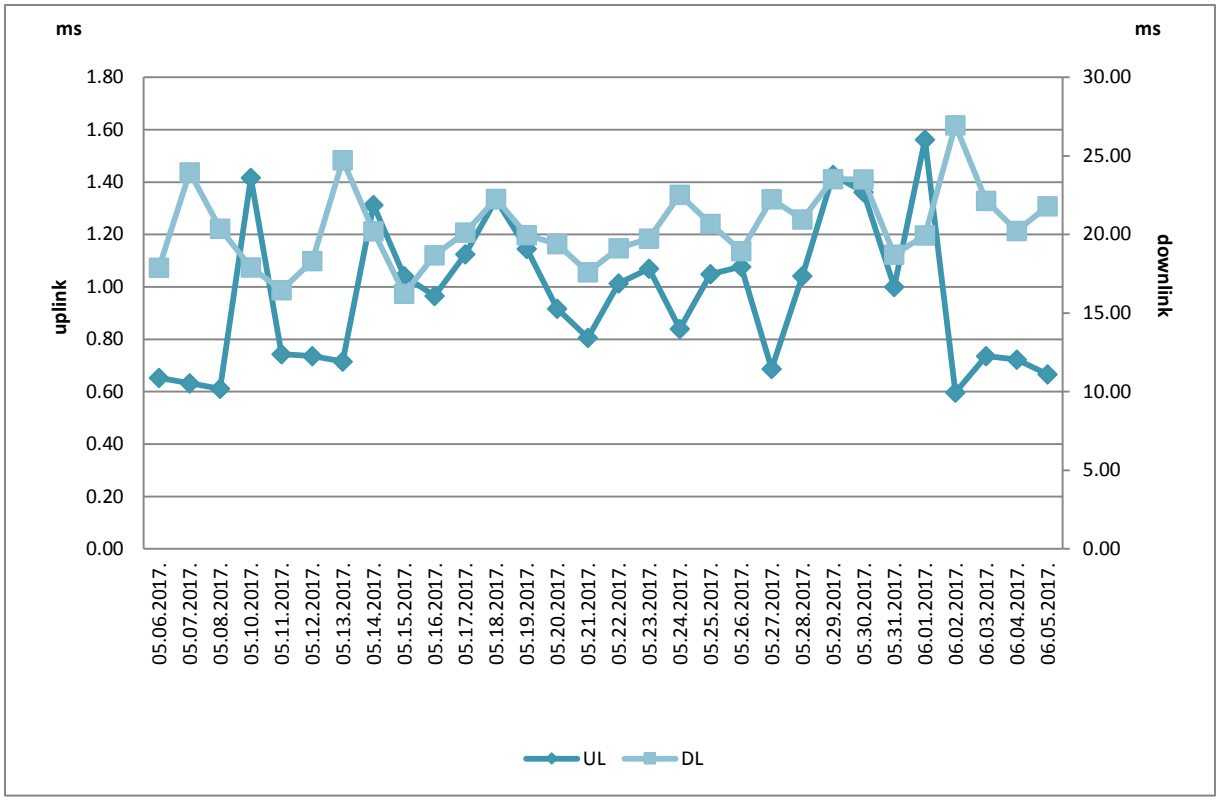
Graf 9 prikazuje ukupan broj pokušaja povezivanja na mrežu i koliki je broj neuspješnih pokušaja. Kako je vidljivo s grafa te vrijednosti variraju iz dana u dan, odnosno pokazuju da raspoloživost kapaciteta ćelije nije jednaka svakog dana u mjesecu, zbog čega je određeni broj zahtjeva odbijen.



Graf 10. Raspoloživost kapaciteta ćelije

Izvor: [10]

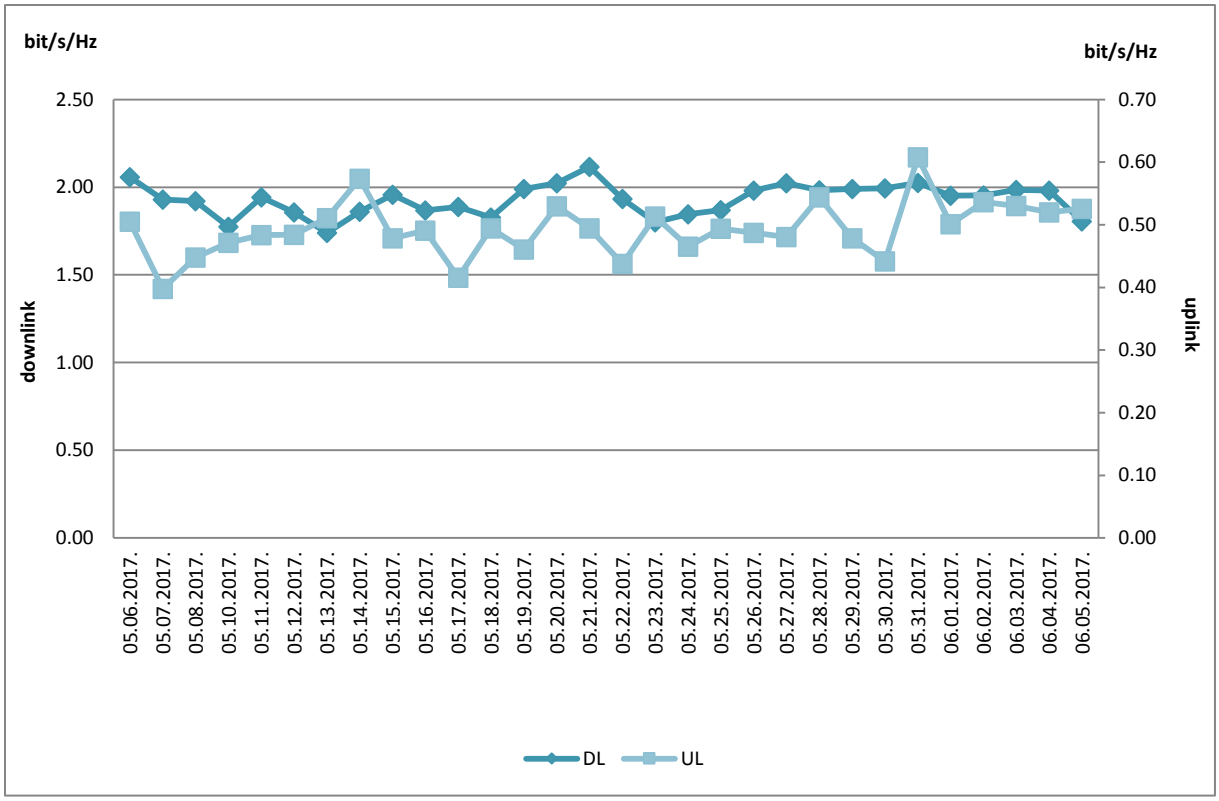
Raspoloživost kapaciteta ćelije, prikazana grafom 10, daje informaciju o tome je li kapacitet ćelije koja prekriva područje dostatan za količinu zahtjeva za spajanje na mrežu. 100%-tna raspoloživost zabilježena je samo 12.05.2017. Podaci prikazani na ovom grafu ukazuju na razlog povećanog broja odbijenih zahtjeva za tri analizirana dana (8., 10. i 14. svibnja) što je prikazano na grafu 9.



Graf 11. Vrijednosti latencije

Izvor: [10]

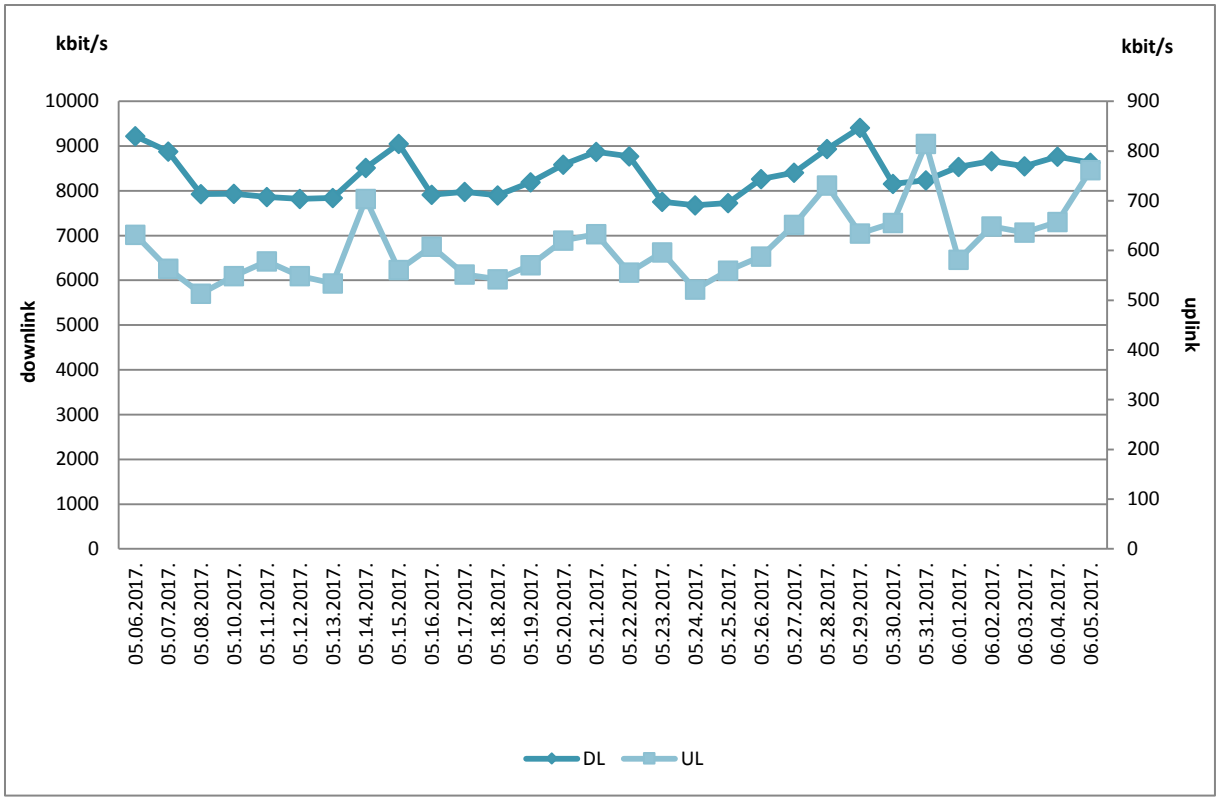
Vrijednosti latencije u uzlaznoj i silaznoj vezi kroz razdoblje od mjesec dana prikazane su na grafu 11. Postoje varijacije u odnosu na količinu zahtjeva za spajanjem na mrežu. Najviša vrijednost dostignuta je 02.06.2017. kada je broj pokušaja za uspostavljanjem veze iznosio 4 491 532. To nije maksimalan broj pokušaja koji je zabilježen u danima mjerenja, što znači da latencija ne ovisi samo o broju zahtjeva, već o količini generiranog prometa. Isto tako, u danu kada je izmjerena najviša vrijednost, izmjerena je najveća udaljenost korisničke opreme od bazne stanice BTS1.



Graf 12. Spektralna učinkovitost

Izvor: [10]

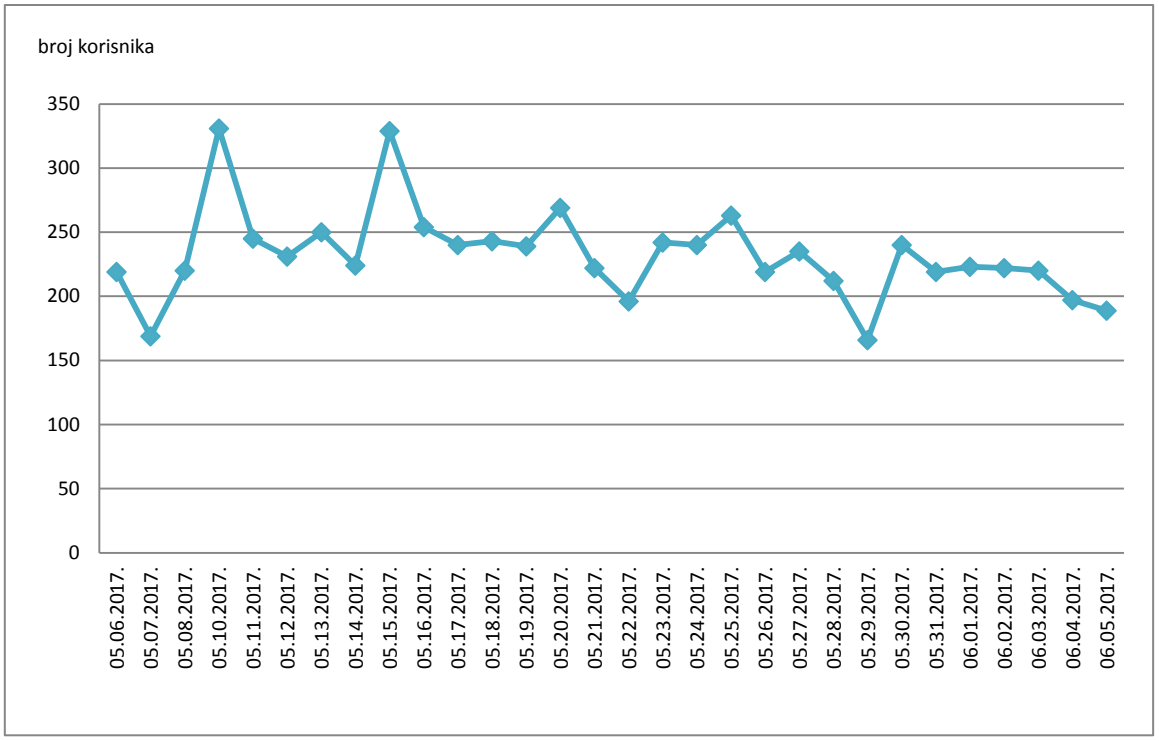
Spektralna učinkovitost prikazana grafom 12 poprima različite vrijednosti izmjerene u pojedinom danu, međutim nisu uočena prevelika odstupanja bilo da je riječ o silaznoj vezi ili uzlaznoj vezi. Spektralna učinkovitost je zapravo broj prenesenih bita u sekundi po jedinici širine pojasa, a ovisi o modulaciji koja se koristi. S obzirom na to da se u LTE mreži koristi drugačija shema modulacije za *downlink* i *uplink*, postoji razlika. U silaznoj vezi koristi se OFDM (*Orthogonal Frequency Division Multiplexing*) modulacija u kojoj se koristi veliki broj prijenosnih frekvencija točno određene širine, dok se u uzlaznoj vezi koristi SC-FDMA (*Single Carrier Frequency Division Multiple Access*) modulacija koja iskorištava prednosti OFDM-a, a istovremeno rješava problem velikih varijacija koje mogu nastati kao posljedica neefikasnog korištenja spektra.



Graf 13. Propusnost po korisničkoj opremi

Izvor: [10]

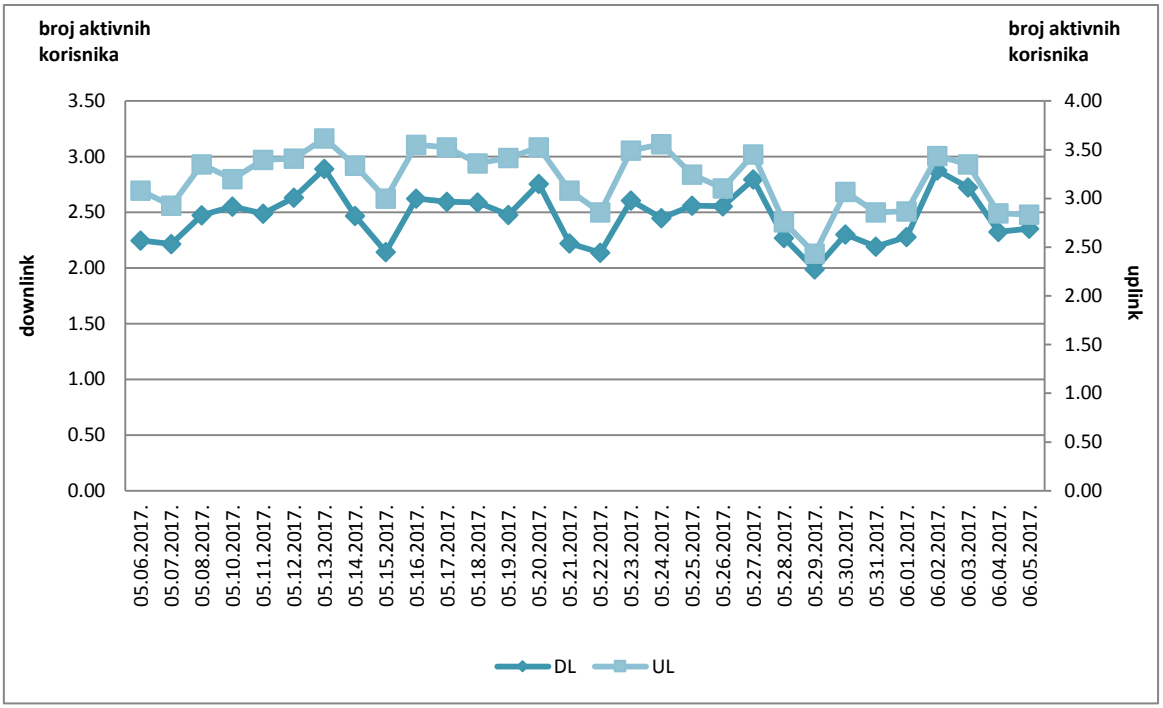
Prosječna propusnost po korisničkoj opremi praćena u razdoblju od mjesec dana varira od 7 679 kbit/s do 9 409 kbit/s u silaznoj vezi, te od 521 kbit/s do 761 kbit/s u uzlaznoj vezi. Podaci su prikazani na grafu 13, a uočena je i povezanost s prethodno objašnjenom spektralnom učinkovitosti.



Graf 14. Maksimalan broj aktivnih korisnika

Izvor: [10]

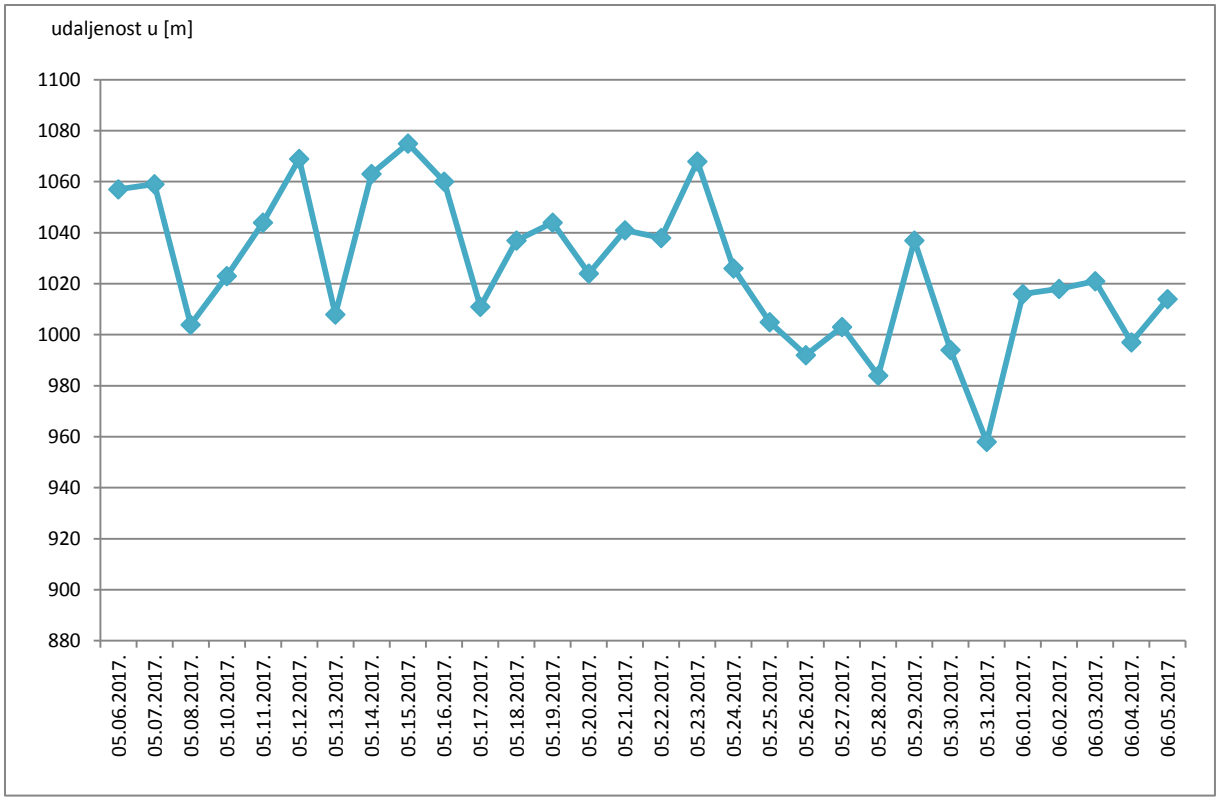
Aktivnost korisnika u razdoblju od 06.05.2017. do 05.06.2017. vidljiva je na grafu 14. Najveća izmjerena vrijednost aktivnih korisnika iznosi 331 korisnik, a najmanja 166. Alat za mjerenje mrežnih performansi u ovom slučaju bilježi maksimalan broj aktivnih korisnika u određenom trenutku mjerenja.



Graf 15. Prosječan broj aktivnih korisnika čiji podaci su stavljeni u *buffer*

Izvor: [10]

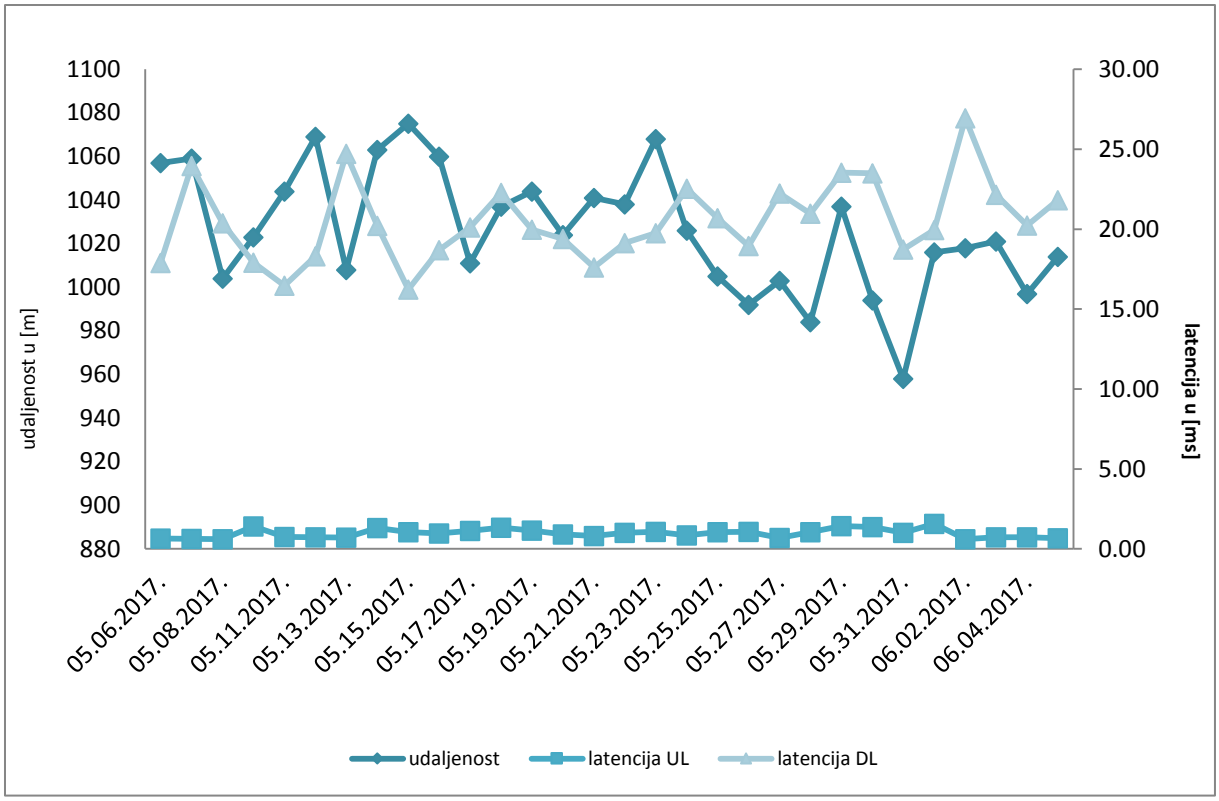
Grafom 15 prikazan je prosječan broj aktivnih korisnika čiji podaci su stavljeni u *buffer* u silaznoj i uzlaznoj vezi. U razdoblju u kojem su provedena mjerenja (06.05.2017. – 05.06.2017.) izmjerene su različite vrijednosti u svakom danu. Najmanja zabilježena vrijednost iznosi 1,99 korisnika u silaznoj vezi i 2,43 korisnika u uzlaznoj vezi, dok je najveća izmjerena vrijednost 2,89 korisnika u silaznoj vezi i 3,62 korisnika u uzlaznoj vezi.



Graf 16. Udaljenost korisničke opreme

Izvor: [10]

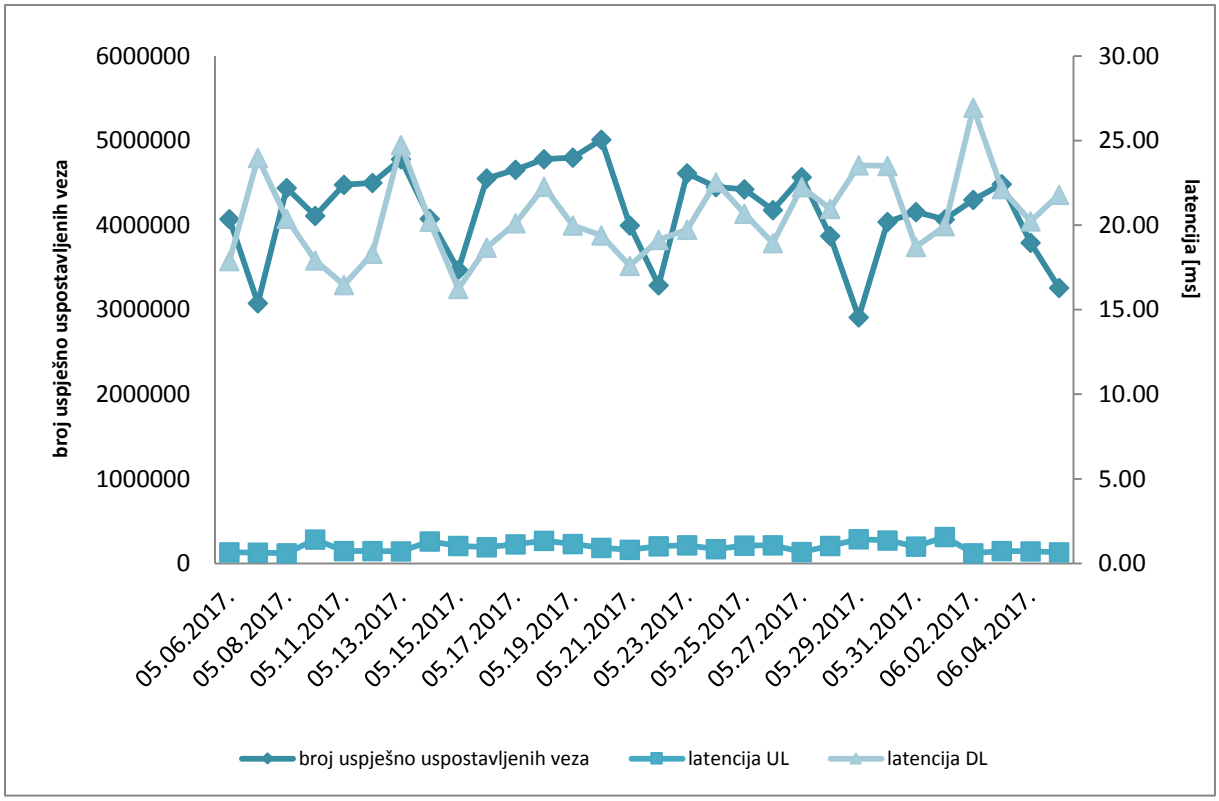
Alatom za praćenje mrežnih performansi izmjerena je prosječna udaljenost korisničke opreme od bazne stanice BTS1, prikazano na grafu 16. Ovisno o poziciji korisnika, ta vrijednost varira u svakom danu. Najveća udaljenost izmjerena je 15.05.2017., a najmanja 31.05.2017. Prikazane udaljenosti utječu na izmjerene parametre koji su prikazani prethodnim grafovima.



Graf 17. Utjecaj prosječne udaljenosti na latenciju

Izvor: [10]

Na grafu 17 prikazan je utjecaj prosječne udaljenosti korisničke opreme od bazne stanice BTS1 na latenciju. Vidljive su varijacije iz dana u dan što se tiče prosječne udaljenosti korisničke opreme od bazne BTS1, a s udaljenošću varira i latencija. Povezanost između udaljenosti i latencije vidljiva je tek na lijevoj polovici grafa, što znači da udaljenost nije jedini faktor koji utječe na latenciju.



Graf 18. Utjecaj uspješno uspostavljenih veza na latenciju

Izvor: [10]

Graf 18 prikazuje ovisnost latencije o broju uspješno uspostavljenih veza promatranih u prikazanom razdoblju. Latencija i broj uspješno uspostavljenih veza mogu imati utjecaj jedno na drugo tako da broj takvih veza utječe na latenciju, ali ne nužno. Veći broj uspješno uspostavljenih veza ne znači da je ostvaren veći promet. Osim prometa, na latenciju utječe prosječna udaljenost korisničke opreme prikazana na prethodnom grafu.

6.2. Mogućnosti primjene dobivenih rezultata

Mreže nove generacije kao što je LTE sastoje se od višestrukih radio tehnologija i komponenata koje su često proizvodi različitih dobavljača. Kako bi se izradilo dosljedno, smisleno izvješće, poželjno je konsolidirati podatke različitih tehnologija i dobavljača. Alatom za praćenje mrežnih performansi korištenim u ovom radu moguće je pružiti takvu vrstu izvještaja jer omogućuje prilagođene hijerarhijske definicije i prilagođena izvješća. Izvještaj koji obuhvaća više tehnologija i više dobavljača omogućuje cjelokupni pregled u kojem kombiniranje ćelija koje podržavaju različite tehnologije i različite dobavljače pružaju prikaz izvedbe mreže. Mogućnost prilagodbe hijerarhije, tj. razine grupiranja podataka dobivaju se različiti ključni pokazatelji uspješnosti koji su izrazito važni za operatora. Alat ima sposobnost

generiranja korisničkih prilagođenih izvješća koja imaju naglasak na specifične karakteristike vezane uz praćenje korisničkog ponašanja.

7. Zaključak

Mjerenje i analiza korištenja podatkovnih usluga i prometa u LTE mreži važni su procesi koji prikazuju realno stanje u mreži. Prikupljanje takvih informacija koristi različitim interesnim skupinama unutar telekomunikacijskog lanca vrijednosti kako bi unaprijedili svoje poslovanje, odnosno kvalitetu korisničkog iskustva. Nove usluge i aplikacije koje se svakodnevno razvijaju i stavljaju na tržište zahtijevaju određeno unaprjeđenje mrežnih elemenata LTE mreže u odnosu na prethodne generacije mobilnih mreža. Prikazom i analizom arhitekture LTE mreže, opisani su procesi koji se događaju u pristupnom i jezgrenom dijelu mreže kako bi se uspješno obavio prijenos podataka. Važnu ulogu prilikom slanja paketa od izvorišta do odredišta imaju protokoli kao skup pravila prema kojima se obavlja proces slanja paketa. Podatkovni promet moguće je klasificirati prema više kriterija kako bi se kasnije lakše taj isti promet analizirao. Razvijeni su brojni alati i metode na tržištu koji omogućuju postavljanje mjernih točaka u mreži i proučavaju ponašanje prometa u mreži. Analizom nekoliko njih u ovom radu, vidljivo je da se mogu koristiti na različitim čvorovima ili linkovima u LTE mreži, ali isto tako na jednoj ili više lokacija, ovisno o funkcionalnostima i namjeni. S obzirom na sve veći razvoj mobilnih platformi, a samim time i aplikacija, mjerenja internetskog prometa također se vrše unutar različitih tipova aplikacija.

Analizom prometa i mrežnih performansi za podatke prikupljene pomoću alata za praćenje mrežnih performansi prikazano je variranje pojedinih vrijednosti tijekom perioda promatranja. Analizom podataka predočenom grafičkim prikazima za područje jedne bazne stanice moguće je komparirati dobivene rezultate za iste periode i donositi određene zaključke. Iz prikaza mogu se uočiti povezanosti pojedinih dobivenih rezultata, (npr. latencija i udaljenost korisničke opreme, raspoloživost kapaciteta ćelije i broja odbijenih zahtjeva itd.). Grupiranjem podataka dobivaju se različiti ključni pokazatelji uspješnosti, koji svojim brojčanim i grafičkim prikazom opisuju poslovanje određene telekom kompanije. Nakon praćenja mrežnih performansi kroz određeni vremenski period, kreiraju se izvješća na temelju kojih se dobiva cjelokupno stanje u mreži. Praćenjem i analizom prikupljenih podataka može se:

- odrediti potrebni kapacitet bazne stanice i mreže u cijelosti za najopterećeniji period dana

- odrediti područja (geografska) na kojima je veća koncentracija prometa, odnosno ona područja gdje su mrežni elementi znatno ispod opterećenja
- identificirati ponašanje prometa od pojedinih aplikacija i ponašanje korisnika.

LITERATURA

[1] Palat S., Godin P. The LTE Network Architecture. Alcatel - Lucent. 2009. Dostupno:

http://www.cse.unt.edu/~rdantu/FALL_2013_WIRELESS_NETWORKS/LTE_Alcatel_White_Paper.pdf

[2] SesiaS., Toufik I., Baker M. LTE – The UMTS Long Term Evolution, 2nd Edition. John Wiley & Sons Ltd. United Kingdom; 2011

[3] Riikonen A. Mobile Internet Usage - Network Traffic Measurements. Master'sThesis. Helsinki; Espoo; 2009. Dostupno: http://lib.tkk.fi/Dipl/2009/urn100072.pdf

[4] Mrvelj Š. Autorizirana predavanja. Fakultet prometnih znanosti; Zagreb; 2015. Dostupno: http://e-student.fpz.hr/

[5] Kalden R. A. Mobile Internet Traffic Measurement and Modeling Based on Data from Commercial GPRS Networks. Disertation. Kassel; Germany; 2004. Dostupno:

https://core.ac.uk/download/pdf/11458725.pdf

[6] Sandvine Incorporate ULC. Identifying and Measuring Internet Traffic: Techniques and Considerations. United Kingdom; 2015. Dostupno:

https://www.sandvine.com/downloads/general/whitepapers/identifying-and-measuring-internet-traffic.pdf

[7] Mahanti A. Internet Traffic Measurement. Dostupno:

http://130.216.33.163/courses/compsci314s2c/lectures/anm/InternetMeasurement.pdf

[8] Wittie M. P., Stone-Gross B., Almeroth K. C., Belding E. M. MIST: Cellular Data Network Measurement for Mobile Applications. California. Dostupno:

http://people.cs.ucsb.edu/ebelding/sites/people/ebelding/files/publications/broadnets07_mist.pdf

[9] Kaup F., Jomrich F., Hausheer D. Demonstration of Network Coverage – A Mobile Network Performance Measurement App. Darmstadt; Germany; 2004. Dostupno:

https://www.netsys2015.com/wp-content/uploads/NetSys2015_Demo_Kaup.pdf

[10] Interni dokumenti mrežnog operatora; 2015.; 2017.

POPIS SLIKA

Slika 1. Arhitektura LTE mreže 7

Slika 2. Prikaz HPMN i VPLM u *roaming*-u 11

Slika 3.Protokolni složaj internetske mreže 13

Slika 4. Proces aktivnog mjerenja prometa 23

Slika 5. Proces pasivnog mjerenja prometa 24

Slika 6. Shema rada dobavljača alata za mjerenje za sustav mobilnih mreža 34

Slika 7. Prikaz sučelja alata za analizu prometa 39

POPIS TABLICA

Tablica 1. Kategorizacija korisničke opreme 6

Tablica 2. Pregled mogućih kategorija prometa 18

Tablica 3. Pregled mogućih klasa prometa 19

Tablica 4. Tipovi mobilnih aplikacija 31

Tablica 5. Prikaz korisničkih grupa koje koriste alat 36

POPIS GRAFOVA

Graf 1. Uspješnost uspostavljanja veze 42

Graf 2. Postotak raspoloživosti kapaciteta ćelije 43

Graf 3. Latencija 44

Graf 4. Spektralna učinkovitost 45

Graf 5. Prosječna propusnost po korisniku 45

Graf 6. Maksimalan broj aktivnih korisnika 46

Graf 7. Prosječan broj aktivnih korisnika čiji podaci su stavljeni u *buffer* 46

Graf 8. Prosječna udaljenost korisničke opreme 47

Graf 9. Uspješnost povezivanja na mrežu 48

Graf 10. Raspoloživost kapaciteta ćelije 49

Graf 11. Vrijednosti latencije 50

Graf 12. Spektralna učinkovitost 51

Graf 13. Propusnost po korisničkoj opremi 52

Graf 14. Maksimalan broj aktivnih korisnika 53

Graf 15. Prosječan broj aktivnih korisnika čiji podaci su stavljeni u *buffer* 54

Graf 16. Udaljenost korisničke opreme 55

Graf 17. Utjecaj prosječne udaljenosti na latenciju 56

Graf 18. Utjecaj uspješno uspostavljenih veza na latenciju 57

POPIS DIJAGRAMA

Dijagram 1. Proces prijenosa podataka..... 15

POPIS KRATICA

2G	(2nd Generation) druga generacija mobilne mreže
3G	(3rd Generation) treća generacija mobilne mreže
3GPP	(3rd Generation Partnership Project) naziv za suradnju telekomunikacijskih organizacija
APN	(Access Point Name) mrežni čvor između mobilne i računalne mreže
AS	(Access Stratum) protokolni sloj između radio mreže i korisničke opreme
AuC	(Authentication Center) komponenta odgovorna za validnost SIM kartice
BSS	(Base Station System) sustav baznih stanica
CDMA	(Code Division Multiple Access) vrsta multipleksa bazirana na kôdu
DNS	(Domain Name System) servis vezan za nazive domena
DPI	(Deep Packet Inspection) napredna metoda filtriranja podataka
EPC	(Evolved Packet Core) unaprijeđeni jezgreni dio LTE mreže
EPS	(Evolved Packet System) unaprijeđeni sustav LTE mreže
E-SMLC	(Evolved Serving Mobile Location Center) mrežni element zadužen za lociranje
E-UTRAN	(Evolved Terrestrial Radio Access Network) unaprijeđena UMTS mreža
FMC	(Fixed Mobile Convergence) fiksno-mobilna konvergencija
FTP	(File Transfer Protocol) protokol za razmjenjivanje datoteka između terminala
GGSN	(Gateway GPRS Support Node) omogućuje komunikaciju između pretplatnika i vanjskih *host*-ova u mreži
GMLC	(Gateway Mobile Location Centre) mrežni element koji omogućuje lokacijske usluge
GPRS	(General Packet Radio Service) standard koji omogućava bežični prijenos podataka kroz GSM mrežu
GPS	(Global Positioning System) sustav koji omogućuje pozicioniranje
GSM	(Global System for Mobile Communications) globalni standard mobilne telefonije
HD	(High Definition) medij visoke rezolucije i kvalitete
HPMN	(Home Public Mobile Network) mreža na koju je pretplatnik pretplaćen
HSS	(Home Subscriber Server) baza korisničkih podataka
HTTP	(HyperText Transfer Protocol) glavni protokol za prijenos informacija na

	Internetu
ICMP	(Internet Control Message Protocol) protokol za kontrolu internetskog prometa
ICT	(Information and Communication Technology) informacijsko-komunikacijska tehnologija
IMAP	(Internet Message Access Protocol) protokol za preuzimanje elektronske pošte putem Interneta
IMS	(IP Multimedia Subsystem) sustav koji pruža multimedijske usluge preko IP protokola
IP	(Internet Protocol) protokol za prijenos podataka između izvorišnog i odredišnog terminala preko računalne mreže
IRC	(Internet Relay Chat) aplikacijski protokol zadužen za razgovor putem Interneta
KPI	(Key Performance Indicator) ključni pokazatelj uspješnosti
L2TP	(Layer 2 Tunneling Protocol) protokol koji se rabi kao podrška za virtualnu privatnu mrežu
LTE	(Long Term Evolution) četvrta generacija mobilne mreže
MAC	(Media Access Control) brojčana oznaka mrežne kartice
MBH	(Mobile Backhaul) veza od bazne stanice do jezgrene mreže
MGCP	(Media Gateway Control Protocol) signalizacijski i kontrolni protokol u VoIP-u
MGW	(Media Gateway) mrežni čvor koji pretvara medijske formate između različitih tehnologija i sustava
MIMO	(Multiple-Input Multiple-Output) komunikacijski sustav s više prijamnih i odašiljačkih antena
MME	(Mobility Management Entity) kontrolni čvor putem kojeg se vrši signalizacija između korisničke opreme i jezgrene mreže
NAS	(Non-Access Stratum) protokoli koji djeluju između korisničke opreme i jezgrene mreže
NNTP	(Network News Transfer Protocol) aplikacijski protokol za prenošenje mrežnih vijesti
NSS	(Network Switching Subsystem) jezgrena mreža GSM sustava
NTP	(Network Time Protocol) mrežni protokol za sinkronizaciju vremena
OFDM	(Orthogonal Frequency Division Multiplexing) frekvencijski multipleks

	ortogonalnih podnosilaca
OTT	(Over-The-Top) termin za prijenos informacija putem Interneta zaobilaženjem mreže operatora
PCRF	(Policy and Charging Rules Function) mrežni element odgovaran za terećenje i politiku mreže
PDN	(Packet Data Network) podatkovna mreža
P-GW	(Packet Data Network Gateway) mrežni čvor koji omogućuje konekciju između korisničke opreme i podatkovne mreže
PLMN	(Public Land Mobile Network) javna mobilna mreža na određenom teritoriju
POP3	(Post Office Protocol version 3) mail protokol za preuzimanje elektroničke pošte s poslužitelja
P-TMSI	(Packet-Temporary Mobile Subscriber Identity) privremena identifikacija pretplatnika u mobilnoj mreži
QAM	(Quadrature Amplitude Modulation) kvadraturna amplitudna modulacija
QCI	(QoS Class Identifier) QoS identifikator klase
QoE	(Quality of Experience) iskustvena kvaliteta usluge
QoS	(Quality of Service) kvaliteta usluge
RRM	(Radio Resource Management) upravljanje radio sučeljem u bežičnoj mreži
RSS	(Really Simple Syndication) *web* formati korišteni za stranice koje je često potrebno osvježiti
RTMP	(Real-Time Messaging Protocol) vlasnički protokol za prijenos multimedijskih datoteka između *Flash player*-a i servera
RTP	(Real-Time Transport Protocol) mrežni protokol za isporuku multimedijskih datoteka preko IP mreže
RTSP	(Real Time Streaming Protocol) protokol odgovoran za kontrolu isporuke podataka u stvarnom vremenu
RTT	(Round-Trip Time) kružno kašnjenje
SC-FDMA	(Single Carrier Frequency Division Multiple Acces) frekvencijska modulacija s jednim signalom nosiocem
SDM	(Subscriber Data Management) upravljanje pretplatničkim podacima
SGSN	(Serving GPRS Support Node) dio GPRS mreže odgovoran za prebacivanje

	paketa u mreži, mobilnost i autentičnost korisnika
S-GW	(Serving Gateway) element u mreži kroz koji se šalju paketi između korisničke opreme i *eNodeB* čvorova.
SIP	(Session Initiation Protocol) protokol za isporuku glasovnih usluga
SMTP	(Simple Mail Transfer Protocol) protokol za siguran i pouzdan prijenos poruka elektroničke pošte
SNMP	(Simple Network Management Protocol) jednostavni protokol za upravljanje mrežom
SSH	(Secure Shell) mrežni protokol za uspostavu sigurnog komunikacijskog kanala
SSL	(Secure Sockets Layer) transportni protokol zadužen za sigurnu komunikaciju preko Interneta
TCP	(Transmission Control Protocol) pouzdan protokol transportnog sloja
TTL	(Time-To-Live) vrijeme života IP paketa
UDP	(User Datagram Protocol) nepouzdan protokol transportnog sloja
UE	(User Equipment) korisnička oprema
UICC	(Universal Integrated Circuit Card) identifikacijska pretplatnička kartica implementirana u terminalni uređaj
UML	(Unified Modeling Language) standardizirani jezik za modeliranje
UMTS	(Universal Mobile Telecommunications System) mreža s bržim protokom podataka u odnosu na GSM
USIM	(Universal Subscriber Identity Module) kartica kojom je omogućena komunikacija s mobilnom mrežom
VAS	(Value Added System) sustav usluga s dodanom vrijednošću
VNC	(Virtual Network Computing) daljinsko upravljanje drugim računalom
VoIP	(Voice over IP) tehnologija vezana uz prijenos govora preko IP-a
VPLMN	(Visited Public Land Mobile Network) mreža na koju je pretplatnik spojen kada je u *roaming*-u
WAP	(Wireless Application Protocol) protokol koji omogućuje bežičnim terminalnim uređajima pristup aplikacijama vezanim uz Internet
Wi-MAX	(Worldwide Interoperability for Microwave Access) protokol zadužen za fiksni i mobilni pristup Internetu

XML (eXtensible Markup Language) jezik kojim se označavaju podaci