

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA
U OSIJEKU
ELEKTROTEHNIČKI FAKULTET OSIJEK

Višnja Križanović

**Tehno-ekonomski model za uvođenje širokopojasnog pristupa
Internetu u ruralnim područjima**

**Techno-economic Model for
Rural Broadband Access Implementation**

Doktorska disertacija

Osijek, 2014.

Doktorska disertacija izrađena je na Zavodu za komunikacije Elektrotehničkog fakulteta Sveučilišta J. J. Strossmayera u Osijeku.

Mentor: Prof.dr.sc. Drago Žagar

Povjerenstvo za ocjenu doktorske disertacije:

1. Prof.dr.sc. Snježana Rimac-Drlje, Elektrotehnički fakultet Osijek, predsjednica
2. Prof.dr.sc. Drago Žagar, Elektrotehnički fakultet Osijek, mentor
3. Prof.dr.sc. Ignac Lovrek, Fakultet elektrotehnike i računarstva Sveučilišta u Zagrebu, član
4. Izv.prof.dr.sc. Dominika Crnjac-Milić, Elektrotehnički fakultet Osijek, član
5. Doc.dr.sc. Krešimir Grgić, Elektrotehnički fakultet Osijek, član

Povjerenstvo za obranu doktorske disertacije:

1. Prof.dr.sc. Snježana Rimac-Drlje, Elektrotehnički fakultet Osijek, predsjednica
2. Prof.dr.sc. Drago Žagar, Elektrotehnički fakultet Osijek, mentor
3. Prof.dr.sc. Ignac Lovrek, Fakultet elektrotehnike i računarstva Sveučilišta u Zagrebu, član
4. Izv.prof.dr.sc. Dominika Crnjac-Milić, Elektrotehnički fakultet Osijek, član
5. Doc.dr.sc. Krešimir Grgić, Elektrotehnički fakultet Osijek, član

Datum obrane disertacije: **15. travnja 2014.**

SADRŽAJ:

1. UVOD	1
2. ŠIROKOPOJASNI PRISTUP INTERNETU	5
2.1. Značajke širokopojasnog pristupa Internetu	5
2.2. Usvajanje, razvoj i implementacija širokopojasnih tehnologija i usluga.....	8
2.3. Pregled širokopojasnih tehnologija	11
2.4. Usporedba širokopojasnih pristupnih rješenja	16
2.5. Širokopojasni pristup Internetu u ruralnim područjima	19
2.5.1. Ruralna područja i mjere ruralnosti	19
2.5.1.1. Kategorizacija ruralnih područja	21
2.5.1.2. <i>Studijski primjer:</i> Kategorizacija hrvatskih područja i županija prema kvantitativnim mjerama ruralnosti.....	21
2.5.1.3. Kategorizacija ruralnih naselja	23
2.5.1.4. <i>Studijski primjer:</i> Kategorizacija hrvatskih ruralnih naselja ..	24
2.5.1.5. Problemi ruralnih područja	25
2.5.2. Problem digitalnog jaza	26
2.5.2.1. <i>Studijski primjer:</i> Digitalni jaz između hrvatskih ruralnih i urbanih područja i županija.....	27
2.5.2.2. Smjernice za smanjenje digitalnog jaza.....	30
2.5.3. Širokopojasna pristupna rješenja prikladna za ruralna područja.....	31
3. VREDNOVANJE TEHNIČKIH MOGUĆNOSTI I EKONOMSKIH ASPEKATA UVOĐENJA ŠIROKOPOJASNOG PRISTUPA INTERNETU	33
3.1. Poslovno planiranje u telekomunikacijama	34
3.2. Pregled istraživanja vezanih uz tehničke i ekonomske aspekte razvoja i implementacije širokopojasnih tehnologija i usluga.....	35
3.3. Postupci i metode za vrednovanje tehničkih mogućnosti i ekonomskih aspekata uvođenja širokopojasnih pristupnih rješenja.....	38
3.3.1. Planiranje modela	42
3.3.2. Kreiranje modela	43

3.3.2.1.	Modeliranje tržišta	44
3.3.2.2.	Modeliranje pristupnih mreža	47
3.3.2.3.	Modeliranje cijena usluga	49
3.3.2.4.	Modeliranje prihoda	50
3.3.2.5.	Modeliranje troškova	52
3.3.3.	Analiziranje održivosti i ocjenjivanje isplativosti modela	55
3.3.3.1.	Analiza financijske održivosti i isplativosti modela	55
3.3.3.2.	Ocjena ekonomske isplativosti modela	57
3.3.4.	Vrednovanje modela	59
3.3.4.1.	Usporedba scenarija	60
3.3.4.2.	Analize osjetljivosti	61
3.3.4.3.	<i>Monte Carlo</i> simulacije	62
3.3.4.4.	Teorija igara	62
3.3.4.5.	Realne opcije	64
3.4.	Pregled primjene tehno-ekonomskih metoda i modela	65
3.4.1.	Pregled i usporedba primijenjenih metoda za vrednovanje tehničkih mogućnosti i ekonomskih aspekata uvođenja širokopojsnih pristupnih rješenja	66
3.4.2.	Izdvojena problematika vezana uz postupke vrednovanja tehničkih mogućnosti i ekonomskih aspekata uvođenja širokopojsnih pristupnih rješenja i pregled postojećih rješenja	69
3.5.	Analize isplativosti širokopojsnih pristupnih rješenja za ruralna područja	72
3.5.1.	Opis problematike vezane uz provedbu tehno-ekonomskih analiza uvođenja širokopojsnog pristupa Internetu u ruralna područja i prikaz predloženih rješenja	73
3.5.2.	Usporedba isplativosti različitih širokopojsnih pristupnih rješenja za ruralna područja	78
3.5.2.1.	Usporedba isplativosti uvođenja širokopojsnih pristupnih rješenja u ruralna područja na lokalnoj razini	79
3.5.2.2.	Usporedba isplativosti uvođenja širokopojsnih pristupnih rješenja u ruralna područja na regionalnoj razini	82
3.5.3.	Pregled metoda i analiziranih vrsta širokopojsnih pristupnih rješenja za ruralna područja	84

4. ANALIZE ČIMBENIKA BITNIH ZA UVOĐENJE ŠIROKOPOJASNOG PRISTUPA INTERNETU U RURALNIM PODRUČJIMA	86
4.1. Regresijska analiza čimbenika bitnih za uvođenje širokopojasnog pristupa Internetu	87
4.1.1. Korelacije između čimbenika	88
4.1.2. Jednostavna linearna i nelinearna regresijska analiza čimbenika	91
4.1.3. Višestruka linearna i nelinearna regresijska analiza čimbenika	95
4.1.4. Testiranje hipoteza u modelima višestruke linearne regresije	98
4.2. Čimbenici bitni za uvođenje širokopojasnog pristupa Internetu u ruralnim područjima	101
4.2.1. Preduvjeti za usvajanje širokopojasnih tehnologija i usluga u ruralnim područjima i izbor čimbenika za regresijsku analizu	105
4.2.2. Socio-demografski i tehno-ekonomski čimbenici i usvajanje širokopojasnih tehnologija i usluga	107
4.2.3. Regresijska analiza socio-demografskih i tehno-ekonomskih čimbenika i usvajanja širokopojasnih tehnologija i usluga u ruralnim područjima	111
4.2.3.1. Studijski primjer: Linearna regresijska analiza utjecaja socio-demografskih i ekonomskih čimbenika na usvajanje širokopojasnih tehnologija i usluga u hrvatskim ruralnim županijama	113
4.2.3.2. Analiza rezultata provedene linearne regresijske analize socio-demografskih i ekonomskih čimbenika	115
4.2.3.3. Studijski primjer: Nelinearna regresijska analiza utjecaja socio-demografskih i tehno-ekonomskih čimbenika na usvajanje širokopojasnih tehnologija i usluga u hrvatskim ruralnim županijama	116
4.2.3.4. Analiza rezultata provedene nelinearne regresijske analize socio-demografskih i tehno-ekonomskih čimbenika	121
4.2.4. Problemi pri provedbi regresijskih analiza čimbenika	123
4.3. Analiza čimbenika bitnih operatorima pri odlučivanju o uvođenju širokopojasnog pristupa u ruralnim područjima	124

4.4.	Analiza troškova i koristi pri uvođenju širokopojasnog pristupa Internetu u ruralnim područjima	126
5.	TEHNO-EKONOMSKI MODEL ZA UVOĐENJE ŠIROKOPOJASNOG PRISTUPA INTERNETU U RURALNIM PODRUČJIMA.....	128
5.1.	Razmatrana problematika i prijedlog tehno-ekonomskog modela za uvođenje širokopojasnog pristupa Internetu u ruralnim područjima.....	128
5.2.	Tehno-ekonomski model koji se temelji na okviru za vrednovanje uvođenja širokopojasnog pristupa Internetu u ruralnim područjima.....	131
5.2.1.	Struktura predloženog tehno-ekonomskog modela s okvirom.....	137
5.2.2.	Opis okvira	140
5.2.2.1.	Regresijska analiza čimbenika koji opisuju korisnike i utječu na broj korisnika.....	141
5.2.2.2.	Regresijska analiza čimbenika koji opisuju zahtjeve krajnjih korisnika.....	142
5.2.2.3.	Kvantitativna analiza utjecaja promjena iznosa tehno-ekonomskih čimbenika na ukupan broj korisnika.....	144
5.2.2.4.	Modeliranje prihoda	146
5.2.2.5.	Modeliranje troškova.....	147
5.2.2.6.	Primjena dobivenih rezultata analiza provedenih unutar okvira	148
5.2.3.	Značajke predloženog modela s okvirom	153
5.3.	Vrednovanje primjenjivosti predloženog tehno-ekonomskog modela kroz procjenu održivosti poslovnih modela uvođenja širokopojasnih pristupnih mreža u ruralnim područjima.....	154
5.3.1.	Opis odabranih poslovnih modela za vrednovanje primjenjivosti predloženog tehno-ekonomskog modela s okvirom.....	155
5.3.2.	Analiza dobivenih rezultata	159
6.	ZAKLJUČAK.....	165
	Popis slika.....	170
	Popis tablica.....	173

Literatura	175
Prilog	190
Sažetak	193
Sažetak na engleskom jeziku	194
Životopis	195
Životopis na engleskom jeziku	196

1. UVOD

Razvoj svakog suvremenog informacijskog društva temelji se na razvoju novih informacijskih i komunikacijskih tehnologija. Budući da razvoj novih informacijskih i komunikacijskih tehnologija, poput širokopojasnih pristupnih tehnologija, potiče gospodarski rast, sve države koje žele biti konkurentne na svjetskom tržištu potiču razvoj takvih tehnologija. Suvremene informacijske i komunikacijske mreže imaju široki raspon mogućih tehnoloških i poslovnih primjena. Takve mreže, zasnovane na širokopojasnim prijenosnim tehnologijama opisanima u drugom poglavlju rada, namijenjene su pružanju telekomunikacijskih usluga s garantiranom kvalitetom, pa je danas sve izraženija potreba za osiguravanjem odgovarajućih razina kvalitete pruženih usluga. Poveznica između mogućnosti osiguravanja odgovarajućih razina kvalitete pri pružanju telekomunikacijskih usluga i dostupne infrastrukture uzrokovala je potrebu za sustavnim analizama tehničkih, ekonomskih i tržišnih aspekata poslovnih prilika, detaljnije opisanima u radu.

Proces analize tehničkih te ekonomskih aspekata poslovnih prilika - poslovno planiranje, danas je sve više u fokusu različitih sudionika na telekomunikacijskim tržištima, ali i znanstvene zajednice, budući da takav proces osigurava uvid u mogućnosti uvođenja pojedinih telekomunikacijskih rješenja te njihovu optimizaciju. Suvremene metode upravljanja poslovnim procesima prema kreiranim poslovnim planovima, uz održavanje ili stvaranje očekivanih prihoda - poslovni modeli, u području telekomunikacija razmatraju različite skupine tehnoloških rješenja i usluga kojima se opisuju mogući izvori prihoda. Svaki poslovni model nastoji povezati odgovarajući tehnološki potencijal sa ostvarenom ekonomskom vrijednošću, a upravo se zbog ovisnosti tehnološke i ekonomske komponente poslovnih modela postupci analize poslovnih modela nazivaju tehno-ekonomskim analizama. Tehno-ekonomske metode modeliranja opisane u trećem poglavlju rada imaju za cilj utvrđivanje tehničke i ekonomske izvedivosti analiziranih modela. Osnovna struktura analize poslovnih modela, tehno-ekonomska analiza sadrži prihodovni i troškovni dio te evaluacijski dio u kojem se određenim kvantitativnim metodama vrednuju kreirani poslovni modeli.

Modeli uvođenja širokopojasnih pristupnih mreža na određene prostore mogu se također analizirati uz uvažavanje svih bitnih tehničkih i ekonomskih aspekata poslovnih prilika. Pri tome, primijenjene kvalitativne i kvantitativne analize kreiranih poslovnih modela imaju za

cilj ukazivanje na isplativost uvođenja širokopojasnog pristupa Internetu u određena područja. Analiza takvih modela omogućuje predviđanje ishoda kreiranih projekata te njihovu optimizaciju. Nadogradnja tehno-ekonomskih analiza, kao osnovnih metoda za analiziranje poslovnih modela, omogućuje analitičko propitivanje međusobnog utjecaja strategija više operatora te regulatornih mjera prisutnih na promatranom tržištu. U tu svrhu se pri proširenju analitičkog postupka mogu primijeniti metode kao što su analize osjetljivosti, realne opcije i teorija igara, opisane u trećem poglavlju rada, koje omogućuju dobivanje boljeg uvida u moguće ishode uvođenja pojedinih poslovnih modela i izbor najoptimalnijeg modela za promatrana područja.

Danas su prisutne brojne razlike između snažno urbaniziranih europskih prostora u blizini većih gradskih središta te ostalih, većinski izrazito ruralnih područja. Ruralna područja se suočavaju s brojnim problemima, kao što su degradacijski procesi, depopulacija te slabiji gospodarski razvoj. Nadalje, infrastrukturni preduvjeti za pokretanje gospodarskog razvoja u ruralnim područjima puno su slabiji nego oni u urbanim područjima, a u takve infrastrukturne komponente ubraja se i sva informacijska i komunikacijska infrastruktura, kakva je i širokopojasna pristupna infrastruktura. Poticanjem razvoja širokopojasnog pristupa Internetu nastoji se smanjiti postojeći digitalni jaz, odnosno postojanje velikih razlika u dostupnosti širokopojasnog pristupa Internetu, kako između pojedinih država, tako i između različitih urbanih i ruralnih područja unutar pojedinih država.

O stupnju razvijenosti te stupnju primjene informacijske i komunikacijske infrastrukture ovisi i stupanj razvoja ruralnih područja. Razvoj širokopojasnih komunikacija omogućuje stvaranje i primjenu novih usluga, tehnologija i aplikacija te poboljšanje postojećih, čime se može potaknuti gospodarski rast u ruralnim područjima kroz stvaranje novih proizvoda, privlačenje ulaganja i otvaranje radnih mjesta. Nadalje, razvoj širokopojasnih komunikacija utječe i na proizvodnost mnogih gospodarskih grana i procesa, što dovodi do većeg bruto društvenog proizvoda i kraćeg perioda povrata ulaganja u pristupnu infrastrukturu. Dostupnost širokopojasnih usluga jedan je od ključnih elemenata koji olakšava privlačenje novih ulaganja, uvođenje rada na daljinu, djelotvornije i brže usluge zdravstvene zaštite, kvalitetnije obrazovanje te kvalitetnije i pristupačnije usluge javne uprave. Budući da je razvoj svake države i regije povezan i s razvojem pripadnih ruralnih područja, u svim je područjima podjednako bitno osigurati širokopojasni pristup Internetu kako bi svi stanovnici imali jednake mogućnosti pristupa korisnim informacijama i uslugama.

Kako je opisano u četvrtom poglavlju rada, modelima uvođenja i razvoja širokopojasnog pristupa Internetu potrebno je posvetiti dovoljno pozornosti budući da prisustvo odgovarajućih regulatornih te poslovnih uvjeta na pojedinim područjima omogućuje pružanje bržeg, kvalitetnijeg i jeftinijeg širokopojasnog pristupa. Pravilan izbor modela razvoja širokopojasnog pristupa Internetu može povećati ukupnu dobit ostvarenu nakon njegovog uvođenja. Optimalni modeli širokopojasnih pristupnih mreža definiraju optimalne uvjete rada, načine održavanja, upravljanja te proširivanja pristupnih mreža. To je posebno bitno za područja u kojima uvođenje širokopojasnog pristupa nije ekonomski privlačno, kao što su ruralna područja. Kako je navedeno u petom poglavlju rada, pravilan izbor odgovarajućeg poslovnog modela može povećati ekonomski omjer isplativosti uvođenja širokopojasnog pristupa u ruralna područja, a tada primijenjena pristupna tehnologija postaje dostupna većem broju korisnika.

S obzirom na kratko navedenu problematiku vezanu uz uvođenje širokopojasnog pristupa Internetu u ruralnim područjima, definirana je struktura ove disertacije. Nakon ovog prvog poglavlja u kojem je kratko prikazan sadržaj disertacije, u drugom je poglavlju dan općeniti uvod u problematiku vezanu uz uvođenje širokopojasnog pristupa Internetu u ruralnim područjima koja se nalazi u fokusu istraživanja u disertaciji. Na početku poglavlja navedene su osnovne značajke širokopojasnog pristupa Internetu, kratko su opisane postojeće širokopojasne pristupne tehnologije i načini njihove implementacije te su izdvojena širokopojasna pristupna rješenja prikladna za ruralna područja. Nadalje, kratko su navedeni postojeći problemi vezani uz uvođenje širokopojasnog pristupa u ruralnim područjima te je istaknut problem nejednake dostupnosti i primjene širokopojasnog pristupa Internetu u ruralnim i urbanim područjima, tzv. digitalni jaz. Kako bi se utvrdilo postojanje digitalnog jaza između pojedinih ruralnih i urbanih područja, u odabranom studijskom primjeru je načinjena procjena broja širokopojasnih priključaka u ruralnim i urbanim područjima uz primjenu logističke funkcije te je provedena analiza dobivenih rezultata. Na posljetku su kratko navedene općenite smjernice i metode za smanjivanje digitalnog jaza na kojima se temelje istraživanja u disertaciji.

Treće poglavlje rada obuhvaća daljnje razlaganje problematike uvođenja širokopojasnog pristupa Internetu. Zbog lakše usporedbe različitih rješenja primijenjenih u brojnim provedenim studijama i analizama koje razmatraju tehničke i ekonomske aspekte uvođenja širokopojasnih pristupnih mreža, u ovom poglavlju je načinjena kategorizacija i prikaz

najrelevantnijih metoda i modela iz literature. Pri tome su razmotrene i opisane postojeće tehno-ekonomske metode za vrednovanje uvođenja širokopojasnog pristupa Internetu, a to su planiranje tehno-ekonomskog modela, kreiranje modela, analiziranje održivosti i ocjenjivanje isplativosti modela te vrednovanje modela.

U četvrtom poglavlju rada prikazana je metodologija primijenjena za rješavanje odabrane problematike uvođenja širokopojasnog pristupa Internetu u ruralnim područjima uz određivanje čimbenika koji su bitni za uvođenje širokopojasnog pristupa Internetu u takvim područjima. U ovoj cjelini rada razmotrena su dva aspekta – aspekt mrežnih operatora te onaj potencijalnih krajnjih korisnika. Ovi pristupi uključuju provedbu kvantitativnih analiza (regresijske analize ključnih socio-demografskih čimbenika bitnih za uvođenje širokopojasnog pristupa u ruralnim područjima i analize ključnih tehno-ekonomskih čimbenika koji utječu na operatorovu odluku o uvođenju širokopojasnog pristupa Internetu u ruralnim područjima) te provedbu kvalitativnih analiza (analize podataka o potencijalnim krajnjim korisnicima novih širokopojasnih usluga u ruralnim područjima i analize ključnih čimbenika pri investiranju u širokopojasni pristup u ruralnim područjima iz perspektive mrežnih operatora). Rezultati provedenih analiza primjenjeni su pri kreiranju dodatnog okvira pomoću kojeg je moguće nadograditi postojeće tehno-ekonomske modele za uvođenje širokopojasnog pristupa Internetu. Navedeni okvir služi za vrednovanje uvođenja širokopojasnog pristupa Internetu u ruralnim područjima iz perspektive potencijalnih krajnjih korisnika te mrežnih operatora.

Peto poglavlje rada sadrži opis predloženog nadograđenog tehno-ekonomskog modela za vrednovanje uvođenja širokopojasnog pristupa u ruralnim područjima. Predloženim modelom se povezuju i razmatraju potrebe korisnika u ruralnim područjima za širokopojasnim tehnologijama i uslugama (zahtjevi na cijenu i kvalitetu širokopojasnih usluga, količinu prometa i brzinu pristupa), kao i interesi mrežnih operatora (isplativi poslovni modeli). Primjena predloženog modela trebala bi rezultirati većom dostupnošću širokopojasnog pristupa Internetu u ruralnim područjima prilagođenom zahtjevima korisnika te smanjenjem postojećeg digitalnog jaza između ruralnih i urbanih područja. U svrhu vrednovanja korisnosti predloženog modela odabrani su poslovni modeli u ruralnim područjima koji razmatraju izbor najboljih strategija za operatore u konkurentskom okruženju te je načinjena analiza dobivenih rezultata. U posljednjem, zaključnom poglavlju rada ukratko su navedeni ostvareni rezultati i doprinosi disertacije te su predložene smjernice za daljnji razvoj kreiranog modela.

2. ŠIROKOPOJASNI PRISTUP INTERNETU

2.1. Značajke širokopojasnog pristupa Internetu

Širokopojasni pristup Internetu (engl. *broadband Internet access*) omogućuje prijenos podataka velikim brzinama:

- u dolaznom (engl. *downstream*) smjeru - od Interneta prema korisničkom računalu i
- u odlaznom (engl. *upstream*) smjeru - od korisničkog računala prema Internetu.

Kako je propisano mjerama za razvoj širokopojasnog pristupa Internetu na razini Europske unije, u sklopu Digitalne agende za Europu, pri širokopojasnom prijenosu podataka definirana teorijska donja granica brzine prijenosa podataka iznosi 144 kbit/s, dok je praktična donja granica brzine 2 Mbit/s [1]. Prema podržanim prijenosnim brzinama razlikuju se sljedeće kategorije širokopojasnog pristupa: osnovni širokopojasni pristup (od 2 Mbit/s do 30 Mbit/s), brzi širokopojasni pristup (od 30 Mbit/s do 100 Mbit/s) te ultrabrzi širokopojasni pristup (100 Mbit/s i više) [1].

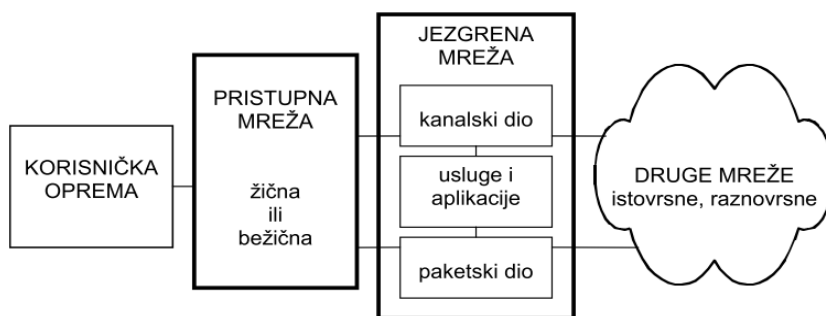
Osnovne tehničke značajke širokopojasnog pristupa moguće je analizirati kroz sljedeće parametre:

- širinu frekvencijskog pojasa (engl. *bandwidth*);
- asimetričnost (engl. *asymmetry*), odnosno razliku između raspoloživih širina frekvencijskih pojaseva u dolaznom i odlaznom smjeru;
- kapacitet (engl. *capacity*), odnosno dostupnu prijenosnu brzinu;
- natjecateljski omjer (engl. *contention ratio*) pri raspodjeli kapaciteta jednog prijenosnog kanala između više korisnika;
- domet (engl. *range*), odnosno maksimalnu udaljenost pri pokrivanju područja;
- vremensko kašnjenje (engl. *latency*) pri prijenosu podataka [2].

Razlozi primjene širokopojasnog pristupa Internetu vezani su uz njegove brojne prednosti u odnosu na uskopojasni (engl. *narrowband*) pristup. Neke od osnovnih prednosti širokopojasnog pristupa su veće dostupne brzine prijenosa podataka zbog veće širine raspoloživih frekvencijskih pojaseva, manja kašnjenja pri prijenosu podataka, pristup internetskim uslugama visoke kvalitete - internetskoj telefoniji (engl. *Voice over Internet*

Protocol, skr. VoIP), video sadržajima na zahtjev (engl. *streaming video*), *on-line* igrama te svim interaktivnim sadržajima i uslugama, kao i uslugama koje zahtijevaju prijenos velikih količina podataka u realnom vremenu.

Infrastruktura koja korisnicima osigurava širokopojasni pristup Internetu, pristupna mreža (engl. *access network*), odnosno tzv. posljednja milja (engl. *the last mile*) [3], sastoji se od lokalnih petlji (engl. *local loops*), koje se još nazivaju i pretplatničkim linijama (engl. *subscriber lines*), te odgovarajuće mrežne opreme. Međutim, dostupnost širokopojasnog pristupa Internetu ne ovisi samo o pristupnoj mreži, već i o načinu priključenja pristupne mreže na jezgrenu mrežu (engl. *backbone network*), odnosno o posrednoj vezi kojom se podaci prenose između pristupne i jezgrene mreže (engl. *backhaul*), o tzv. srednjoj milji (engl. *the middle mile*) [4], kako je prikazano na slici 2.1..



Slika 2.1. Mrežna arhitektura [4]

Za širokopojasni prijenos podataka bitno je odabrati odgovarajuću mrežnu infrastrukturu. U ovisnosti o primijenjenoj pristupnoj mrežnoj infrastrukturi, razlikuju se:

- žična (engl. *wired*) pristupna mreža, gdje se pristup do krajnjeg korisnika ostvaruje fiksnim žičnim vezama (npr. bakrenim paricama, koaksijalnim kabelima, optičkim kabelima ili elektroenergetskim vodovima), te
- bežična (engl. *wireless*) pristupna mreža, gdje se pristup do krajnjeg korisnika ostvaruje fiksnim ili mobilnim bežičnim vezama (npr. satelitskim vezama, zemaljskim radijskim vezama, mikrovalnim vezama, infracrvenim te optičkim vezama).

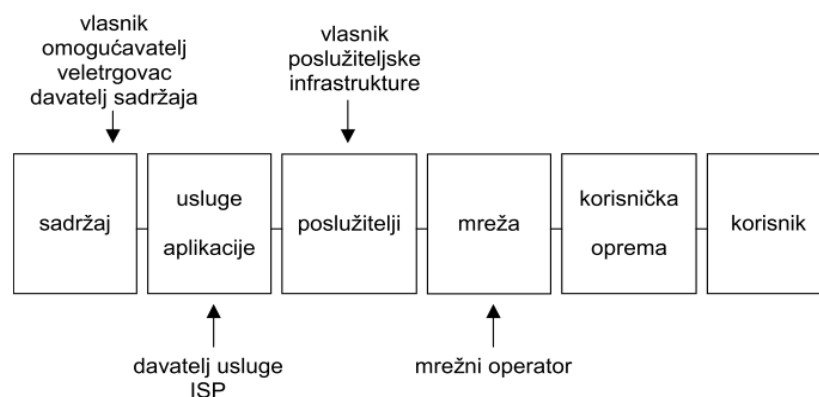
Izbor mrežnih infrastrukturnih rješenja moguće je izvršiti ovisno o tome zasniva li se širokopojasni pristup Internetu dijelom na postojećoj ili u potpunosti na novoj mrežnoj infrastrukturi [4] budući da je iskorištavanjem slobodnih kapaciteta postojeće infrastrukture moguće izbjeći nepotrebne troškove izgradnje istovrsnih mrežnih infrastruktura [5].

U postojeću infrastrukturu koju je moguće koristiti pri izgradnji nove pristupne mreže pripadaju kabelska kanalizacija, antenski stupovi te svi dostupni prostori u funkciji mrežnih čvorišta, dakle prostori koji služe za smještaj mrežne opreme. Iskorištavanje postojeće infrastrukture uz regulirane uvjete pristupa postojećim infrastrukturnim objektima te koordinacija pri izgradnji pristupne infrastrukture s planiranim projektima izvođenja javnih radova, omogućuje bržu i ekonomičniju izgradnju širokopojasnih pristupnih mreža [5].

Nadalje, izbor mrežnih infrastruktura i širokopojasnih tehnologija ovisi i o brojnim drugim čimbenicima, vezanima ponajprije uz značajke samih područja, ali i uz sudionike i stanje na telekomunikacijskim tržištima prisutno na određenim područjima. Sudionici na telekomunikacijskim tržištima mogu imati različite uloge, od kojih su osnovne uloge vezane uz formiranje ponude te formiranje potražnje za određenim tehnologijama i uslugama [6].

Dok potražnju na tržištu širokopojasnog Interneta formiraju korisnici (engl. *user*), kako je prikazano na slici 2.2., ponudu formiraju:

- davatelji sadržaja (engl. *content provider*), koji su često ujedno i vlasnici sadržaja (engl. *content owner*), omogućavatelji (engl. *content enabler*) te veletrgovci (engl. *content wholesaler*),
- davatelji internetskih usluga (engl. *Internet Service Provider, ISP*), koji su često i vlasnici poslužiteljske infrastrukture (engl. *server infrastructure owner*) i
- davatelji usluga mreže, tj. mrežni operatori (engl. *network operator*), pri čemu se razlikuju davatelji usluga fiksne mreže (engl. *fixed network operator*) i davatelji usluga pokretne mreže (engl. *mobile network operator*) [6].



Slika 2.2. Sudionici i uloge na telekomunikacijskim tržištima [6]

Pri izboru širokopojasnih pristupnih tehnologija i usluga ponašanje krajnjih korisnika - pojedinaca ili skupina, ovisi o nizu čimbenika koji oblikuju to ponašanje. Ponašanje krajnjih

korisnika određeno je njihovim interesima, potrebama, željama i mogućnostima, o kojima ovisi izbor širokopojasnih tehnologija i usluga. Stoga se krajnji korisnici širokopojasnog pristupa najčešće dijele na:

- privatne korisnike (engl. *residential users*) – pojedinci / kućanstva ili zajednice,
- poslovne korisnike (engl. *commercial users*) – organizacije i
- javne korisnike (engl. *public users*) – javni sektor.

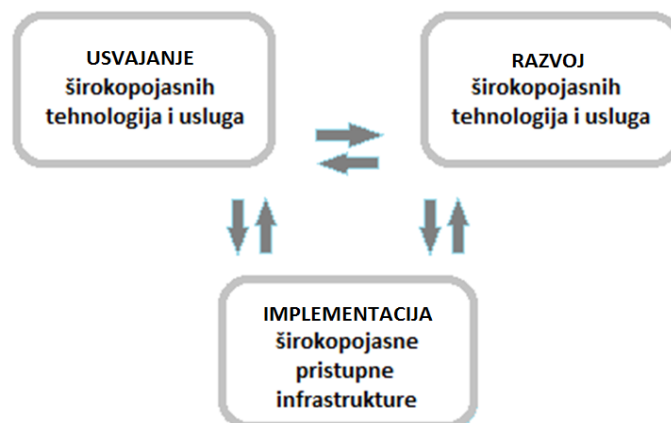
Ove skupine korisnika međusobno se razlikuju i prema namjeni širokopojasnih tehnologija i usluga. Tako se, na primjer, pri nabavi određene informacijske i komunikacijske opreme, ovisno o njenoj namjeni, razlikuje mrežna oprema koju izabire određena organizacija (poslovni korisnici) u odnosu na onu koju izabiru pojedinci (privatni korisnici).

2.2. Usvajanje, razvoj i implementacija širokopojasnih tehnologija i usluga

Širokopojasni pristup Internetu moguće je vrednovati s obzirom na procese:

- usvajanja (engl. *adoption*) širokopojasnih internetskih tehnologija i usluga,
- razvoja (engl. *development*) širokopojasnih pristupnih tehnologija i usluga te
- implementacije (engl. *deployment*) tj. uvođenja širokopojasne pristupne infrastrukture,

u koje su uključeni različiti sudionici na telekomunikacijskim tržištima. Svi su ovi procesi međusobno povezani, kako je prikazano na slici 2.3.. Tako proces usvajanja širokopojasnih tehnologija i usluga potiče daljnji razvoj širokopojasnih tehnologija i usluga, dok istovremeno i ovisi o njihovom razvoju. Implementacija širokopojasnog pristupa ovisi o razvoju širokopojasnih tehnologija i usluga, te istovremeno omogućuje njihovo usvajanje, odnosno primjenu.



Slika 2.3. Proces usvajanja, razvoja i implementacije širokopojasnog pristupa

U procese usvajanja, razvoja i implementacije širokopojasnog pristupa Internetu uključeni su brojni sudionici i njihovi interesi. Proces usvajanja, odnosno potražnje za širokopojasnim tehnologijama i uslugama, odnosi se na usvajanje širokopojasnih tehnologija i usluga sljedećih kategorija korisnika: privatnih korisnika – pojedinaca / kućanstava; društvenih skupina – lokalnih zajednica; poslovnih korisnika – organizacija te javnog sektora – lokalnih, regionalnih i državnih uprava. Proces razvoja, odnosno planiranja i poticanja širokopojasnih tehnologija i usluga, uključuje interese industrijskog sektora – proizvođača i operatora, lokalnih zajednica, općina, regionalnih i državnih uprava, te postavljene nacionalne i međunarodne ciljeve i strategije. Na proces implementacije pristupne infrastrukture, odnosno ponude širokopojasnog pristupa, utječu industrija, te lokalni i državni sektor.

Osnovne razloge za usvajanje, razvoj i uvođenje širokopojasnog pristupa Internetu moguće je podijeliti prema razinama prikazanim u tablici 2.1..

Tablica 2.1. Razlozi poticanja širokopojasnog pristupa Internetu

Poticaj:	Očekivanja:	Razina:
<ul style="list-style-type: none"> ▪ razvoj informacijskog društva i ekonomije zasnovane na znanju ▪ povećanje konkurentnosti ▪ smanjivanje digitalnog jaza i nedovoljne povezanosti ▪ povećanje digitalne uključivosti 	<ul style="list-style-type: none"> ▪ povećanje inovativnosti i proizvodnosti ▪ ekonomski rast ▪ širokopojasni pristup za sve, svugdje ▪ pristup važnim elektroničkim informacijskim uslugama 	<ul style="list-style-type: none"> ▪ međunarodna ▪ nacionalna ▪ državna ▪ regionalna ▪ općinska
<ul style="list-style-type: none"> ▪ ekonomski rast 	<ul style="list-style-type: none"> ▪ povećanje prihoda 	<ul style="list-style-type: none"> ▪ industrija
<ul style="list-style-type: none"> ▪ povećanje fleksibilnosti ▪ povećanje stručnosti 	<ul style="list-style-type: none"> ▪ omogućavanje rada na daljinu ▪ stjecanje novih znanja kroz primjenu <i>on-line</i> edukacijskih sadržaja 	<ul style="list-style-type: none"> ▪ organizacije
<ul style="list-style-type: none"> ▪ komunikacija ▪ usluge ▪ pogodnosti 	<ul style="list-style-type: none"> ▪ primjena komunikacijskih softverskih alata ▪ pristup elektroničkim informacijskim uslugama ▪ povećanje kvalitete života 	<ul style="list-style-type: none"> ▪ privatni korisnici

Navedene razloge moguće je dodatno podijeliti s obzirom na njihov utjecaj na društvenoj, zajedničkoj, individualnoj te komercijalnoj razini [7], kako je prikazano u tablici 2.2.. Dok je na društvenoj razini primjena širokopojasnih tehnologija vezana uz povećanje inovativnosti i proizvodnosti, na zajedničkoj te individualnoj razini, širokopojasne tehnologije omogućuju pristup velikom broju elektroničkih usluga koje na mnoge načine mogu pridonijeti ostvarivanju ciljeva zajednice te poboljšanju kvalitete života korisnika.

Takve širokopojasne usluge i servisi vezani su uz područja kao što su kultura, obrazovanje (npr. *e-Obrazovanje*) i zabava, telemedicina (npr. *e-Zdravstvo*), ekonomski razvoj (npr. *e-Poslovanje*), on-line javne usluge (npr. *e-Uprava*), širokopojasne komunikacijske usluge (npr. VoIP, video sadržaji na zahtjev), komunikacijske usluge za osobe s invaliditetom (npr. *Video Relay Services*, skr. VRS) i dr.

Tablica 2.2. Očekivane koristi od širokopojasnog pristupa Internetu

Očekivanja:	Razina:
<ul style="list-style-type: none"> ▪ povećanje proizvodnosti ▪ poticanje inovacija 	<ul style="list-style-type: none"> ▪ društvena
<ul style="list-style-type: none"> ▪ pristup informacijskim i komunikacijskim uslugama ▪ pristup dostupnim javnim elektroničkim uslugama ▪ zatvaranje digitalnog jaza 	<ul style="list-style-type: none"> ▪ zajednička
<ul style="list-style-type: none"> ▪ primjena naprednijih usluga u odnosu na uskopojasne usluge ▪ pristup dostupnim javnim elektroničkim uslugama, informacijskim, zabavnim i komunikacijskim sadržajima 	<ul style="list-style-type: none"> ▪ individualna
<ul style="list-style-type: none"> ▪ povećanje prihoda 	<ul style="list-style-type: none"> ▪ komercijalna

Komercijalna razina je vezana uz ulaganja u informacijsku i komunikacijsku širokopojasnu pristupnu infrastrukturu s ciljem ostvarivanja određenih prihoda kroz iznose koje korisnici izdvajaju za pristup širokopojasnim uslugama.

2.3. Pregled širokopojasnih tehnologija

Tehnologije koje omogućuju širokopojasni pristup Internetu moguće je podijeliti na više načina. Jedna od osnovnih podjela, prikazana u tablici 2.3., temelji se na načinu prijenosa podataka u pristupnoj mreži.

Tablica 2.3. Vrste širokopojasnih tehnologija

	Prijenos podataka:	Opis širokopojasnih tehnologija:	Komercijalni nazivi tehnologija:
a)	<i>bakrene parice</i>	tehnologije za širokopojasni pristup Internetu putem digitalne pretplatničke linije	xDSL (engl. <i>x Digital Subscriber Line</i>)
b)	<i>koaksijalni kabeli ili kombinacija optičkih i koaksijalnih kabela</i>	tehnologije za širokopojasni pristup Internetu putem kabela mreže	HFC (engl. <i>Hybrid Fiber-Coaxial</i>)
c)	<i>optički kabeli</i>	tehnologije za širokopojasni pristup Internetu putem optičke mreže	FTTx (engl. <i>Fiber To The x</i>)
d)	<i>elektroenergetski vodovi</i>	tehnologije za širokopojasni pristup Internetu putem elektroenergetske mreže	PLC (engl. <i>Powerline communications</i>), odnosno BPL (engl. <i>Broadband over Power Lines</i>)
e)	<i>radijske veze</i>	širokopojasne pristupne tehnologije u WLAN (engl. <i>Wireless Local Area Network</i>) mrežama	Wi-Fi (engl. <i>Wireless Fidelity</i>)
		širokopojasne pristupne tehnologije u WMAN (engl. <i>Wireless Metropolitan Area Network</i>) mrežama	WiMAX (engl. <i>Worldwide Interoperability for Microwave Access</i>)
		širokopojasne pristupne tehnologije treće generacije mobilnih mreža, tzv. 3G / 3.5G	UMTS (engl. <i>Universal Mobile Telecommunications System</i>) / HSPA (engl. <i>High Speed Packet Access</i>)
		širokopojasne pristupne tehnologije četvrte generacije mobilnih mreža, tzv. 4G	LTE (engl. <i>Long Term Evolution</i>)
f)	<i>satelitske veze</i>	tehnologije za širokopojasni pristup Internetu putem jednosmjernih ili dvosmjernih satelitskih veza	Satelitski pristup

S obzirom na vrstu prijenosnog medija koji se koristi u pristupnoj mreži navedene širokopojasne pristupne tehnologije su podijeljene te ukratko opisane u nastavku.

a) Širokopolasne pristupne tehnologije koje se temelje na prijenosu podataka bakrenim paricama

xDSL (engl. *x Digital Subscriber Line*), odnosno digitalna pretplatnička linija, naziv je za tehnologije koje omogućuju digitalnu razmjenu podataka putem bakrenih žica fiksne telefonske linije dostupne u većini današnjih kućanstava. Naziv xDSL koristi se kako bi se označila skupina svih DSL tehnologija (HDSL, ADSL, VDSL, SDSL, RADSL, IDSL, CDSL, UDSL, DSL Lite i dr.), odnosno za označavanje bilo koje od njih. Ove tehnologije se međusobno razlikuju prema podržanim brzinama prijenosa podataka, maksimalnim udaljenostima i podržanim uslugama. Dijele se na asimetrične i simetrične tehnologije, pri čemu se simetričnost definira s obzirom na prijenosne brzine podataka u dolaznom i odlaznom smjeru. Danas su među najprimjenjenijim xDSL tehnologijama ADSL i VDSL.

ADSL (engl. *Asymmetric Digital Subscriber Line*), odnosno asimetrična digitalna pretplatnička linija je tehnologija koja ima najveći broj korisnika širokopolasnog Interneta na tržištu. Njegove prednosti su zadovoljavajuće prijenosne brzine, standardizacija unutar ITU-T G.992 (što je iznimno bitno operatorima, ali i korisnicima) te mogućnost proširenja maksimalnog dometa uz primjenu regeneratora. Budući da prijenosni kapaciteti opadaju s povećavanjem udaljenosti, ograničena je maksimalna udaljenost krajnjih korisnika od telefonske centrale. Stoga su kreirani ADSL2 i ADSL2+ standardi koji predstavljaju nadogradnju na postojeći ADSL, a uz brži prijenos podataka omogućuju i prijenos podataka na veće udaljenosti.

VDSL (engl. *Very high data rate Digital Subscriber Line*), odnosno digitalna pretplatnička linija vrlo velikih brzina prijenosa, definirana unutar ITU-T G.993, pruža veće prijenosne brzine nego ADSL. VDSL2 i VDSL 2+, standardi druge generacije VDSL-a, u odnosu na prvu generaciju imaju širi frekvencijski pojas, pa je omogućena podrška primjeni multimedijских usluga uz održavanje visokih razina kvalitete.

b) Širokopolasne pristupne tehnologije koje se temelje na prijenosu podataka koaksijalnim kabelima

HFC (engl. *Hybrid Fiber-Coaxial*) je tehnologija za pristup Internetu putem kableske mreže definirana DOCSIS standardima. Današnji kableski Internet koristi kablesku mrežu primarno namijenjenu prijenosu signala kableske televizije koja je nastala kako bi se korisnicima u

signalom slabije pokrivenim područjima osigurao kvalitetniji prijem. Zbog potrebe za pronalaskom što lakših i bržih načina za pristup Internetu, napravljene su određene tehnološke preinake postojeće infrastrukture mreže kabelaške televizije kako bi se ona mogla koristiti za širokopolasni prijenos podataka. Kabelaški Internet omogućuje relativno velike brzine prijenosa podataka koje se ne smanjuju s povećanjem udaljenosti od korisnika do lokacije pružatelja usluge kabelaškog pristupa Internetu. Kabelaške mreže uglavnom su implementirane u urbanim središtima.

c) Širokopolasne pristupne tehnologije koje se temelje na prijenosu podataka optičkim kablama

Povećanje prijenosnih kapaciteta u jezgrenim mrežama često ne prati i istovremeno povećanje prijenosnih kapaciteta u pretplatničkim pristupnim mrežama, pa zbog sve veće količine podatkovnog prometa koji se razmjenjuje u posljednjoj milji na linkovima između lokalnih i jezgrenih mreža često dolazi do smanjivanja propusnosti te do zagušenja. Kao djelomično rješenje tog problema nameće se primjena paričnih ili kabelaških pristupnih infrastruktura. Međutim, budući da njihovi prijenosni kapaciteti često nisu dovoljno veliki, rješenje problema nedovoljnih kapaciteta u pristupnim mrežama postalo je dovođenje optičkih vlakana do krajnjih korisnika, tzv. **FTTU** (engl. *Fiber To The User*). Pri tome se razlikuju topologija *točka-točka* (engl. *Point-to-Point*, skr. P2P), definirana unutar IEEE 802.3, i *točka-više točaka* (engl. *Point To MultiPoint*, skr. P2MP), definirana unutar ITU-T G.983 i ITU-T G.984.

Optički prijenosni sustavi u odnosu na električne imaju brojne prednosti. Tako optička vlakna osiguravaju prijenos prometa visokog kapaciteta na udaljenosti veće od dvadeset kilometara, pri čemu su neosjetljiva na vanjske elektromagnetske smetnje. Takve su pristupne mreže nazivaju se pristupnim mrežama nove generacije. Tipovi optičke pristupne mreže određeni su lokacijom optičke mrežne jedinice, pa se razlikuju sljedeći tipovi optičkih pristupnih mreža (**FTTx**): vlakno do kuće, skr. **FTTH** (engl. *Fibre To The Home*), vlakno do zgrade, skr. **FTTB** (engl. *Fibre To The Building*), vlakno do ulice, skr. **FTTC** (engl. *Fibre To The Curb*), vlakno do ormara, skr. **FTTCab** (engl. *Fibre To The Cabinet*) te vlakno do centrale, skr. **FTTExch** (engl. *Fibre To The Exchange*).

d) Širokopolasne pristupne tehnologije koje se temelje na prijenosu podataka elektroenergetskim vodovima

Tehnologija pristupa Internetu putem elektroenergetske mreže, poznata kao **BPL** (engl. *Broadband Over Powerlines*) omogućuje širokopolasni pristup Internetu svakom kućanstvu koje koristi komercijalnu naponsku distribucijsku mrežu (engl. *powerline*), odnosno gotovo svim današnjim kućanstvima. Današnja BPL tehnologija omogućuje širokopolasni prijenos podataka preko niskonaponske i sredjenaponske elektroenergetske mreže. Primjena elektroenergetskih mreža za komunikaciju, tzv. **PLC** (engl. *Powerline communications*) postojala je još pedesetih godina prošloga stoljeća. Zbog malih prijenosnih brzina, niske funkcionalnosti i visokih troškova razvoja, BPL tehnologija tada nije smatrana ozbiljnom komunikacijskom tehnologijom. Provedbom standardizacije obuhvaćene unutar IEEE Std 1901-2010, primjenom novih modulacijskih postupaka, naprednih tehnika smanjivanja pogrešaka, efikasnih algoritama digitalne obrade signala te razvoja specijaliziranog hardvera, BPL tehnologija postaje rješenje pogodno za široku primjenu.

e) Širokopolasne pristupne tehnologije koje se temelje na prijenosu podataka bežičnim radijskim vezama

Kako se potrebni prijenosni kapaciteti sve više povećavaju, postavljaju se sve viši zahtjevi pri izboru prikladnih pristupnih mrežnih infrastruktura. Polaganje žične infrastrukture ukazalo je na određene sigurnosne i funkcijske nedostatke. Tako se, npr. pri prijenosu podataka bakrenim paricama javlja problem smanjenja prijenosnih brzina s povećanjem udaljenosti, dok je polaganje optičkih kablova često skupo. Navedene nedostatke moguće je izbjeći uvođenjem određenih bežičnih pristupnih rješenja.

U bežičnim lokalnim mrežama, tzv. WLAN (engl. *Wireless Local Area Network*) mrežama primjenu je našla **Wi-Fi** (engl. *Wireless Fidelity*) tehnologija - prva bežična tehnologija koja je počela koristiti širokopolasni prijenos podataka. Wi-Fi tehnologija, definirana IEEE 802.11 skupinom standarda, koristi se za ostvarivanje bežične radiofrekvencijske veze uz primjenu odgovarajućih antena. Najveći problem u realizaciji takvih mreža predstavljaju smetnje.

U bežičnim gradskim mrežama, tzv. WMAN (engl. *Wireless Metropolitan Area Network*) mrežama primjenjuje se **WiMAX** (engl. *Worldwide Interoperability for Microwave Access*) bežična tehnologija. WiMAX tehnologija, definirana IEEE 802.16 skupinom standarda, za

kreiranje bežične veze u pristupnoj mreži koristi bežične pristupne točke (engl. *access points*). Razlikuju se **fiksni** i **mobilni WiMAX**. Mobilni WiMAX je tehnologija koja se zasniva na istom dizajnu kao fiksni WiMAX, a njena je prednost u odnosu na fiksni WiMAX to što omogućuje Internetsku vezu korisnicima u pokretu.

U mobilnim bežičnim mrežama rasprostranjenima na širem području, tzv. WWAN (engl. *Wireless Wide Area Network*) mrežama koje su neovisne o pristupnim točkama primjenjuje se nekoliko generacija sustava mobilnih komunikacija čijom se standardizacijom bavi 3GPP skupina. **UMTS** (engl. *Universal Mobile Telecommunications System*) tehnologija je naziv za treću generaciju mobilnih mreža, tzv. **3G**. Razvoj mobilnih mreža od 2G prema 3G karakterizira prijelaz sa isključivo glasovnih usluga na multimedijske mobilne usluge. UMTS tehnologija pruža veću mobilnost komunikacije, a namijenjena je korisnicima u pokretu. Daljnjim razvojem 3G standarda i spajanjem dvaju protokola mobilne telefonije, HSDPA (engl. *High Speed Downlink Packet Access*) i HSUPA (engl. *High Speed Uplink Packet Access*) nastaje **HSPA** (engl. *High Speed Packet Access*) tehnologija koja podržava veće prijenosne brzine podataka u odnosu na UMTS. Nadogradnja HSPA tehnologije je HSPA+. **LTE** (engl. *Long Term Evolution*) tehnologija je naziv za četvrtu generaciju mobilnih mreža, tzv. **4G**. Ovaj novi standard za bežičnu komunikaciju omogućuje veće brzine pri prijenosu podataka, a zasniva se na novim modulacijskim tehnikama koje optimiziraju dostupni dio spektra.

f) Širokopolasne pristupne tehnologije koje se temelje na prijenosu podataka putem satelitskih veza

Satelitski pristup Internetu (engl. *satellite broadband*) još je jedan od načina bežičnog širokopolasnog pristupa Internetu. Satelitski sustavi definirani DVB-S standardima u pristupnim se mrežama koriste za širokopolasni prijenos podataka. Satelitske prijenosne tehnologije karakterizira rad u optimalnom frekvencijskom području te veliki doseg pokrivanja područja signalom. Širokopolasni pristup Internetu putem satelita u posljednje se vrijeme odvija u višim frekvencijskim pojasima čiji je kapacitet prijenosa podataka veći u odnosu na sustave koji rade u nižim pojasovima.

2.4. Usporedba širokopojasnih pristupnih rješenja

Širokopojasne pristupne tehnologije moguće je usporediti prema njihovim osnovnim tehničkim značajkama. Usporedba opisanih širokopojasnih tehnologija podijeljenih na žične i bežične tehnologije prikazana je u tablici 2.4. [2]. Pri tome se asimetričnost odnosi na razlike između raspoloživih širina frekvencijskih pojaseva u dolaznom i odlaznom smjeru, a natjecanje na raspodjelu kapaciteta prijenosnog kanala između više korisnika. Nadalje, najčešća kašnjenja do kojih dolazi pri prijenosu podataka nastaju zbog podjele dostupnih resursa između više korisnika (dok se kod žičnog pristupa dijeli prijenosni medij, kod bežičnog se dijeli frekvencijski pojas) ili zbog propagacije.

Tablica 2.4. Usporedba širokopojasnih pristupnih tehnologija

Tehnologija	Pristupne brzine	Asimetričnost	Natjecanje	Kašnjenja	Vrsta
ADSL	osnovni pristup	asimetrična	ne	zanemariva	ŽIČNE
VDSL	brzi pristup	asimetrična	ne	zanemariva	
HFC	brzi pristup	asimetrična	da	zbog dijeljenog medija	
FTTH PON / P2P	ultrabrzi pristup	simetrična	da (PON) / ne (P2P)	zanemariva	
PLC	osnovni pristup	simetrična	da	zbog dijeljenog medija	
Wi-Fi	osnovni ili brzi pristup	simetrična	da	zbog dijeljenja frekvencijskog pojasa	BEŽIČNE
WiMAX	osnovni pristup	asimetrična	da	zbog dijeljenja frekvencijskog pojasa	
UMTS/HSPA	osnovni pristup	asimetrična	da	zbog dijeljenja frekvencijskog pojasa	
LTE	brzi pristup	asimetrična	da	zbog dijeljenja frekvencijskog pojasa	
Satelitski pristup	osnovni pristup	simetrična ili asimetrična	da	velika propagacijska kašnjenja	

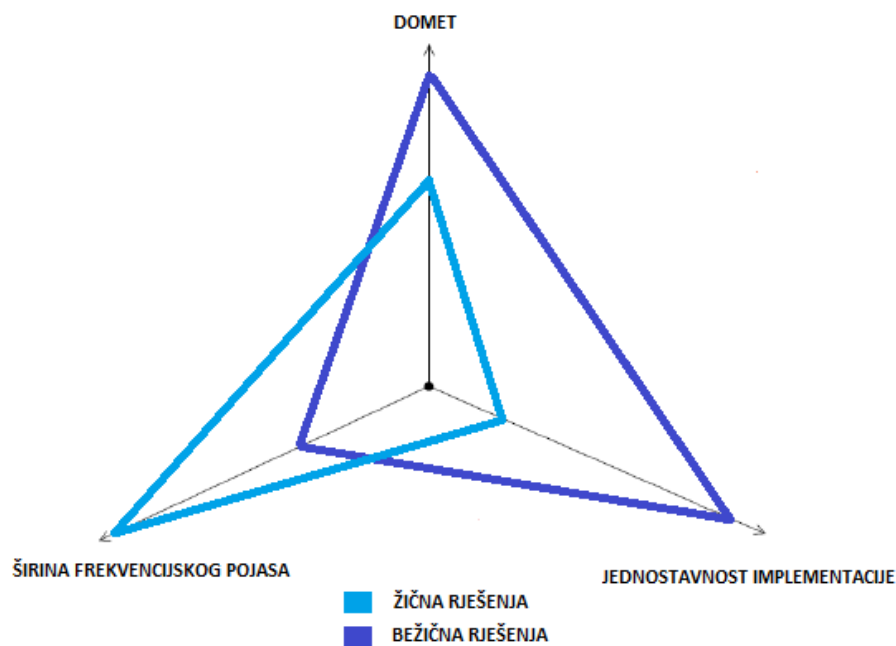
U tablici 2.5. prikazani su najbitniji podaci za navedene vrste širokopojasnih pristupnih rješenja [2]. Za svako od širokopojasnih pristupnih rješenja navedene su mogućnosti njegove implementacije, dio postojeće pristupne infrastrukture koji je moguće iskoristiti, vrste postojećih mrežnih topologija te pristupnih terminala.

Tablica 2.5. Prikaz širokopojsnih pristupnih rješenja

Pristupno rješenje:	Načini implementacije:	Postojeća pristupna infrastruktura koju je moguće iskoristiti:	Prijenosni mediji:	Topologije:	Terminali:
ADSL	izgradnja u cijelosti nove pristupne mrežne infrastrukture ili nadogradnja postojeće infrastrukture javne komutirane telefonske mreže	kabelska kanalizacija, prostori za smještaj mrežne opreme	bakrene parice	točka-točka	fiksni
VDSL			bakrene parice i optički kabeli	točka-točka	fiksni
HFC	izgradnja u cijelosti nove pristupne mrežne infrastrukture ili nadogradnja postojeće mrežne infrastrukture kabelaške televizije		kombinacija optičkih i koaksijalnih kabela	točka-više točaka	fiksni
FTTH PON / P2P	izgradnja u cijelosti nove pristupne mrežne infrastrukture		optički kabeli	točka-više točaka / točka-točka	fiksni
PLC	nadogradnja postojeće elektroenergetske mreže		srednjenaponski i niskonaponski elektroenergetski vodovi	točka-više točaka	fiksni
Wi-Fi	postavljanje nove pristupne mrežne opreme	antenski stupovi, prostori za smještaj mrežne opreme	nelicencirani radijski frekvencijski spektar	točka-više točaka	mobilni
WiMAX	postavljanje nove pristupne mrežne infrastrukture		licencirani ili nelicencirani radijski frekvencijski spektar	točka-više točaka	fiksni ili mobilni
UMTS/ HSPA	postavljanje u cijelosti nove pristupne mrežne infrastrukture ili nadogradnja postojeće infrastrukture mobilne mreže		licencirani radijski frekvencijski spektar	točka-više točaka	mobilni
LTE			licencirani radijski frekvencijski spektar	točka-više točaka	mobilni
Satelitski pristup	postavljanje mrežne opreme na lokaciji korisnika	-	licencirani radijski frekvencijski spektar	točka-više točaka	fiksni ili mobilni (pri malim brzinama)

Gruba usporedba između žičnih i bežičnih pristupnih rješenja navedenih u tablici 2.4. prikazana je na slici 2.4.. Grafički prikaz potrebno je tumačiti okvirno, odnosno kvalitativno budući da postoje značajne razlike, kako između pojedinih vrsta žičnih tehnologija i između pojedinih vrsta bežičnih tehnologija, tako i između standarda za pojedine žične te za pojedine bežične tehnologije.

Prikazana usporedba između skupine žičnih i bežičnih pristupnih tehnologija načinjena je s obzirom na: maksimalni ostvarivi domet tehnologija unutar razmatrane skupine, način implementacije pristupne mrežne infrastrukture te maksimalnu raspoloživu širinu frekvencijskih pojaseva po korisniku unutar skupine [2]. Pri usporedbi dometa između navedenih skupina tehnologija bitno je naznačiti da je maksimalni ostvarivi domet pojedinih bežičnih rješenja veći u odnosu na maksimalni domet koji je moguće ostvariti žičnim pristupnim rješenjima. Nadalje, s obzirom na složenost implementacije mrežne infrastrukture i na činjenicu da je za žična rješenja nužna izgradnja ili nadogradnja žične pristupne infrastrukture, implementacija bežičnih rješenja je jednostavnija. Konačno, s obzirom na maksimalne ostvarive širine frekvencijskih pojaseva po korisniku, žične su tehnologije u prednosti nad bežičnim rješenjima budući da ostvarive širine frekvencijskih pojaseva bežičnih tehnologija ovise o brojnim čimbenicima, poput udaljenosti od pristupnih točaka te o interferenciji.



Slika 2.4. Usporedba žičnih i bežičnih pristupnih rješenja

Ovisno o navedenim karakteristikama tehnologija prikazanim u tablici 2.4, o načinima implementacije pojedinih pristupnih rješenja prikazanim u tablici 2.5. te o dostupnoj mrežnoj infrastrukturi moguće je odabrati prikladna tehnološka rješenja za pojedine tipove područja. Pri tome se zbog specifičnosti ruralnih područja najčešće razlikuju širokopolasna pristupna rješenja prikladna za ruralna područja od onih prikladnih u urbanim područjima.

2.5. Širokopojasni pristup Internetu u ruralnim područjima

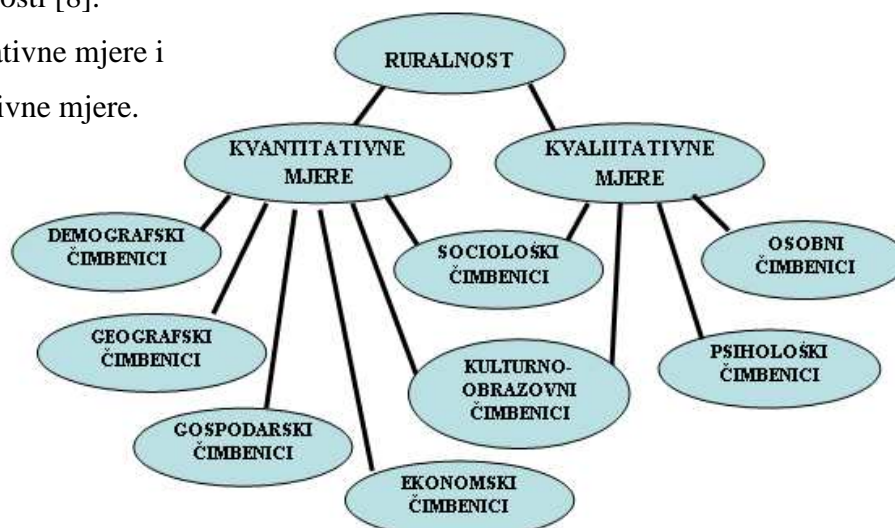
Zbog specifičnosti ruralnih područja uvođenje širokopojasnog pristupa Internetu u ruralnim područjima predstavlja poseban izazov. S obzirom na značajne razlike između ruralnih i urbanih područja te na razlike između pojedinih tipova ruralnih područja, razlikuje se i izbor prikladnih širokopojasnih pristupnih rješenja u tim područjima te način njihove implementacije.

Stoga je u cilju jednoznačne klasifikacije područja na ruralna i urbana područja potrebno izvršiti izbor najprikladnijeg kriterija ruralnosti, razmotriti osnovne značajke ruralnih područja i definirati razlike između ruralnih i urbanih područja, kako je načinjeno u nastavku ovog poglavlja. Nadalje, s obzirom na definirane razlike između područja potrebno je utvrditi i postoje li između ruralnih i urbanih područja razlike u razinama primjene širokopojasnih tehnologija i usluga. Na temelju dobivenih rezultata, kao i značajki prethodno opisanih širokopojasnih tehnologija, potrebno je predložiti širokopojasna pristupna rješenja prikladna za ruralna područja, što je načinjeno u nastavku poglavlja.

2.5.1. Ruralna područja i mjere ruralnosti

Ruralna područja obuhvaćaju seoska naselja, poljoprivredne površine i šume, te sva područja s naglašenim prirodnim karakteristikama pejzaža. Ova područja nastajala su kao posljedica povijesnih zbivanja, demografskog i gospodarskog ustroja područja, reljefnih obilježja prostora. U svrhu utvrđivanja ruralnosti određenog područja najčešće se primjenjuju sljedeće mjere ruralnosti [8]:

- kvantitativne mjere i
- kvalitativne mjere.



Slika 2.5. Kvantitativne i kvalitativne mjere ruralnosti

Tablica 2.6. Kvantitativne i kvalitativne mjere ruralnosti područja

KVANTITATIVNE MJERE		
SOCIO- DEMOGRAFSKA SKUPINA ČIMBENIKA	Gustoća naseljenosti	OECD i EU razmatraju ruralnost područja prema gustoći naseljenosti. Prema njihovim kriterijima, ruralna područja su područja s gustoćom naseljenosti ispod: 150 stan./km ² (kriterij OECD-a), odnosno 100 stan./km ² (kriterij EU-a).
	Udio ruralnog stanovništva	OECD kriterij razmatra strukturu stanovništva, odnosno udio ruralnog stanovništva u ukupnom broju stanovnika na određenim područjima i razlikuje: <i>pretežno ruralna područja:</i> područja u kojima udio ruralnog stanovništva iznosi 15%-50% <i>izrazito ruralna područja:</i> područja u kojima udio ruralnog stanovništva iznosi 50%-100%.
	Dobna struktura stanovništva	Zbog depopulacije i iseljavanja mladog stanovništva, u ruralnim područjima uglavnom dominira starije stanovništvo.
	Obrazovna struktura stanovništva	Udio stanovnika sa srednjom, višom i visokom stručnom spremom u ukupnom stanovništvu je u ruralnim područjima često niži nego u urbanim područjima.
GEO- EKONOMSKA SKUPINA ČIMBENIKA	Reljefna i morfološka obilježja prostora	Ruralna područja su područja s naglašenim prirodnim karakteristikama pejzaža.
	Dohodak po glavi stanovnika	Dohodak po glavi stanovnika je u ruralnim područjima uglavnom niži nego u urbanima.
	Zaposlenost	Stopa zaposlenosti je u ruralnim područjima često niža nego u urbanim područjima.
	Sektori djelatnosti	Ruralni razvoj osigurava stanovništvu proizvodne zalihe prehrambenih proizvoda i obnovljivih primarnih sirovina, pa je za ruralna područja karakteristična značajna zastupljenost primarnog sektora djelatnosti.
	Prosječni prihodi	Prihodi su u ruralnim područjima uglavnom niži nego u urbanim područjima. Od ukupno četiri različita društvena sloja - sloj vrlo bogatih, sloj relativno dobro situiranih, sloj onih koji ne oskudijevaju te sloj onih koji oskudijevaju, u ruralnim područjima dominantna su posljednja dva sloja.
KVALITATIVNE MJERE		
SOCIO- PSIHOLOŠKA SKUPINA ČIMBENIKA	Utjecaj obitelji	Utjecaj obitelji je tradicijski naglašeniji u ruralnim nego u urbanim područjima.
	Navike i potrebe stanovnika	Navike i potrebe stanovnika ruralnih područja razlikuju se u odnosu na navike i potrebe urbanog stanovništva.
	Stil i način života stanovništva	Konkretni aktivnosti i interesi pojedinca čine njegov životni stil, a odražavaju se na okolinu u kojoj pojedinac živi i radi. Životni stil i način života se u ruralnim područjima razlikuje u odnosu na stil i način života stanovnika u urbanim područjima.

Kvantitativne i kvalitativne mjere ruralnosti obuhvaćaju različite čimbenike prikazane na slici 2.5., od kojih su među najbitnijim skupinama čimbenika vezanima uz određivanje ruralnosti područja socio-demografska skupina, geo-ekonomska skupina i socio-psihološka skupina, detaljnije opisane u tablici 2.6..

2.5.1.1. Kategorizacija ruralnih područja

Kvantitativne mjere ruralnosti obuhvaćaju kategorizaciju područja prema gustoći naseljenosti te prema udjelu ruralnog stanovništva u ukupnom broju stanovnika [10]. No, s obzirom na činjenicu da postoji više različitih kvantitativnih kriterija ruralnosti područja zasnovanih na gustoći naseljenosti, otežana je jednoznačna klasifikacija područja na ruralna i urbana područja.

Stoga je nužno analizirati i usporediti osnovne kriterije za definiranje ruralnosti promatranih područja – OECD i EU kriterije. Nakon toga je moguće izvršiti izbor najprikladnijeg kriterija za promatrana područja [9].

Kako je prikazano kroz sljedeći studijski primjer kategorizacije hrvatskih područja prema gustoći naseljenosti, EU kriterij ruralnosti je, u odnosu na OECD kriterij, prikladniji za hrvatski (i europski) prostor budući da omogućuje primjereniju klasifikaciju područja na ruralna i urbana područja,.

2.5.1.2. Studijski primjer: Kategorizacija hrvatskih područja i županija prema kvantitativnim mjerama ruralnosti

Prema OECD kriteriju, u Republici Hrvatskoj ruralna područja zauzimaju oko 90% kopnenog dijela zemlje, a u njima živi oko 47% ukupnog stanovništva, iz čega se vidi kako Republika Hrvatska kao država pokazuje visok stupanj ruralnosti [10].

Kako je prikazano u tablici 2.7., primjena OECD-ovog kriterija na hrvatske županije nije prikladna pri daljnjoj analizi budući da se prema tom kriteriju samo područje Grada Zagreba i Međimurska županija mogu definirati urbanima. Stoga se u analizi ruralnosti županija Republike Hrvatske primjenjuje kriterij Europske unije [10].

Tablica 2.7. Kategorizacija hrvatskih županija

	Županija	Gustoća naseljenosti (<i>stan./km²</i>)		OECD kriterij ruralnosti	EU kriterij ruralnosti
		Popis 2001.	Popis 2011.		
1.	Ličko-senjska	10	10	RURALNA	RURALNA
2.	Šibensko-kninska	38	37	RURALNA	RURALNA
3.	Karlovačka	39	36	RURALNA	RURALNA
4.	Sisačko-moslavačka	41	39	RURALNA	RURALNA
5.	Zadarska	44	47	RURALNA	RURALNA
6.	Virovitičko-podravska	46	42	RURALNA	RURALNA
7.	Požeško-slavonska	47	43	RURALNA	RURALNA
8.	Bjelovarsko-bilogorska	50	45	RURALNA	RURALNA
9.	Dubrovačko-neretvanska	69	69	RURALNA	RURALNA
10.	Koprivničko-križevačka	71	66	RURALNA	RURALNA
11.	Istarska	73	74	RURALNA	RURALNA
12.	Osječko-baranjska	80	73	RURALNA	RURALNA
13.	Vukovarsko-srijemska	83	73	RURALNA	RURALNA
14.	Primorsko-goranska	85	83	RURALNA	RURALNA
15.	Brodsko-posavska	87	78	RURALNA	RURALNA
16.	Zagrebačka	101	104	RURALNA	URBANA
17.	Splitsko-dalmatinska	102	100	RURALNA	URBANA
18.	Krapinsko-zagorska	116	108	RURALNA	URBANA
19.	Varaždinska	146	139	RURALNA	URBANA
20.	Međimurska	162	157	URBANA	URBANA
21.	Grad Zagreb	1 215	1 237	URBANA	URBANA

Prema EU kriteriju su, od ukupno 21 županije, njih 15 kvalificirane kao ruralne. Dakle, na temelju EU kriterija, ruralne županije su: Ličko-senjska, Šibensko-kninska, Karlovačka, Sisačko-moslavačka, Zadarska, Virovitičko-podravska, Požeško-slavonska, Bjelovarsko-bilogorska, Dubrovačko-neretvanska, Koprivničko-križevačka, Istarska, Osječko-baranjska, Vukovarsko-srijemska, Primorsko-goranska i Brodsko-posavska županija.

Za mjeru ruralnosti uzima se često i udio ruralnog stanovništva u ukupnom broju stanovnika županije. Ako se na prostor Republike Hrvatske primjene ovi kriteriji, tada se prostor Republike Hrvatske ponovno može podijeliti na urbani i ruralni prostor. Na temelju ovog kriterija, ruralne županije su: Krapinsko-zagorska, Međimurska, Brodsko-posavska, Virovitičko-podravska, Vukovarsko-srijemska i Koprivničko-križevačka. U Varaždinskoj, Ličko-senjskoj, Bjelovarsko-bilogorskoj, Zadarskoj i Osječko-baranjskoj županiji udio ruralnog stanovništva iznosi približno 40%.

Objedinjeni rezultati primijenjenih kriterija ruralnosti pokazuju da obje kvantitativne mjere ruralnosti zadovoljavaju Brodsko-posavska, Virovitičko-podravska, Vukovarsko-srijemska i Koprivničko-križevačka županija. Uz navedeno, potrebno je istaknuti kako i Osječko-baranjska županija ima opravdane specifične karakteristike ruralnosti – najveća prigradska naselja s karakteristikama ruralnih područja, što je bitno za kvantitativnu analizu te tradiciju razvoja gospodarstva zasnovanog na poljoprivredi i ratarstvu kao primarom sektoru djelatnosti tipičnom za ruralna područja.

2.5.1.3. Kategorizacija ruralnih naselja

Prema kvantitativnim kriterijima moguće je kategorizirati i naselja [11]. Pri diferencijaciji naselja na ruralna i urbana osnovni su pokazatelji:

- upravni status naselja,
- veličina naselja - izražena brojem stanovnika,
- socio-ekonomska struktura stanovništva - izražena udjelom zaposlenih mještana u pojedinim sektorima djelatnosti (u ruralnim i prijelaznim naseljima dominira primarni sektor djelatnosti, a u urbanim naseljima sekundarni i tercijarni sektor),
- morfološko-fizionomska obilježja naselja - izražena udjelom poljoprivrednih kućanstava.

Model izdvajanja urbanih naselja definiran u [12], prikazan je u tablici 2.8.. Naselja koja se prema navedenim kriterijima ne mogu definirati kao urbana, smatraju se ruralnim naseljima.

Tablica 2.8. Model izdvajanja urbanih naselja [12]

Veličina naselja izražena brojem stanovnika	Udio nepoljoprivrednih kućanstava	Udio zaposlenih stanovnika, osim aktivnog poljoprivrednog stanovništva	Stupanj centraliteta
< 2 000	≥ 50%	≥ 25%	Subregionalni centar
2 000 – 4 900	≥ 50%	≥ 25%	-
5 000 – 9 999	-	≥ 25%	-
> 10 000	-	-	-

S obzirom na činjenicu da se sva ruralna naselja ne mogu promatrati na isti način zbog njihovih brojnih razlika (poput razlika u gustoćama naseljenosti te njihovim udaljenostima od urbanih središta), predložena je kategorizacija ruralnih naselja na različite tipove [9].

Kako je prikazano i u sljedećem studijskom primjeru, ruralna naselja moguće je podijeliti na sljedeće tipove:

- seoska naselja, koja uključuju:
 - zbijena ili grupirana sela (kružna, izdužena, pravokutna...)
 - disperzna sela (raštrkana, raspršena)
 - osamljena gospodarstva
- prijelazna naselja, odnosno:
 - male gradiće - prigradska naselja (naselja s karakteristikama ruralnih područja vezana uz urbana naselja).

2.5.1.4. Studijski primjer: Kategorizacija hrvatskih ruralnih naselja

Ruralna naselja, odnosno seoska i prijelazna naselja zauzimaju 88% naseljene površine Republike Hrvatske, a u njima živi 37% stanovništva. Republika Hrvatska ima veći broj seoskih naselja u odnosu na europski prosjek, s tim što je broj stanovnika u selima manji od tog prosjeka.

Nadalje, za Republiku Hrvatsku je karakteristična usitnjenost sela. Tome u prilog govore podaci kako 30% sela ima manje od sto stanovnika, a 80% seoskih i mješovitih naselja ima manje od petsto stanovnika. Dakle, u Republici Hrvatskoj prevladavaju mala seoska naselja. Sela s malim brojem stanovnika i ostarjelim stanovništvom raširena su u Žumberku, Gorskoj Hrvatskoj, Istri, Kvarneru, Vinodolu, Dubrovačkom primorju i na otocima.

Dok se osamljena gospodarstva te raspršena i raštrkana disperzna sela najvećim dijelom nalaze u peripanonskim brežuljkastim područjima i na prigorjima panonskih gora, mali gradići – prigradska naselja nalaze se u neposrednoj okolini većih gradova i županijskih središta (u Istočnoj Slavoniji, Srijemu, Baranji i Podravini). Zbijena sela, sela izrazito pravilnog oblika nalaze se u istočnoj Slavoniji i Srijemu, raštrkana sela, sela sa zaseocima i osamljenim gospodarstvima, u peripanonskoj brežuljkastoj Hrvatskoj i na prigorjima panonskih gora, a nizna sela, sela uglavnom uz cestu, potok, rijeku, u zapadnoj Slavoniji.

2.5.1.5. Problemi ruralnih područja

Danas postoje brojne razlike između urbaniziranih područja oko velikih gradova i izrazito ruralnih područja. Ruralna područja se suočavaju s brojnim problemima. Najizraženiji problemi su degradacijski procesi, depopulacija te zanemarivanje gospodarskog razvoja u tim područjima. Promjene u gospodarstvu su u ruralnim područjima utjecale na smanjenje broja radnih mjesta u poljoprivredi i industriji. Zanemarivanje razvojne komponente ruralnih područja dovelo je do ekonomskog i socijalnog pada koji je uvjetovao daljnja iseljavanja mladog i obrazovanog, odnosno radno aktivnog stanovništva. Posljedice depopulacije su iznimno teške. U nekim je ruralnim regijama broj aktivnog radnog stanovništva jako smanjen, pa se sela suočavaju s izraženom nezaposlenošću stanovništva.

Veći gradovi postali su nositelji ekonomskog, društvenog i kulturnog razvoja te su privlačili obrazovano mlado stanovništvo. Stoga je stanovništvo uglavnom koncentrirano oko većih regionalnih središta, što upućuje na činjenicu da su tamo i različita komercijalna infrastrukturna ulaganja isplativija uslijed postojanja veće i koncentriranije potražnje. Ostala su područja slabije naseljena, pa su u tom smislu i manje privlačna za ulaganja. Slabiji ekonomski razvoj manjih regionalnih centara utjecao je na depopulaciju brojnih ruralnih prostora koji su zahvaćeni dugogodišnjim depopulacijskim procesima, pa se u njima tek u posljednje vrijeme oblikuju infrastrukturni preduvjeti za iniciranje gospodarskog razvoja, poput osiguravanja nužne informacijske i komunikacijske infrastrukture.

Budući da je razvoj svake države povezan s razvojem svih njenih područja, pa tako i svih pripadnih ruralnih područja [10], nužne su sustavne mjere koje potiču razvoj ruralnih područja. U takve mjere ubraja se i uvođenje informatizacije u ruralna područja [13] jer je svim stanovnicima potrebno osigurati jednak pristup znanju i informacijama, bez obzira na zemljopisne, socijalne, generacijske te druge razlike [1]. Nadalje, u ruralnim područjima bitno je i poticanje ulaganja u svu informacijsku i komunikacijsku infrastrukturu, kao što je i širokopojasna pristupna infrastruktura [14] koja je trenutno slabije razvijena u ruralnim područjima, kako je detaljnije opisano u nastavku rada.

2.5.2. Problem digitalnog jaza

U ruralnim područjima danas su jako izražene razlike u razinama dostupnosti i stupnju primjene širokopojasnih tehnologija u odnosu na urbana područja, odnosno prisutan je tzv. **problem digitalnog jaza**, koji se nalazi u fokusu istraživanja provedenih u ovom radu.

Suvremena očekivanja usmjerena su prema ravnomjernijem prostornom razvitku svih područja, pa su doneseni brojni programi i strategije za poticanje revitalizacije ruralnih područja i izjednačavanje kvalitete života u urbanim i ruralnim područjima kroz poticanje uvođenja novih informacijskih i komunikacijskih infrastrukturnih rješenja, kako u Svijetu i Europi [1], tako i u Hrvatskoj [14]. Dio tih programa vezan je uz poticanje svjesnosti o važnosti pristupa informacijama primjenom naprednih informacijskih i komunikacijskih tehnologija u svim urbanim i ruralnim područjima te poticanje investicija vezanih uz implementaciju novih tehnoloških rješenja poput širokopojasnih pristupnih rješenja.

Poticanje primjene naprednih informacijskih i komunikacijskih tehnologija poput širokopojasnih pristupnih tehnologija te poticanje investicija vezanih uz implementaciju širokopojasnih pristupnih rješenja u ruralnim područjima trebalo bi pridonijeti revitalizaciji i razvoju ruralnih prostora.

Među čimbenicima koji utječu na dostupnost širokopojasnog pristupa na određenom području isplativost njegovog uvođenja jedan je od glavnih čimbenika. Zbog specifičnosti ruralnih područja (veća udaljenost korisnika od mjesta pristupa mreži, manji broj korisnika po pristupnoj platformi i dr.), troškovi za uvođenje širokopojasnog pristupa Internetu po korisniku su u ruralnim područjima viši od troškova pristupa u urbanim područjima. Stoga, iako je pokrivenost širokopojasnim uslugama u urbanim područjima uglavnom dobro riješena, još je uvijek prisutan problem nedovoljne dostupnosti širokopojasnog pristupa Internetu u ruralnim područjima.

Pokušaji premošćivanja ovih razlika rezultirali su porastom ukupnog broja širokopojasnih priključaka u proteklih nekoliko godina. Međutim, između brojnih urbanih i ruralnih područja prisutan je digitalni jaz, odnosno velika razlika u dostupnosti širokopojasnog pristupa Internetu.

Kako bi se razmotrio digitalni jaz između pojedinih ruralnih i urbanih područja, potrebno je provesti analizu dostupnih podataka o broju širokopojsnih priključaka po glavi stanovnika u takvim područjima. Nad prikupljenim podacima za procjenu je moguće primijeniti sljedeću logističku funkciju:

$$Y_{ix} = a / (1 + e^{-(b+c \cdot x)}) + d_{ix} \quad (2.1)$$

pri čemu Y_{ix} predstavlja broj širokopojsnih priključaka po glavi stanovnika u području i u godini x , parametar a određuje trenutak nakon kojeg se smanjuje porast broja novih korisnika, parametar b određuje brzinu porasta broja korisnika, parametar c određuje potencijal tehnologije na tržištu, a parametar d_{ix} prikazuje pogrešku načinjene aproksimacije.


Nakon toga, potrebno je usporediti procijenjene prosječne vrijednosti u ruralnim i urbanim područjima. Ukoliko su parametar a , koji prikazuje dugoročnu procjenu broja širokopojsnih priključaka, te parametar b , koji određuje brzinu porasta broja korisnika, veći u urbanim nego u ruralnim područjima, može se zaključiti kako niti u jednom budućem trenutku ruralna područja ne mogu dostići prosjek broja širokopojsnih priključaka po glavi stanovnika istovjetan onom u urbanim područjima, kako je pokazano i u analizi načinjenoj u sljedećem studijskom primjeru.

2.5.2.1. Studijski primjer: Digitalni jaz između hrvatskih ruralnih i urbanih područja i županija

U cilju utvrđivanja postojanja te procjene digitalnog jaza između ruralnih i urbanih područja, provedena je sljedeća analiza. Za procjenu prosječnog broja širokopojsnih priključaka po glavi stanovnika primijenjena je logistička funkcija (2.1) nad prikupljenim podacima za hrvatske ruralne i urbane županije u periodu od 2002. do 2011. godine.

Pri tome Y_{ix} predstavlja broj širokopojsnih priključaka po glavi stanovnika u županiji i u godini x , parametar a određuje trenutak nakon kojeg se smanjuje porast broja novih korisnika, parametar b određuje brzinu porasta broja korisnika, parametar c određuje potencijal širokopojsne pristupne tehnologije na tržištu, a parametar d_{ix} prikazuje pogrešku aproksimacije.

Na slici 2.6. su prikazane prosječne vrijednosti broja širokopojsnih priključaka po glavi stanovnika u hrvatskim ruralnim (BB_RUR) i urbanim (BB_URB) županijama, minimalne vrijednosti u ruralnim županijama (BB_RURmin), maksimalne vrijednosti u urbanim županijama (BB_URBmax) te pripadne logističke funkcije (*Logistic*). Prikazane prosječne, maksimalne i minimalne vrijednosti ukazuju na postojanje digitalnog jaza.



Slika 2.6. Digitalni jaz između ruralnih i urbanih županija


Na temelju podataka o prosječnom broju širokopojsnih priključaka po glavi stanovnika u urbanim županijama, ruralnim županijama te Republici Hrvatskoj procijenjeni su parametri logističkih funkcija prikazani u tablici 2.9.. Prema vrijednostima parametra d_{ix} vidi se da su u svim promatranim slučajevima pogreške procjene vrlo male te da je broj korisnika dobro opisan prikazanom logističkom funkcijom.

Također, prema dobivenim rezultatima moguće je zaključiti da je parametar a , koji prikazuje dugoročnu procjenu broja širokopojsnih priključaka, veći u urbanim nego u ruralnim županijama. Dugoročno gledano, prosječan broj širokopojsnih priključaka u urbanim županijama teži prema 24%, dok u ruralnim županijama teži prema 21%.

Tablica 2.9. Rezultati procjene broja širokopojsnih priključaka logističkom funkcijom

Parametri :	Vrijednosti: (uz 95% razinu vjerojatnosti)	
Urbane županije (<i>Logistic_URB</i>)		
a	0.2362	(0.2167, 0.2556)
b	-2.029	(-2.329, -1.73)
c	3.128	(2.574, 3.682)
d	-0.003656	(-0.009311, 0.001999)
Standardna pogreška (SSE)	0.000276	
Koeficijent determinacije (R-square)	0.9971	
Korigirani koeficijent determinacije (Adjusted R-square)	0.9962	
Korijen srednje kvadratne pogreške (RMSE)	0.005253	
Ruralne županije (<i>Logistic_RUR</i>)		
a	0.2088	(0.1895, 0.228)
b	-2.4	(-2.643, -2.158)
c	2.824	(2.404, 3.244)
d	-0.002541	(-0.006043, 0.0009618)
Standardna pogreška (SSE)	0.0001053	
Koeficijent determinacije (R-square)	0.9982	
Korigirani koeficijent determinacije (Adjusted R-square)	0.9976	
Korijen srednje kvadratne pogreške (RMSE)	0.003245	
Prosjek - Republika Hrvatska		
a	0.2211	(0.2011, 0.2411)
b	-2.185	(-2.461, -1.91)
c	2.927	(2.436, 3.418)
d	-0.003212	(-0.007843, 0.00142)
Standardna pogreška (SSE)	0.0001811	
Koeficijent determinacije (R-square)	0.9975	
Korigirani koeficijent determinacije (Adjusted R-square)	0.9968	
Korijen srednje kvadratne pogreške (RMSE)	0.004256	

Nadalje, s obzirom na činjenicu da je parametar *b*, koji određuje brzinu porasta broja korisnika, veći u urbanim nego u ruralnim županijama, može se zaključiti kako niti u jednom budućem trenutku ruralne županije ne mogu dostići prosjek broja širokopojsnih priključaka po glavi stanovnika istovjetan onom u urbanim županijama u promatranom periodu, kako je prikazano i na slici 2.7.. Dakle, rezultati ukazuju na postojanje digitalnog jaza između ruralnih i urbanih područja, te na činjenicu da, ukoliko se nastave prikazani trendovi porasta broja korisnika širokopojsnog Interneta, jaz između ruralnih i urbanih područja neće biti moguće premostiti. Stoga se nameće zaključak kako je nužno primijeniti mjere te kreirati modele koji bi trebali potaknuti intenzivniju primjenu širokopojsnih usluga u ruralnim područjima.



Slika 2.7. Procjena broja širokopolasnih priključaka po glavi stanovnika u ruralnim i urbanim županijama

2.5.2.2. Smjernice za smanjenje digitalnog jaza

Suvremene informacijske i komunikacijske mreže, poput širokopolasnih pristupnih mreža imaju široki raspon tehnoloških i poslovnih primjena, a o stupnju razvijenosti informacijske i komunikacijske infrastrukture te o stupnju primjene informacijskih i komunikacijskih usluga ovisi i razvoj pojedinih područja. Primjena širokopolasnih tehnologija, aplikacija i usluga smatra se ključnim pokretačem ekonomskog i gospodarskog rasta, zaposlenosti, konkurentnosti i učinkovitosti te načinom povećanja kvalitete života stanovnika. Budući da je razvoj svake države i regije povezan s razvojem svih njenih područja, u svim je područjima nužno osigurati širokopolasni pristup Internetu te svim stanovnicima omogućiti primjenu širokopolasnih aplikacija i usluga.

Postavljeni ciljevi vezani uz smanjenje digitalnog jaza rezultirali su značajnim porastom ukupnog broja širokopolasnih priključaka u europskim državama u nekoliko posljednjih godina, međutim jaz između urbanih i ruralnih područja unutar pojedinih država i dalje je jako izražen. Na to ukazuju i dobiveni rezultati prethodno opisane analize. Dakle, rezultati provedene analize ukazuju na postojanje velikih razlika u dostupnosti širokopolasne pristupne infrastrukture, tj. digitalnog jaza između promatranih ruralnih i urbanih područja te na

činjenicu da, ukoliko se nastave prikazani trendovi porasta broja korisnika širokopojasnog pristupa Internetu, jaz između ruralnih i urbanih područja neće biti moguće premostiti.

Stoga bi smanjenju digitalnog jaza trebalo pridonijeti:

- *poticanje daljnjeg digitalnog opismenjavanja ruralnog stanovništva;*
- *poticanje daljnjeg usvajanja širokopojasnih pristupnih rješenja kroz razvoj novih aplikacija i usluga prilagođenih zahtjevima i potrebama stanovnika ruralnih područja (takve aplikacije i usluge korisnicima bi trebale omogućiti jednostavniju komunikaciju, pristup važnim elektroničkim informacijskim uslugama, stjecanje novih znanja kroz primjenu on-line edukacijskih sadržaja, rad na daljinu i sl.);*
- *poticanje daljnje implementacije i razvoja širokopojasne pristupne infrastrukture (stoga je nužno utvrditi najbitnije čimbenike koji su u ruralnim područjima povezani s implementacijom širokopojasnog pristupa Internetu, odabrati najprikladnija širokopojasna pristupna rješenja za ruralna područja i omogućiti njihovu daljnju implementaciju, kroz čega bi se trebalo ostvariti povećanje ukupnog broja korisnika širokopojasnog pristupa te smanjenje postojećeg digitalnog jaza).*

2.5.3. Širokopojasna pristupna rješenja prikladna za ruralna područja

Ovisno o navedenim karakteristikama tehnologija prikazanim u tablici 2.4, o načinima implementacije pojedinih pristupnih rješenja prikazanim u tablici 2.5. te o dostupnoj mrežnoj infrastrukturi, moguće je od navedenih širokopojasnih rješenja odabrati rješenja prikladna za ruralna područja.

Budući da su infrastrukture javnih komutiranih telefonskih mreža te elektroenergetskih mreža danas uglavnom dostupne u većini ruralnih područja, među najdostupnijim žičnim infrastrukturnim rješenjima za pristup Internetu u ruralnim područjima svakako su xDSL i PLC. Postojeće parične i elektroenergetske mrežne infrastrukture moguće je nadograditi kako bi se one prilagodile za širokopojasni prijenos podataka. Budući da ADSL tehnologija omogućuje širokopojasni prijenos podataka na veće udaljenosti u odnosu na VDSL, ADSL se smatra prikladnijim rješenjem za ruralna područja. ADSL2 i ADSL2+ standardi koji predstavljaju nadogradnju na postojeći ADSL, uz brži prijenos podataka omogućuju prijenos podataka na veće udaljenosti, što je posebno bitno za ruralna područja. Izgradnja u cijelosti nove pristupne infrastrukture optičke mreže predstavlja složenije rješenje, pa se unatoč

brojnim prednostima u odnosu na druga pristupna rješenja, s obzirom na složenost i visoke troškove implementacije [4], optičke mreže često ne smatraju prikladnim pristupnim rješenjem za ruralna područja. Nadalje, s obzirom na činjenicu da je kabelska mreža uglavnom implementirana u urbanim središtima, a da je implementacija kabelske infrastrukture relativno skupa [4], ni ova se tehnologija često ne razmatra kao pristupno rješenje prikladno za ruralna područja.

Između ponuđenih bežičnih pristupnih rješenja navedenih u tablici 2.5., rješenja koja zahtijevaju određenu nadogradnju postojeće mrežne infrastrukture su UMTS/HSPA i LTE, dok WiMAX zahtjeva postavljanje nove pristupne infrastrukture. Postavljanje mrežne opreme nužno je za satelitski i Wi-Fi pristup. Sva navedena bežična rješenja prikladna su za ruralna područja budući da omogućuju jednostavniju implementaciju u odnosu na postavljanje novih žičnih rješenja. Međutim, iako kod satelitskog i Wi-Fi pristupa nema potrebe za izgradnjom pristupne infrastrukture, budući da su dozvole za uporabu radiofrekvencijskog spektra za satelitsku komunikaciju skupe [2], a da je primjena Wi-Fi tehnologije uglavnom vezana uz lokalne mreže u urbanim područjima, ove se tehnologije često ne razmatraju kao najprikladnija pristupna rješenja za ruralna područja.

Pri implementaciji širokopojasnih pristupnih mreža potrebno je uvijek kada je moguće iskoristiti postojeću mrežnu infrastrukturu budući da to omogućuje bržu i ekonomičniju izgradnju mreža [5]. Dok je u žičnim pristupnim mrežama moguće iskoristiti postojeću kabelsku kanalizaciju i dostupne prostore za smještaj mrežne opreme, u bežičnim pristupnim mrežama moguće je iskoristiti postojeće antenske stupove te prostore za smještaj opreme. Ovakvi načini smanjenja troškova implementacije novih pristupnih rješenja posebno su bitni u ruralnim područjima u kojima ulaganje u pristupnu infrastrukturu često nije isplativo.

Kako je već istaknuto, za širokopojasni prijenos podataka bitno je odabrati odgovarajuću mrežnu infrastrukturu. Izbor mrežne infrastrukture i širokopojasnih tehnologija ovisi o brojnim čimbenicima, vezanima ponajprije uz značajke samih područja, ali i uz sudionike te stanje na telekomunikacijskim tržištima prisutno na određenim područjima. Zato je prilikom razmatranja mogućnosti i opravdanosti uvođenja širokopojasnih pristupnih rješenja u pojedinim područjima uvijek potrebno načiniti sustavnu analizu čimbenika bitnih za njegovo uvođenje, pa su metode i modeli koji se pri tome mogu primijeniti detaljno opisani u idućem poglavlju rada.

3. VREDNOVANJE TEHNIČKIH MOGUĆNOSTI I EKONOMSKIH ASPEKATA UVOĐENJA ŠIROKOPOJASNOG PRISTUPA INTERNETU

Na dostupnost širokopojasnog pristupa Internetu na određenom području utječe veliki broj različitih čimbenika. Stoga je prilikom razmatranja mogućnosti i opravdanosti uvođenja širokopojasnih pristupnih rješenja u pojedinim područjima potrebno načiniti sustavnu analizu svih čimbenika bitnih za njegovo uvođenje.

Sve popularniji telekomunikacijski sustavi nove generacije pružaju niz novih tehnoloških i poslovnih mogućnosti. Pri planiranju takvih sustava, kakve su i širokopojasne pristupne mreže, te pri investiranju u njihov razvoj nužno je postići ravnotežu u procesu poslovnog upravljanja, opisanom u nastavku rada. Budući da su takve pristupne mreže namijenjene pružanju komunikacijskih usluga temeljenih na širokopojasnim prijenosnim tehnologijama s garantiranom kvalitetom usluga, one moraju imati povećani kapacitet u svom pristupnom dijelu. Upravo su sve izraženija potreba za osiguravanjem definiranih razina kvalitete pruženih usluga te povezanost između mogućnosti pružanja kvalitete i dostupne infrastrukture dovele do potrebe za detaljnom analizom tehničkih, ekonomskih i tržišnih aspekata poslovnih prilika, odnosno za provedbom tehno-ekonomskih analiza.

Različite metode tehno-ekonomskog modeliranja od ranih devedesetih godina prošlog stoljeća koriste se za analizu i usporedbu tehničkih mogućnosti i ekonomske opravdanosti uvođenja različitih telekomunikacijskih rješenja. Kroz brojne projekte detaljno su analizirani različiti aspekti uvođenja telekomunikacijskih mreža i usluga na tržišta. U posljednjih desetak godina tehno-ekonomsko modeliranje primjenjuje se i pri analizama mogućnosti i opravdanosti uvođenja širokopojasnih pristupnih mreža i usluga. Provedene analize se međusobno razlikuju ovisno o primijenjenim metodama te ovisno o analiziranim aspektima koji se stavljaju u fokus istraživanja. Kako bi bila moguća lakša usporedba različitih rješenja primijenjenih u brojnim provedenim studijama i analizama koje razmatraju uvođenje širokopojasnih pristupnih mreža, nedostaje kategorizacija i usporedni prikaz najrelevantnijih metoda i tehno-ekonomskih modela, odnosno sustavna analiza postojećih tehno-ekonomskih metoda i modela koji se primjenjuju za vrednovanje tehničkih mogućnosti i ekonomske opravdanosti uvođenja širokopojasnih pristupnih mreža. Stoga je u nastavku rada dan opis te je provedena nužna kategorizacija i usporedba primijenjenih tehno-ekonomskih metoda i modela iz literature.

3.1. Poslovno planiranje u telekomunikacijama

Pri planiranju telekomunikacijskih sustava, kakve su i širokopojasne pristupne mreže, te pri investiranju u njihov razvoj nužno je postići ravnotežu u procesu poslovnog upravljanja budući da način provedbe procesa poslovnog upravljanja utječe na efikasnost postupaka projektiranja, razvoja i eksploatacije telekomunikacijskih sustava te na ukupne troškove tih postupaka. U cilju postizanja što veće efikasnosti potrebno je kontinuirano vršiti analize i pronaći ravnotežu između svih parametara i troškova koji mogu utjecati na efikasnost procesa poslovnog upravljanja, procesa koji se sastoji od sljedećih faza - poslovnog planiranja, realizacije te kontrole [15].

Prva faza, faza poslovnog planiranja predstavlja osnovu procesa poslovnog upravljanja. Ona uključuje definiranje ciljeva, smjerova i mogućih alternativa pri realizaciji postavljenih ciljeva, analizu tehničkih i ekonomskih aspekata poslovnih mogućnosti te izbor najoptimalnijeg rješenja. U ovoj fazi izrađuju se investicijski planovi te srednjoročni i dugoročni planovi razvoja [16]. Pri donošenju odluka o investiranju i pri procesima planiranja razvoja telekomunikacijskih sustava, koriste se sljedeći modeli [17]:

- *ekonometrijski modeli* – modeli koji primjenjuju statističke metode za formuliranje i testiranje hipoteza o značajnosti pojedinih parametara u promatranom sustavu; zahtijevaju postojanje baza podataka koje sadrže prošle vrijednosti parametara i najkorisniji su pri studijama koje objašnjavaju prošle događaje;
- *ekonomski modeli* – modeli koji se primjenjuju pri analizama dinamičkih procesa na telekomunikacijskim tržištima; nakon kreiranja matematičkog opisa sustava takve modele je moguće riješiti analitički ili uz primjenu simulacija; modeli predstavljaju poopćenja dinamičkih procesa na tržištima;
- *tehno-ekonomski modeli* – modeli koji se primjenjuju pri vrednovanju implementacije pojedinih tehnoloških rješenja, pri izboru optimalnih tehnoloških rješenja te pri izboru najpogodnijeg trenutka za investiranje;
- *analize slučaja tj. poslovni modeli* – modeli koji se primjenjuju pri procjeni financijske izvedivosti pojedinih projekata; njihova prednost je točnost pri prikazivanju činjenica, a nedostatak je nedovoljna dinamičnost nakon načinjenih pretpostavki;

- *modeli koji opisuju dinamičnost sustava* – modeli koji se primjenjuju pri objašnjavanju kooperativnih ili nekooperativnih interakcija između različitih sudionika na telekomunikacijskim tržištima.

Druga faza, faza realizacije izravno je povezana s fazom planiranja. Ona obuhvaća izvršenje priprema te realizaciju izrađenog poslovnog plana.

Posljednja faza, faza kontrole obuhvaća izradu investicijskih programa i tehničke dokumentacije, financiranje te izgradnju planiranog dijela sustava. Budući da je ova faza povezana s fazom planiranja, moguće je korigirati odstupanja koja mogu nastati pri realizaciji kreiranih poslovnih planova.

Poslovno planiranje ima značajnu ulogu u poslovanju svakog suvremenog telekomunikacijskog sustava. Pri tome se telekomunikacijski sustavi i usluge razmatraju kroz:

- utvrđivanje postojećih potreba za telekomunikacijskim uslugama i predviđanje buduće potražnje,
- izradu poslovnih modela telekomunikacijskih sustava,
- pronalaženje alternativnih rješenja - definiranje mogućih opcija i određivanje najboljih,
- procjenu očekivanih troškova te provođenje analiza isplativosti.

Postupci poslovnog planiranja bitni su pri donošenju odluka o investiranju u telekomunikacijske sustave te pri daljnjem razvoju telekomunikacijske infrastrukture, kakva je i širokopojasna pristupna mrežna infrastruktura. To je u interesu različitih telekomunikacijskih operatora, korisnika i regulatora, ali i znanstvene zajednice, pa su postupci poslovnog planiranja danas u fokusu brojnih znanstvenih istraživanja.

3.2. Pregled istraživanja vezanih uz tehno-ekonomske aspekte razvoja i implementacije širokopojasnih tehnologija i usluga

Pojam '**tehno-ekonomski**' opisuje međusobnu povezanost dviju komponenata – tehničke i ekonomske komponente. U tehničkom području postupci tehno-ekonomskog modeliranja i analiziranja primjenjuju se najčešće za vrednovanje ekonomske isplativosti različitih složenih

tehničkih rješenja. Pri tome se koriste i kombiniraju različite metode iz područja tehničkih financijskih analiza (engl. *Technology Futures Analysis*, skr. TFA):

- *analize troškova i koristi;*
- *kvantitativno modeliranje;*
- *korelacijske analize;*
- *analize trenda;*
- *analize scenarija;*
- *analize realnih opcija;*
- *analize rizika* i dr. [18].

Od devedesetih godina prošlog stoljeća, metode tehno-ekonomskog modeliranja su se koristile za analizu i usporedbu izvedivosti različitih telekomunikacijskih mreža i usluga u nastajanju. Rane primjene su bile usmjerene na analiziranje i uspoređivanje strategija za nadogradnju fiksnih pristupnih mreža monopolističkih operatora kako bi podržavale širokopojasni prijenos podataka. S liberalizacijom tržišta uvedene su nove fiksne i mobilne tehnologije, a fokus je pomaknut u skladu s tim na nove tehnologije i alternativne tehnološke arhitekture [19].

Znanstveno-istraživački rad vezan uz primjenu tehno-ekonomskih postupaka započeo je krajem prošlog stoljeća. Većina istraživanja vezanih uz primjenu tehno-ekonomskih postupaka uglavnom je vezana uz područje energetike, biotehnologije, industrije i sl.

U područje telekomunikacija, pojam “tehno-ekonomski” uveden je pri provedbi europskog istraživačkog programa RACE (*Research into Advanced Communications for Europe*), koji je bio aktivan u periodu od sredine osamdesetih do sredine devedesetih godina prošlog stoljeća, a razmatrao je primjenu postupaka tehno-ekonomskog modeliranja i analiziranja različitih strategija i scenarija za uvođenje širokopojasnog pristupa Internetu.

Nakon ovog programa, uslijedili su brojni slični europski istraživački i razvojni projekti. Popis te kratki pregled projekata vezanih uz tehno-ekonomske aspekte razvoja i implementacije širokopojasnog pristupa Internetu naveden je u tablici 3.1..

Tablica 3.1. Pregled istraživačkih projekata vezanih uz tehno-ekonomske aspekte razvoja i implementacije širokopojsnih tehnologija i usluga

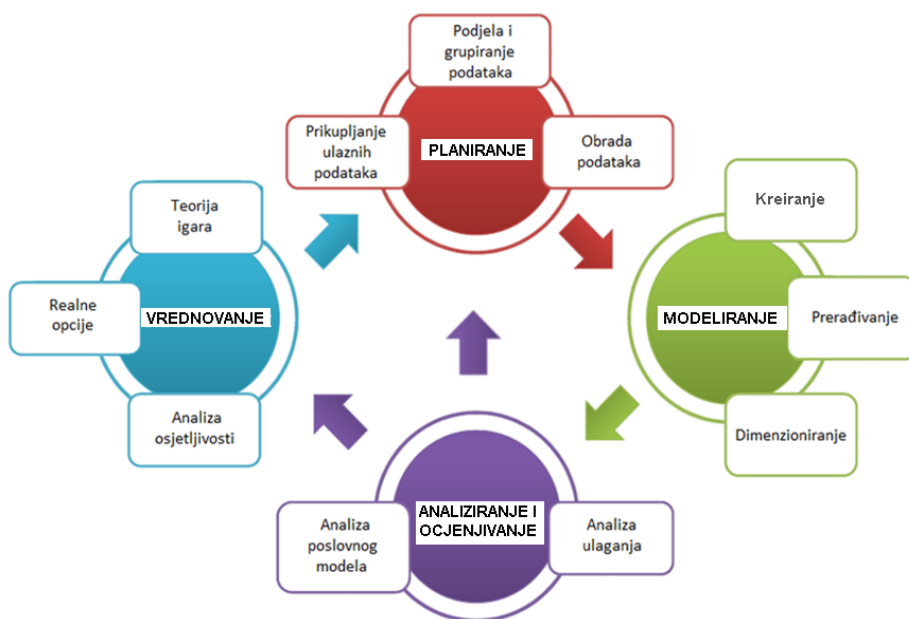
Naziv projekta	Postavljeni ciljevi i rezultati	Program	Period
TERA (<i>Techno-economic results from ACTS</i>)	Smjernice za uvođenje naprednih komunikacijskih mreža i usluga.	ACTS (FP4)	1994.- 1998.
OPTIMUM (<i>Optimised architectures for multimedia networks and services</i>)	Smjernice za uvođenje naprednih komunikacijskih mreža i multimedijских usluga u konkurentskom okruženju.	ACTS (FP4)	1994.- 1998.
TONIC (<i>Techno-economics of IP optimised networks and services</i>)	Tehno-ekonomske procjene novih komunikacijskih mreža i usluga. Teorijske i metodološke osnove za provedbu tehno-ekonomskih studija.	IST (FP5)	1998.- 2002.
FAN (<i>Future access networks</i>)	Skup osnovnih smjernica za migraciju prema IP mrežama zasnovanima na širokopojsnom prijenosu podataka.	EURESCOM (P1117)	2002.- 2003.
BROADWAN (<i>Broadband services for everyone over fixed wireless access networks</i>)	Metode za primjenu bežičnih mreža pri pružanju širokopojsnih usluga.	IST (FP6)	2003.- 2006.
BREAD (<i>Broadband in Europe for all: a multidisciplinary approach</i>)	Plan za uvođenje širokopojsnog pristupa prema konceptu širokopojsni pristup za sve' u Europi.	IST (FP6)	2004.- 2006.
ECOSYS (<i>Techno-economics of integrated communication systems and services</i>)	Tehno-ekonomske procjene integriranih komunikacijskih sustava i usluga. Daljnji razvoj teorijskog i metodološkog okvira za tehno-ekonomske analize telekomunikacijskih mreža.	EUREKA / CELTIC	2004.- 2007.
MUSE (<i>Multi Service Access Everywhere</i>)	Istraživanje i razvoj višeslužnih pristupnih mreža uz niske troškove implementacije.	IST (FP6)	2004.- 2008.

Provedena istraživanja, kao i ona koja su uslijedila nakon njih, definirala su osnovnu terminologiju, metodologiju i teorijske okvire koji se koriste pri vrednovanju tehničkih mogućnosti i ekonomskih aspekata različitih širokopojsnih pristupnih rješenja.

3.3. Postupci i metode za vrednovanje tehničkih mogućnosti i ekonomskih aspekata uvođenja širokopojasnih pristupnih rješenja

U telekomunikacijskom sektoru poslovni modeli, modeli poslovanja kojima se nastoje održati ili stvoriti očekivani prihodi, predstavljaju skup tehnoloških rješenja i usluga kojima se nastoje opisati mogući izvori prihoda. Dakle, svaki osmišljeni poslovni model nastoji povezati određeni tehnološki potencijal sa realiziranom ekonomskom vrijednošću [20]. Zbog međusobne ovisnosti tehnološke i ekonomske komponente u poslovnom modelu postupci koji se koriste za razmatranje takvih modela nazivaju se tehno-ekonomskim postupcima.

Prilikom razmatranja poslovnih modela za uvođenje širokopojasnih pristupnih mreža, primjenjuju se sljedeći tehno-ekonomski postupci: planiranje, modeliranje, analiziranje i ocjenjivanje te vrednovanje [21], kako je grafički prikazano na slici 3.1. Svaki od navedenih postupaka uključuje nekoliko dodatnih postupaka. Tako postupci tehno-ekonomskog planiranja uključuju prikupljanje ulaznih podataka, njihovu podjelu i grupiranje te obradu. Postupci tehno-ekonomskog modeliranja uključuju dimenzioniranje i kreiranje modela koji se zatim, ovisno o postojećim zahtjevima, može dodatno prerađivati. Postupci analiziranja modela obuhvaćaju analizu i ocjenu kreiranih poslovnih modela, a postupci vrednovanja metode za detaljnije definiranje i analiziranje kreiranih modela - analize osjetljivosti, realne opcije ili teoriju igara.




Slika 3.1. Tehno-ekonomski postupci [21]

Budući da na dostupnost širokopojasnog pristupa Internetu utječe iznimno puno čimbenika, kako bi se dobio što bolji uvid u postojeća stanja na određenim telekomunikacijskim tržištima, bitno je obuhvatiti što više dostupnih podataka o uvjetima i sudionicima na tim tržištima, potencijalnim krajnjim korisnicima te dostupnim širokopojasnim uslugama.

Stoga se kreiraju projekti kojima se definiraju određeni poslovni modeli. Kreirani projekti sastoje se od jednog ili više scenarija kojima se definiraju regulatorna, geo-demografska, tehnološka i tržišna strategija analiziranog projekta [22]. Pri kreiranju projekta kojim se definira određeni poslovni model primjenjuju se tehno-ekonomske metode za planiranje modela, kreiranje modela tj. modeliranje, analiziranje održivosti modela, ocjenjivanje isplativosti modela te vrednovanje modela.

U nastavku je dan opis postojećih metoda za vrednovanje tehničkih mogućnosti i ekonomskih aspekata uvođenja širokopojasnih pristupnih mreža zasnovan na sadržajima brojnih izvora koji opisuju navedenu tematiku. Način na koji su koraci pri tehno-ekonomskom modeliranju i kreiranju strukture određenih poslovnih modela međusobno povezani prikazani su na slici 3.2.



Slika 3.2. Tehno-ekonomski modeli

Prilikom kreiranja određenog tehno-ekonomskog modela koji razmatra uvođenje širokopojasnih pristupnih mreža potrebno je u obzir uzeti sve aspekte koji opisuju takav model - tržišne, tehničke i ekonomske aspekte. Navedeni aspekti obuhvaćaju pojedine okvire prikazane na slici 3.2.. Tako se tržišni aspekti razmatraju unutar okvira za modeliranje industrijskih arhitektura koji obuhvaća definiranje odnosa između različitih sudionika na telekomunikacijskim tržištima, kao i definiranje regulatorne i geo-demografske komponente razmatranog scenarija te unutar okvira za modeliranje tržišta i usluga koji obuhvaća planiranje, odnosno predviđanje potencijalnog broja korisnika i definiranje dostupnih usluga. Tehnički aspekti razmatraju se unutar okvira za modeliranje tehničkih arhitektura koji obuhvaća modeliranje pristupnih mreža. Ekonomski aspekti razmatraju se unutar okvira za modeliranje prihoda, okvira za modeliranje cijena usluga i okvira za modeliranje troškova.

Analiziranje i vrednovanje kreiranog tehno-ekonomskog modela provodi se unutar okvira za financijsko modeliranje, okvira za modeliranje isplativosti te dodatnih okvira koji uključuju metode analize osjetljivosti, realnih opcija i teorije igara koje se primjenjuju za detaljnije definiranje i analiziranje kreiranih modela. Ovakvi tehno-ekonomski modeli zasnivaju se na postojanju odgovarajućih baza podataka iz kojih se preuzimaju ulazne vrijednosti koje se koriste pri modeliranju.

Prilikom kreiranja modela potrebno je voditi računa o redoslijedu kreiranja pojedinih okvira i o njihovoj međuovisnosti. Poveznice između pojedinih okvira prikazane su slikom 3.2.. Tako je, na primjer, u cilju preciznije procjene ukupnih prihoda koje je moguće ostvariti određenim modelom, prije kreiranja okvira za modeliranje prihoda potrebno predvidjeti potencijalni broj korisnika pojedinih komunikacijskih usluga i njihove cijene, što se provodi unutar okvira za modeliranje tržišta i usluga. Pri modeliranju tržišta moguće je definirati međudnose sudionika na telekomunikacijskom tržištu uz pomoć teorije igara. Pri određivanju cijena usluga primjenjuju se i podaci o cijenama istovrsnih ili sličnih komunikacijskih usluga preuzetih iz određenih baza podataka koji omogućuju preciznije definiranje cijena.

Isto tako, u cilju preciznijeg definiranja troškova u modelu nužno je prije kreiranja okvira za modeliranje troškova definirati stanje na promatranom telekomunikacijskom tržištu i isplanirati pristupnu mrežu te iz baze podataka preuzeti relevantne podatke o cijenama pojedinih mrežnih komponenti koje se koriste u pristupnoj mreži. Zatim se, na temelju

dobivenih rezultata o prihodima i troškovima u modelu pristupa financijskom i ekonomskom vrednovanju modela te se procjenjuje njegova isplativost.

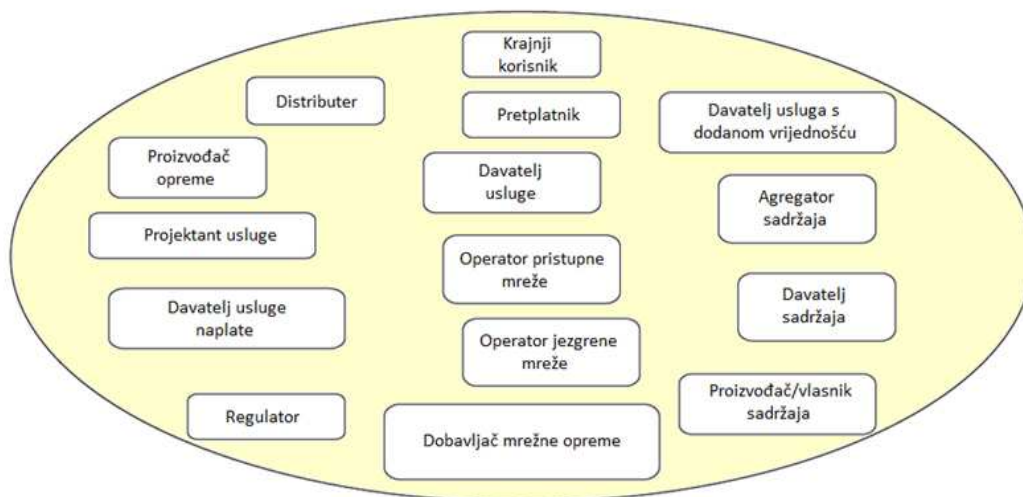
Kako bi se povećala preciznost dobivenih procjena isplativosti i donijela odluka o ulaganju potrebno je primijeniti dodatne metode. Takve metode obuhvaćaju provedbu analiza osjetljivosti, pri čemu se razmatra utjecaj promjena ulaznih vrijednosti na procijenjene vrijednosti te provedbu analiza realnih opcija, pri čemu se razmatraju različite mogućnosti razvoja poslovnog modela.

Pri tome različite pretpostavke pri kreiranju modela definiraju različite poslovne modele, kako je naznačeno na slici 3.2.. Tada se između većeg broja mogućih poslovnih modela može odabrati najbolji model.

Prikazane metode i postupci koji se u tehno-ekonomskim modelima primjenjuju za kreiranje pojedinih okvira detaljnije su opisani u nastavku. Pri tome su redom definirani postupci koji se primjenjuju pri planiranju modela, kreiranju modela, analiziranju održivosti i ocjenjivanju isplativosti modela te njegovom vrednovanju. Nadalje, razmotreni su i određeni problemi koje je potrebno razmotriti pri provedbi navedenih postupaka.

3.3.1. Planiranje modela

Prilikom planiranja scenarija kojim se definira određeni model uvođenja širokopojasnog pristupa Internetu potrebno je u obzir uzeti sve geografske i demografske specifičnosti promatranog područja na kojem se razmatra uvođenje širokopojasnog pristupa. Uslijed razlika koje uvjetuju različita obilježja promatranih područja, od velikog broja mogućih tehnoloških rješenja potrebno je odabrati najprikladnija rješenja za širokopojasni pristup. Zbog velikog broja sudionika na telekomunikacijskom tržištu, navedenih na slici 3.3., te njihovih kompleksnih međuodnosa, svaki od sudionika, ovisno o kapacitetima i sposobnostima, daje doprinos stvaranju ukupne vrijednosti za korisnike [22]. Tako u procesu pružanja usluga na telekomunikacijskim tržištima sudjeluje više operatora i pružatelja usluga (operator pristupne mreže, operator jezgrene mreže, davatelj usluga, davatelj sadržaja i dr.) te sam regulator koji u određenoj mjeri nadzire odnose između sudionika na tržištu i korisnika [6].




Slika 3.3. Različiti sudionici na telekomunikacijskim tržištima [23]

Stoga svaki scenarij koji opisuje model treba sadržavati sljedeće komponente [22]:

- geo-demografsku – koja opisuje zemljopisne te demografske karakteristike tržišta;
- tehnološku – koja opisuje tehnologije i sustave kojima se koriste davatelji usluga;
- regulatornu – koja određuje regulatorne okolnosti pružanja telekomunikacijskih usluga, opisuje kompetitivno stanje na tržištu te navodi podatke o udjelima operatora na tržištu;
- dostupnih usluga – koja daje prikaz dostupnih komunikacijskih usluga, predviđene vrijednosti njihove penetracije te opis dostupnih tarifnih paketa.

3.3.2. Kreiranje modela

Svaka od tehnologija i usluga koja se pojavljuje na telekomunikacijskim tržištima tijekom svog vijeka trajanja (tzv. životnog ciklusa) prolazi kroz sljedeće etape - uvođenje, rast, zasićenje te pad [24], kako je prikazano i na slici 3.4. [25]. U suvremenim kompetitivnim telekomunikacijskim tržištima, u kojima se neprestano pojavljuju nove tehnologije i usluge, poput različitih širokopojsnih pristupnih tehnologija i usluga, razumijevanje i mogućnost predviđanja svake od navedenih etapa postaju nužni preduvjeti za detaljnije analitičko razmatranje poslovnih modela [26].



Slika 3.4. Faze razvoja tehnologija i usluga na telekomunikacijskom tržištu [25]

Općenito, se postupci predviđanja u telekomunikacijama mogu definirati kao postupci predviđanja skupa tehno-ekonomskih pokazatelja nužnih za kreiranje poslovnih telekomunikacijskih modela [27]. Tako je, na primjer, telekomunikacijskim operatorima najčešće u interesu predvidjeti udio korisnika na tržištu, cijene usluga, prihode po korisniku, ukupne prihode te kapitalne i operativne troškove u kreiranom poslovnom modelu.

Prilikom kreiranja određenog poslovnog modela potrebno je u obzir uzeti sve komponente koje opisuju takav model - geo-demografsku, tehnološku, regulatornu te komponentu dostupnih usluga. Pri tome je potrebno primijeniti sve dostupne podatke o navedenim komponentama te pristupiti kreiranju tehno-ekonomskog modela uz primjenu odgovarajućih

metoda za modeliranje tržišta, modeliranje pristupnih mreža, modeliranje cijena usluga, modeliranje prihoda i modeliranje troškova.

Pojedini od koraka pri kreiranju tehnno-ekonomskog modela, odnosno pri modeliranju tržišta, pristupnih mreža, cijena usluga, prihoda i troškova, opisani su u nastavku rada te je za svaki od njih ukratko navedena postojeća problematika, detaljnije opisana u navedenim referencama.

3.3.2.1. Modeliranje tržišta

Prilikom uvođenja novih tehnologija i usluga na neko tržište njih ne usvajaju odmah svi potencijalni krajnji korisnici. Ovisno o trenutku u kojem se odlučuju na usvajanje novih tehnologija i usluga, korisnici se općenito dijele na inovatore i imitatore. Modeliranjem telekomunikacijskog tržišta predviđa se brzina usvajanja određene tehnologije ili usluge. Tako je, na primjer, u studiji [28] provedena analiza i usporedba brzina usvajanja Interneta u različitim državama svijeta.


Pri modeliranju tržišta primjenjuju se metode predviđanja bitnih tržišnih aspekata koji određuju potencijal poslovnog modela, odnosno dinamiku usvajanja tehnologija i usluga na promatranom tržištu. Pri tome se metode modeliranja tržišta dijele se na kvantitativne i kvalitativne metode. Dok se kvalitativne metode uglavnom oslanjaju na predviđanja stručnjaka, kvantitativne se zasnivaju na analitičkim i statističkim modelima određenih pojava za koje se pretpostavlja da će vrijediti unutar promatranog vremenskog razdoblja. Kvantitativne metode modeliranja dijele se na modele difuzije (usvajanje inovacija na društvenoj razini) i modele prihvaćanja (usvajanje inovacija na individualnoj razini) [29].

- Modeli difuzije (engl. *diffusion model*) modeliraju prodor novih tehnologija i usluga u društvo. Kod proračuna difuzije telekomunikacijskih tehnologija i usluga najčešće se koriste Rogersov model [30] te u praksi zastupljeniji, Bassov model [31]. Kako je prikazano na slici 3.5., u oba modela difuzija novih tehnologija i usluga ima oblik zvonolike krivulje normalne razdiobe [21]. Razlika između ta dva modela je uvjetovana brojem i udjelom pojedinih kategorija korisnika - inovatora i imitatora, koji ovise o trenutku usvajanja novih tehnologija ili usluga [3].

Bassov model opisuje kumulativni tržišni udio promatrane tehnologije ili usluge u vremenu. Pri tome je m najveći tržišni potencijal, p koeficijent inovacije i q koeficijent imitacije. Nadogradnja Bassovog modela je Norton-Bassov model koji sadrži podršku za modeliranje difuzije idućih generacija tehnologija i usluga [3]. Uz navedene modele koriste se i drugi, opisani detaljnije u [27].

$$\text{Bassov model: } S(t) = m \cdot (1 - e^{-(p+q)t}) / (1 + \frac{q}{p} e^{-(p+q)t}) \quad (3.1)$$

$$\text{Norton-Bassov model: } S(t) = (1 - e^{-(p+q)t}) / (1 + \frac{q}{p} e^{-(p+q)t}) \quad (3.2)$$



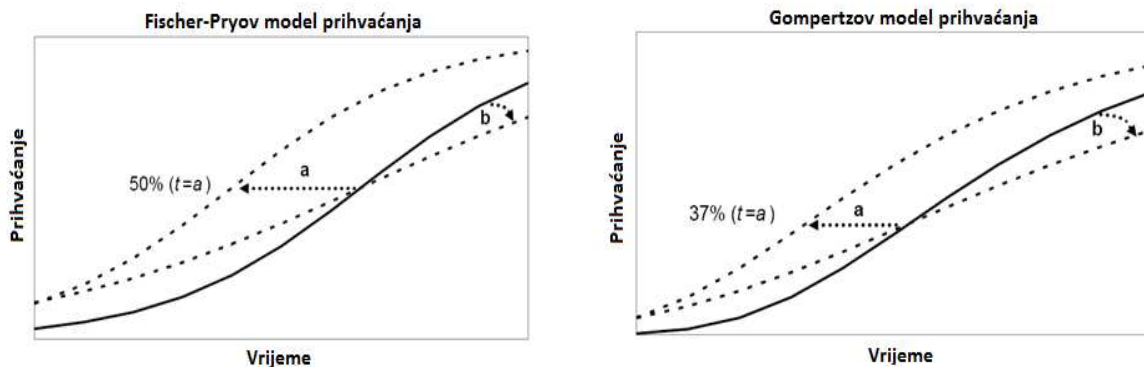
Slika 3.5. Rogersov model (lijevo) i Bassov model (desno) [21]

- Modeli prihvaćanja (engl. *adoption model*) modeliraju usvajanje novih tehnologija i usluga na individualnoj razini, pri čemu se usvajanje odnosi na individualni izbor krajnjih korisnika. Primjenom matematičkih krivulja, tzv. *S*-krivulja, oni predviđaju ukupan broj korisnika novih tehnologija ili usluga. Na krivuljama tih modela parametar a , položaj točke infleksije, određuje trenutak nakon kojeg se smanjuje porast broja novih korisnika. Parametar b , nagib krivulje, određuje brzinu porasta broja korisnika, a parametar m određuje potencijal tehnologije na tržištu. Osnovna razlika između ovih modela vezana je uz različit položaj točaka infleksije [32], kako je prikazano slikom 3.6.. U praktičnoj primjeni se pokazalo da Gompertzov model bolje odgovara realnim slučajevima.

Dakle, najčešći modeli prihvaćanja su Fisher-Pryov (tzv. logistički) te Gompertzov model.

$$\text{Fisher-Pryov model: } S(t) = m \cdot \frac{1}{1 + e^{-b(t-a)}} \quad (3.3)$$

$$\text{Gompertzov model: } S(t) = m \cdot e^{-e^{-b(t-a)}} \quad (3.4)$$



Slika 3.6. Fisher-Pryov model (lijevo) i Gompertzov model (desno) [32]

Prilikom predviđanja usvajanja, odnosno difuzije i prihvaćanja novih tehnologija i usluga najbitnije je odabrati prikladan model s odgovarajućim parametrima. Pri izboru parametara veliku pomoć pružaju numeričke metode kojima se iz dostupnih povijesnih podataka mogu pretpostaviti buduće vrijednosti vremenskih nizova. Tako je, na primjer, načinjeno i u analizi provedenoj u [28], gdje je na temelju dostupnih povijesnih podataka o broju korisnika Interneta u različitim državama u Svijetu predviđen broj korisnika u budućem razdoblju. Načinjeno predviđanje omogućilo je usporedbu porasta broja korisnika u dvjema skupinama država, pri čemu je uočeno da će u skupini siromašnih država, koje po broju korisnika trenutno zaostaju za bogatima, prosječan broj korisnika u definiranom periodu postupno sustići bogate države.

Osim uz primjenu navedenih tradicionalnih metoda predviđanja koje se temelje na dostupnim povijesnim podacima, usvajanje novih tehnologija i usluga moguće je predviđati i pomoću drugih metoda. Jedna od njih je i metoda neuronskih mreža (engl. *neural networks*), tzv. model crne kutije.


Primjena neuronskih mreža se pokazala uspješnom, kako pri predviđanju, tako i pri aproksimaciji funkcija, klasifikaciji i prepoznavanju uzoraka, u različitim područjima, poput medicine, ekonomije i tehnike. Fleksibilnija je u odnosu na navedene tradicionalne metode predviđanja budući da ne zahtijeva unaprijed poznate funkcijske ovisnosti među podacima, već se ovisnost određuje iz dostupnih podataka.

S obzirom da ulazi u neuronske mreže trebaju biti iskazani brojačno, ova metoda je primjenjiva pri analizi različitih statističkih podataka, kakvi su i podaci o pojedinim tehnologijama i uslugama [33] te o krajnjim korisnicima tehnologija i usluga [34].

3.3.2.2. Modeliranje pristupnih mreža


Na temelju predviđenog broja korisnika i strukture promatranih usluga u određenom poslovnom modelu, pristupa se procesu planiranja pristupnih mreža. Pri planiranju pristupnih mreža nužno je voditi računa o sljedećim aspektima [35]: pokrivenosti (engl. *coverage*), kapacitetu (engl. *capacity*), smetnjama (engl. *carrier to interference ratio*), kompleksnosti (engl. *complexity*) i cijeni (engl. *cost*). Nužni postupci pri modeliranju mreža obuhvaćaju planiranje pokrivenosti područja i procjenu potrebnih kapaciteta, dimenzioniranje mreže te njenu optimizaciju [36]. Kako bi planirana pristupna mreža bila funkcionalna i ekonomski isplativa, osnovni cilj pri planiranju mreže je optimizacija, odnosno postizanje odgovarajuće pokrivenosti područja te dovoljnih kapaciteta, uz što manji broj mrežnih komponenta [37].

Ovisno o planiranom pokrivanju područja mrežnom infrastrukturom, određuje se broj potrebnih mrežnih komponenta te lokacije na koje treba postaviti mrežnu opremu. Time se udovoljava predefiniranim zahtjevima na pokrivenost područja signalom, što čini prvi korak pri planiranju pristupnih mreža. Kod dimenzioniranja pristupnih mreža, odnosno kod proračuna potrebnog broja mrežnih komponenta, slijede se preporučene referentne mrežne arhitekture. Kako je prikazano slikom 3.7., u ovisnosti o prikupljenim podacima o terenu, o prostornom rasporedu te o gustoći korisnika, primjenjuju se određeni geometrijski modeli za prostorno dimenzioniranje mreža [37].




Slika 3.7. Primjena dostupnih podataka pri dimenzioniranju pristupnih mreža [38]

Geometrijski modeli za dimenzioniranje mreže zasnivaju se na modelima koji procjenjuju potrebna kvantitativna obilježja mrežnih arhitektura. Često se primjenjuju jednostavni modeli temeljeni na prostornom razmještaju odgovarajućih mrežnih elemenata u obliku pravilnih geometrijskih likova (npr. trokut, kvadrat ili šesterokut). Na slici 3.8. su prikazani primjeri arhitektura žičnih mreža ovisnih o uvjetima na terenu [32] i planiranje mrežnih struktura pri postavljanju žičnih vodova.



Slika 3.8. Struktura žičnih vodova postavljena duž ulice te dijagonalno [32]

Primjeri arhitektura bežičnih pristupnih mreža te najčešćih struktura pokrivanja područja bežičnim signalom prikazani su na slici 3.9..




Slika 3.9. Struktura pokrivanja područja bežičnim signalom

Arhitekture bežičnih mreža dobivaju se planiranjem potrebnog broja baznih stanica [3] i sektora [39] te planiranjem lokacija baznih stanica na promatranom području [40]. Pri tome se određuju polumjeri pokrivanja područja signalom r i međusobne udaljenosti baznih stanica d , kako je prikazano na slici 3.10.. Pravilnim lociranjem baznih stanica optimalno se pokriva promatrano područje u kojem se želi osigurati raspoloživost usluge [35] i dogovorena kvaliteta usluge.

Ovisno o geografskim obilježjima promatranih područja, pri planiranju topologija pristupnih bežičnih mreža koriste se odgovarajući radiofrekvencijski modeli za procjenu dometa

pokrivanja područja signalom, detaljnije opisani npr. u [41], [42], [43] i [44] za različita pristupna rješenja. Takvi radiofrekvencijski modeli temelje se na fizikalnim zakonima iz područja propagacije radiofrekvencijskih valova, detaljnije opisanim npr. u [45] i [3].




Slika 3.10. Planiranje lokacija baznih stanica pri pokrivanju područja bežičnim signalom [41]

Drugi korak planiranja žičnih i bežičnih pristupnih mreža vezan je uz zadovoljenje zahtjeva za kapacitetom. U ovom se koraku sumiraju definirani zahtjevi za kapacitetom po korisniku te se vrši planiranje ukupnih potrebnih infrastrukturnih resursa. Zatim se vrši usporedba planirane količine potrebne mrežne opreme procijenjene u prvom i drugom koraku te se, ukoliko je nužno, osiguravaju dodatne mrežne komponente kako bi bili zadovoljeni definirani zahtjevi za kapacitetom [46].

Nadalje, pri planiranju pristupnih mreža je, pored razmatranja zahtjeva na pokrivenost područja i na kapacitet, potrebno razmotriti i zahtjeve vezane uz karakteristike mrežne opreme te način izgradnje, međupovezivanja i održavanja pristupnih mreža [47]. Stoga je prilikom planiranja i izbora odgovarajućih rješenja potrebno načiniti određene kompromise.

3.3.2.3. Modeliranje cijena usluga

Cijene telekomunikacijskih usluga su podložne stalnom padu zbog smanjenih troškova proizvodnje opreme, povećanja stupnja liberalizacije tržišta, povećanja razine tržišnog natjecanja i slično [46]. Na osnovu povijesnih podataka o cijenama različitih usluga širokopojasnog pristupa Internetu, pokazuje se da pad cijena uobičajeno slijedi padajući eksponencijalni model [48], što je prikazano i slikom 3.11..



Slika 3.11. Cijene usluga širokopojasnog pristupa Internetu u razdoblju od 2003. do 2010. godine [48]

Procijenjena krivulja koja opisuje potražnju koristi se za predviđanje kretanja cijena usluga. Ukoliko postoji previđanje stope penetracije, cijena usluge može se izračunati prema sljedećem [49]:

$$p = (x / A)^{1/b} , \quad (3.5)$$

odnosno:

$$p = ((\ln x)^{1/\gamma} - \alpha) / \beta, \quad (3.6)$$


gdje je p cijena usluge, x broj pretplatnika te A , b , α , β i γ parametri modela. Navedeni parametri se mogu procijeniti pomoću metode najmanjih kvadrata.

3.3.2.4. Modeliranje prihoda

Prilikom razmatranja bilo kojeg projekta, potrebno je utvrditi sve potencijalne izvore prihoda. Prihodi koje je moguće ostvariti poslovnim modelom modeliraju se na temelju podataka o:

- predviđenom broju korisnika za svaku uslugu obuhvaćenu modelom - što je izravan rezultat postupka modeliranja tržišta, te
- prosječnim prihodima po korisniku (engl. *Average Revenue per User*, ARPU) - koji obuhvaćaju korisničke naknade određene razmatranjem bitnih tržišnih segmenata.

Brojne studije pokazuju kako je krivulja koja opisuje potražnju za širokopojasnim uslugama eksponencijalnog oblika, kako je prikazano i slikom 3.12.. Potražnja za širokopojasnim uslugama se povećava kako se cijene usluga smanjuju.



Slika 3.12. Porast broja pretplatnika mobilnih usluga i broja korisnika Interneta [50]

Broj korisnika i cijene usluga su gotovo obrnuto proporcionalne, pa krivulja koja opisuje potražnju za širokopojasnim uslugama ima sljedeći oblik [49]:

$$x = A \cdot p^b, \quad (3.7)$$

gdje je x broj pretplatnika, p cijena usluge te A i b parametri modela. Povijesni podaci i podaci dobiveni istraživanjem tržišta mogu se procijeniti primjenom navedenog eksponencijalnog modela te linearne regresije:

$$\ln x = \ln A + b \cdot \ln p, \quad (3.8)$$

Za procjenu je moguće primijeniti i model sljedećeg oblika [49]:

$$x = e^{(\alpha + \beta \cdot p)^\gamma}, \quad (3.9)$$

odnosno:

$$\ln x = (\alpha + \beta \cdot p)^\gamma, \quad (3.10)$$

pri čemu se parametri α , β i γ mogu procijeniti pomoću metode najmanjih kvadrata.

Prihode je moguće odrediti procjenom na temelju iznosa prosječnih prihoda po korisniku. Iznos prosječnih prihoda po korisniku pomnožen s brojem pretplatnika daje okvirnu

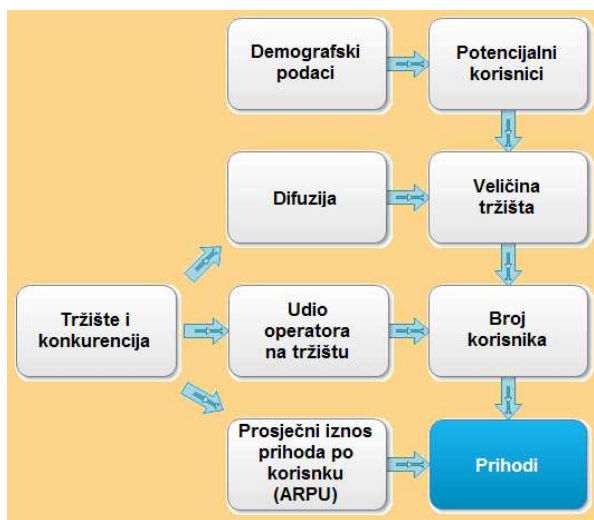
vrijednost ukupnog iznosa prihoda operatora, kako je naznačeno i u radu [51], u kojem se razmatraju različiti modeli naplate usluga.

Iznos prosječnih prihoda po korisniku je stabilniji od cijene pojedinih usluga te se može modelirati na sljedeći način:

$$p_s(t) = p_s(0) \cdot K_s^t = p_s(0) \cdot e^{-c_s \cdot t} \quad (3.11)$$

gdje je $p_s(0)$ iznos prosječnih prihoda po korisniku u početnom trenutku promatranja, dok su K_s i c_s parametri smanjenja iznosa prosječnih prihoda.

Nakon provedbe planiranja projekta (definiranja konkurencije i udjela operatora na tržištu), modeliranja tržišta (definiranja veličine tržišta na temelju demografskih podataka o stanovništvu te predviđanja broja potencijalnih korisnika i difuzije), modeliranja cijena usluga te određivanja prosječnih prihoda po korisniku, moguće je definirati okvir za modeliranje prihoda [49], prikazan na slici 3.13..



Slika 3.13. Okvir za modeliranje prihoda [49]

3.3.2.5. Modeliranje troškova

Postupkom modeliranja troškova određuju se svi značajni troškovi u poslovnom modelu, te se obavlja predviđanje vrijednosti troškova u poslovnom modelu unutar određenog razdoblja promatranja. Prema načinu nastanka, osnovna je podjela troškova na operativne (engl. *operational expenditures* - *OPEX*) te kapitalne (engl. *capital expenditures* – *CAPEX*).

Operativni troškovi su redoviti tekući troškovi određenih resursa koji se koriste tijekom određenog vremenskog razdoblja, a uključuju poslovanje i održavanje, energiju i gorivo, najam i zakup, ugovorne usluge i slično [32]. Dakle, operativni troškovi obuhvaćaju sve troškove koji nisu povezani s izravnim izdacima za opremu, ali su nužni za rad. Često se periodički ponavljaju u određenim vremenskim intervalima. Ovi troškovi dijele se na:

- troškove vezane uz pokretanje mreže (troškovi procesa planiranja mreže, troškovi postavljanja i puštanja u rad opreme),
- troškove vezane uz rad mreže (infrastrukturni troškovi najma opreme, kapaciteta ili prostora, troškovi održavanja mreže, troškovi popravaka kvarova, troškovi uključanja i isključenja usluga, troškovi obračuna usluga te troškovi oglašavanja) i
- ostale troškove (administrativni troškovi koji nisu vezani uz pružanje usluga - najam i održavanje uredskog prostora, troškovi financijskog i kadrovskeg odjela).

Kapitalni troškovi uključuju sve dugoročne izdatke za nabavku ili nadogradnju telekomunikacijske opreme. Dakle, kapitalni troškovi uključuju trošak za stjecanje resursa koji će se koristiti više od godinu dana, poput mrežne opreme, zemljišta i objekata.

Procjene kapitalnih troškova potrebno je pažljivo razmotriti. Obično se cijena mrežne opreme kroz vrijeme smanjuje zbog smanjenja vremena i unaprjeđenja procesa proizvodnje, ali i povećane ponude opreme na tržištu, što je opisano u [52].

Navedeno je opisano i formulom [49]:

$$f(t) = f(0) / [n(0) + (1-n(0) \cdot 9^{-2t/\Delta t})^{\log_2 K}], \quad (3.12)$$

pri čemu je $f(t)$ cijena opreme, $n(t)$ relativni udio proizvedenih komponenti, Δt vremenski period unutar kojeg se penetracija poveća s 10% na 90%, a K relativno smanjenje cijene opreme uslijed povećane proizvodnje.

Budući da oprema postupno gubi svoju vrijednost, kapitalni izdaci se trebaju pretvoriti u godišnji trošak uz primjenu amortizacije, metode koja raspoređuje izdatke kroz korisni vijek trajanja opreme [53].

Promjenjivi (varijabilni) dio troškova uključuje izdatke za poslovanje i održavanje. Nepromjenjivi (fiksni) dio troškova uključuje kamatu, amortizaciju i amortizaciju za kapitalne izdatke. Iako ne postoji način da se nepromjenjivi troškovi izbjegnu u kratkom roku, stalno produženje očekivanog vijeka korisnosti projekta može rezultirati određenim ekonomskim koristima. Produženje rasporeda amortizacije smanjuje neke nepromjenjive troškove na način da ih se raspoređuje na duže vremensko razdoblje.

Postupkom modeliranja troškova određuju se svi značajni troškovi u poslovnom modelu, te se obavlja predviđanje vrijednosti troškova unutar razdoblja promatranja poslovnog modela. Okvir prema kojem se vrši modeliranje troškova [49], prikazan je na slici 3.14..



Slika 3.14. Okvir za modeliranje troškova [49]

Pri modeliranju pristupnih mreža troškovi u modelima se nastoje minimizirati što je više moguće kako bi kreirani projekti bili što isplativiji. Pri tome se, ovisno o promatranim slučajevima, koriste različite metode. Brojni primjeri iz literature opisuju različite metode koje se primjenjuju kako bi ukupni troškovi planiranih modela bili što manji.


Tako se, na primjer, razmatra smanjenje kapitalnih i operativnih troškova bežičnih pristupnih mreža kroz podjelu dostupnih mrežnih resursa (infrastrukture i spektra) između više operatora te kroz implementiranje femto ćelija [54], te primjena većeg broja različitih standarda za radijski prijenos podataka te različitih klasa baznih stanica koje se kombiniraju u heterogene bežične mreže kako bi se osigurali potrebni prijenosni kapaciteti [55].

3.3.3. Analiziranje održivosti i ocjenjivanje isplativosti modela

Osnovna struktura analize poslovnih modela sadrži prihodovne i troškovne dijelove te evaluacijski dio analize, u kojem se određenim kvantitativnim metodama vrednuje poslovni model. Metode koje se koriste pri evaluaciji modela detaljnije su opisane u nastavku.

3.3.3.1. Analiza financijske održivosti i isplativosti modela

Novčani tijek (engl. *Cash Flow*, CF) predstavlja jednostavan način prikaza te analizu prihoda i rashoda. Kako je prikazano na slici 3.15., analiza novčanog tijeka prikazuje neto prihod, definiran kao tijek prihoda minus tijek rashoda, na periodičnoj osnovi. Projekcije novčanog tijeka mogu se primijeniti za izradu izvješća o prihodima i rashodima u kojima su prikazani ukupni prihodi i rashodi podijeljeni po glavnim kategorijama za određeno vremensko razdoblje [22], [51].




Slika 3.15. Prikaz novčanog tijeka

Osnovne statične metode koje pružaju informacije o financijskoj isplativosti i održivosti investicijskih projekata su:

- metode ocjene financijske isplativosti modela
- metode ocjene financijske održivosti modela.

a) Model prema kojem se vrši **analiza financijske isplativosti projekta**, kako je prikazano na slici 3.16., prikazuje ovisnost isplativosti projekta o vrijednostima ukupnih očekivanih prihoda, kapitalnih i operativnih troškova [17].



Slika 3.16. Okvir za modeliranje financijske isplativosti [21]

Metoda određivanja isplativosti prikazana je sljedećim formulama [21]:

$$\text{Novčani tijek prije odbitaka (EBITDA)} = \text{Prihodi} - \text{Operativni troškovi}$$

$$\text{Operativna dobit (EBIT)} = \text{EBITDA} - \text{Deprecijacija} - \text{Amortizacija}$$

$$\text{Dobit prije oporezivanja} = \text{EBIT} - \text{Kamate}$$

b) U **analizi financijske održivosti infrastrukturnog projekta**, isplativost treba predviđati za razdoblje koje odgovara njegovom korisnom ekonomskom vijeku trajanja. Za infrastrukturne projekte vremenski okvir dijeli se na srednjoročni i dugoročni.



Slika 3.17. Okvir za modeliranje financijske održivosti [21]

Uspoređivati se mogu samo istovremeni novčani iznosi. Ako dva iznosa nisu istovremena, potrebno je znati diskontnu stopu (engl. *discount rate*, r), kako bi se odredila sadašnja vrijednost budućeg iznosa.

Sve buduće troškove i koristi koji nastaju kroz niz godina treba diskontirati prema početnoj godini primjenom jedinstvene socijalne diskontne stope. Mnoge zemlje imaju vlastitu socijalnu diskontnu stopu koju su utvrdile za projekte javnog sektora, koja se kreće između 3% i 10% [53]. Kako je prikazano na slici 3.17., socijalna diskontna stopa utječe na održivost projekta.

Izbor diskontne stope važan je jer ima snažan utjecaj na smjer projekta, što se može zaključiti na temelju diskontirane vrijednosti tijeka novca (engl. *Discounted Cash Flow*, DCF) [32], koja se određuje prema sljedećem izrazu [3]:

$$DCF_t = \frac{CF_t}{(1+r)^t} \quad (3.13)$$

pri čemu t označava broj godina iz perioda promatranja, a r odgovarajuću diskontnu stopu.

Niska diskontna stopa prikladna je za investicijske programe jer se kapital ne čini skupim, za izravnu kupnju imovine i za projekte s dugoročnim koristima.

Nakon određivanja vrijednosti tijeka novca, moguće je odrediti vrijeme povrata ulaganja (engl. *Payback Period*, PP), odnosno broj godina n u kojima se vraća početno ulaganje, prema sljedećem izrazu [32]:

$$PP = n : \sum_{t=0}^{n-1} CF_t < 0, \sum_{t=0}^n CF_t \geq 0 \quad (3.14)$$

Ukoliko se u obzir uzmu diskontirane vrijednosti tijeka novca koristi se sljedeći izraz [32]:

$$DPP = n : \sum_{t=0}^{n-1} \frac{CF_t}{(1+r)^t} < 0, \sum_{t=0}^n \frac{CF_t}{(1+r)^t} \geq 0 \quad (3.15)$$

pri čemu se određuje diskontirano vrijeme povrata ulaganja (engl. *Discounted Payback Period*, DPP).

3.3.3.2. Ocjena ekonomske isplativosti modela

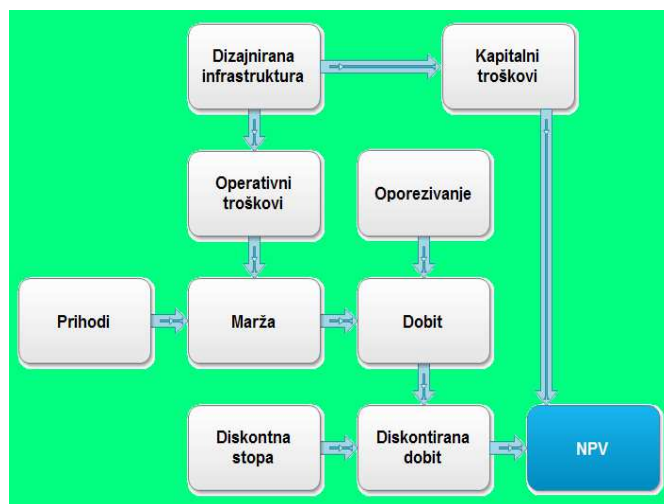
Osnovne metode za ocjenjivanje ekonomske isplativosti investicijskog modela, koje pružaju informacije o isplativosti, poželjnosti i održivosti modela su [3]:

- vrijeme povrata (engl. *Payback Period*, PP),
- neto sadašnje vrijednosti (engl. *Net Present Value*, NPV) i
- unutarnje stope povrata (engl. *Internal Rate of Return*, IRR).

Neto sadašnja vrijednost projekta predstavlja sadašnju vrijednost (engl. *Present Value*, PV) primitaka umanjenu za sadašnju vrijednost izdataka. Neto sadašnju vrijednost moguće je odrediti diskontiranjem vremenskog tijeka primitaka i izdataka tijekom vijeka korisnosti projekta prema tekućoj vrijednosti [3], prema navedenom izrazu. Vremensko diskontiranje koristi se za prebacivanje budućih troškova i koristi u njihovu sadašnju vrijednost, čime troškovi postaju međusobno usporedivi.

$$NPV = CF_0 + PV \quad (3.16) \quad \Leftrightarrow \quad NPV = CF_0 + \sum_{t=1}^T \frac{CF_t}{(1+r)^t} \quad (3.17)$$

Okvir za modeliranje neto sadašnjih vrijednosti prikazan je na slici 3.18.. Da bi se projekt smatrao ekonomski isplativim sadašnja vrijednost koristi treba biti veća od troškova, tj. izračunata neto sadašnja vrijednost projekta treba biti pozitivna (odnosno, najmanje jednaka nuli). Isto tako, neto sadašnja vrijednost projekta mora biti viša od neto sadašnjih vrijednosti drugih, međusobno isključivih opcija projekta.



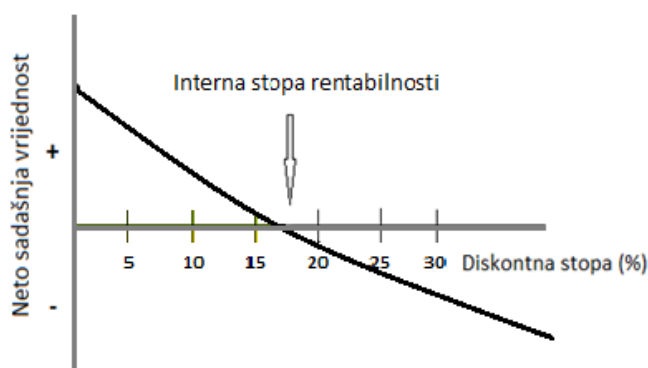
Slika 3.18. Okvir za modeliranje neto sadašnjih vrijednosti [49]

Unutarnja stopa povrata predstavlja diskontnu stopu pri kojoj je neto sadašnja vrijednost jednaka nuli [3], kako je prikazano slikom 3.19. i donjim izrazom.

$$0 = CF_0 + \sum_{t=1}^T \frac{CF_t}{(1+IRR)^t} \quad (3.18)$$

IRR vrijednost je korisna za usporedbu isplativosti promatranog projekta s alternativnim projektima.

Budući da se uz određivanje točne vrijednosti diskontne stope uvijek vežu nesigurnosti, njenu vrijednost je potrebno uključiti kao varijablu rizika za projekt i koristiti ju kao varijablu prilikom ispitivanja scenarija isplativosti projekta.



Slika 3.19. Odnos između neto sadašnje vrijednosti, diskontne stope i interne stope rentabilnosti


Stoga nije toliko bitno točno pretpostaviti vrijednost diskontne stope, već je bitnije odrediti mogući raspon vrijednosti koje diskontna stopa može poprimiti [53].

3.3.4. Vrednovanje modela

Analiza osnovnih ekonomskih pokazatelja ne analizira utjecaj i međuovisnosti ulaznih parametara na konačnu isplativost projekta. Time se zanemaruju promjene koje mogu nastupiti u budućnosti unutar promatranog vremenskog razdoblja, a koje utječu na vrijednosti ulaznih parametara. Također, zanemaruju se i međusobni utjecaji strategija ostalih sudionika u poslovnom modelu jednih na druge.

Kako bi se povećala pouzdanost analize modela, razvijene su dodatne metode za modeliranje rizika. Pri tome se rizicima smatraju sve okolnosti koje mogu promijeniti predviđenu vrijednost diskontiranih novčanih tijekova i tako pogoršati isplativost određenog projekta. Rizici su obično povezani s nesigurnošću, a uključuju mogućnost pojave nepoželjnih događaja. Kako neizvjesnost i rizik rastu, donošenje odluka postaje sve teže. Stoga je prilikom analize rizika potrebno promotriti dva bitna aspekta: gdje se nalazi rizik te koliko je rizik značajan. Nakon identificiranja rizika, model može pomoći u postupku kvantifikacije iznosa rizika. Kvantificiranje rizika označava postupak određivanja vjerojatnosti da će se rizik

dogoditi te utvrđivanje njegovog iznosa, kako bi se donijela odluka isplati li se riskirati. Pronalaženje vjerojatnosti postizanja određenih rezultata je često sam cilj analize modela. Analiza rizika uzima model te promatra kakav učinak imaju promjene određenih vrijednosti u modelu na konačnu vrijednost. Analiza rizika može pomoći pri donošenju odluka uz brzu provjeru svih mogućih scenarija, određivanje varijabli koje najviše utječu na predviđene vrijednosti rezultata i prikazivanje nesigurnosti u modelu, što vodi do boljeg interpretiranja rizika. Za svaku neizvjesnu varijablu u modelu postoji opcija definiranja mogućeg raspona vrijednosti primjenom neke od raspodjela vjerojatnosti prikazanih slikom 3.20..



Slika 3.20. Moguće raspodjele vjerojatnosti neizvjesnih varijabli

Osnovne metode za procjenu rizika i vrednovanje poslovnih modela su usporedba scenarija, analize osjetljivosti, *Monte Carlo* simulacije, teorija igara te realne opcije, detaljnije opisane u nastavku.

3.3.4.1. Usporedba scenarija

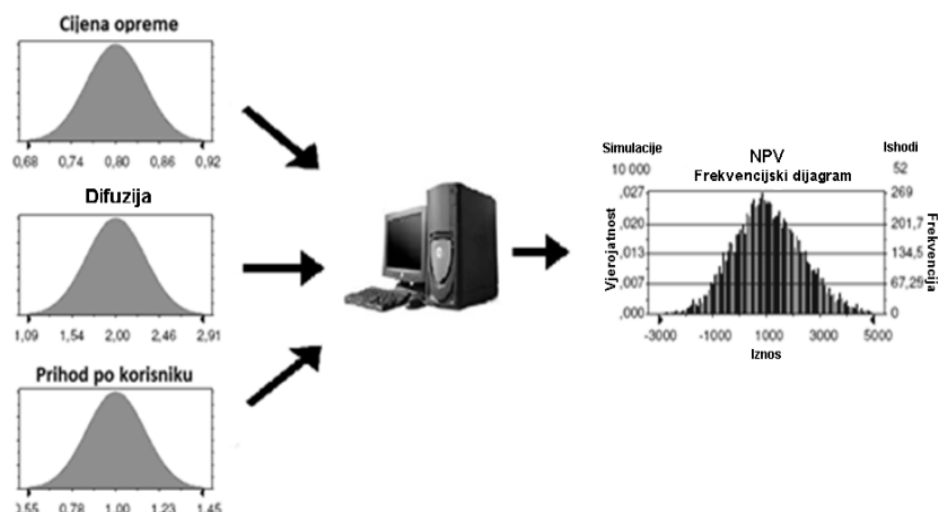
Najjednostavnija metoda modeliranja rizika definira oblikovanje skupa ulaznih podataka, tj. scenarija, koji rezultira određenim procjenama isplativosti definiranog poslovnog modela. Dobiveni rezultati zasnivaju se na procijenjenim vrijednostima ulaznih parametara.

Prilikom planiranja scenarija kojim se definira određeni poslovni model potrebno je u obzir uzeti sve specifičnosti modela. Kreiranjem scenarija koji točno opisuje poslovni model povećava se relevantnost dobivenih rezultata nakon izvršene tehno-ekonomske analize modela, kako je načinjeno i u analizama provedenima u [56] i [57].

Budući da analiza scenarija uvijek rezultira jednom procjenom, ona ne omogućuje istraživanje cijelog skupa eventualnih ishoda. Dakle, takva procjena ukazuje na ono što je moguće, ali ne ukazuje na ono što je vjerojatno. U svrhu generiranja niza vrijednosti za definirane pretpostavke, primjenjuju se druge metode opisane u nastavku.

3.3.4.2. Analize osjetljivosti

Analiza osjetljivosti koristi se pri vrednovanju projekta za dobivanje preciznijih podataka o mogućim načinima smanjenja nesigurnosti. Promatra se svaka varijabla nesigurnosti pojedinačno, dok vrijednosti svih ostalih varijabli ostaju konstantne.



Slika 3.21. Analiza osjetljivosti neto sadašnje vrijednosti na promjene ulaznih faktora

Analiza osjetljivosti koristi se kada se želi utvrditi u kojoj mjeri odgovarajuće pretpostavke utječu na izračunatu predviđenu vrijednost rezultata, kako je prikazano na slici 3.21.. Provodi se i prilikom ulaganja u infrastrukturu kako bi se lakše odredile varijable koje imaju najveći utjecaj na konačnu isplativost projekta, kako je načinjeno i u analizi provedenoj u [58]. Varijable koje je moguće promatrati prilikom provođenja analize osjetljivosti su, npr. promjene korisničkih tarifa, promjene cijena korisničke opreme i sl. [3].

Analiza osjetljivosti pomaže pri vrednovanju projekta te služi za dobivanje preciznijih podataka o mogućim načinima smanjenja nesigurnosti. Promatra svaku varijablu nesigurnosti pojedinačno, dok sve ostale varijable drži konstantnima. Najčešće se promatra:

- utjecaj promjena određenih varijabli na iznos neto sadašnje vrijednosti,
- mogući raspon vrijednosti varijabli,
- vjerojatnost da će se vrijednosti varijabli kretati unutar raspona mogućih vrijednosti,
- stupanj do kojeg je moguće kontrolirati raspon promjene vrijednosti varijabli.

Grafički prikaz osjetljivosti pruža mogućnost brzog i jednostavnog određivanja utjecaja svake od pretpostavki na konačan rezultat.

3.3.4.3. Monte Carlo simulacije

Monte Carlo metoda je deterministička simulacijska metoda. Zasniva se na algoritmima koji pomoću slučajnih brojeva i velikog broja izračuna i ponavljanja predviđaju ponašanje modeliranih sustava.

Metode *Monte Carlo* simulacija smanjuju nedostatke metode analize osjetljivosti, uključujući u postupak modeliranja rizika istovremeno više ulaznih parametara. Vrijednosti varijable za koju se simulacija provodi, odabiru se iz funkcije raspodjele vjerojatnosti koja odgovara stvarnoj pojavi zadane varijable, kako je načinjeno i u analizi provedenoj u [59].

3.3.4.4. Teorija igara

Deregulacijom telekomunikacijskih tržišta, odnosno uklanjanjem regulatornih ograničenja i uvođenjem slobodnog tržišnog natjecanja, primjena teorije igara dobiva sve značajniju ulogu u istraživanju i donošenju optimalnih poslovnih odluka. U području telekomunikacija primjena teorije igara omogućuje modeliranje rizika i analizu različitih poslovnih modela iz aspekta potencijalnih interakcija različitih sudionika u promatranim telekomunikacijskim sustavima (npr. ostali operatori, korisnici, regulator). Takve interakcije mogu utjecati na pouzdanost predviđanja tržišnih parametara i troškova u modelu.

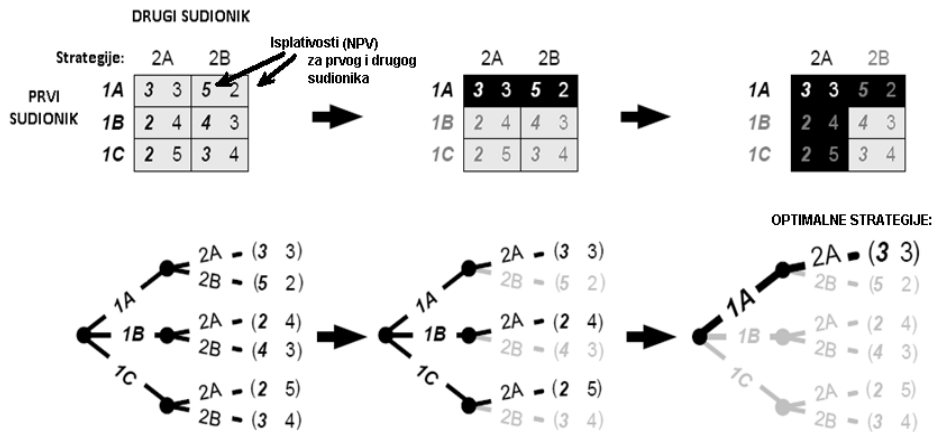
Pri provođenju procesa odlučivanja o optimalnom poslovnom modelu nužno je u razmatranje uzeti interakcije između različitih sudionika na telekomunikacijskim tržištima na gotovo svim razinama. Kada se u obzir uzmu interakcije različitih sudionika na telekomunikacijskim

tržištima, kao i činjenica da odluke svakog pojedinog sudionika utječu na odluke svih ostalih sudionika na promatranom tržišnom segmentu, svaki modelirani okvir odlučivanja trebao bi uključivati koncept pronalaženja ravnoteže u promatranom sustavu. Ravnoteža u sustavu je nužna budući da u takvom okruženju svaki sudionik nastoji optimizirati svoju odluku na temelju odabranog kriterija, a to utječe na odluke svih ostalih sudionika u sustavu. Ukoliko se odluke svih sudionika donose istovremeno, koncept koji se najčešće koristi pri traženju ravnoteže u promatranom okruženju je koncept *Nash*-ove ravnoteže.

U teoriji igara, *Nash*-ova ravnoteža (engl. *Nash equilibrium*) predstavlja koncept rješenja igre koja uključuje dva ili više sudionika, u kojoj se pretpostavlja da svaki sudionik zna poteze koji zadovoljavaju optimalnu strategiju drugog sudionika, a niti jedan sudionik nema koristi od jednosmjerne promjene svoje strategije. Koncept *Nash*-ove ravnoteže koristi se pri analiziranju rezultata strateških interakcija dvaju ili više sudionika koji donose odluke u konkurentskom okruženju. Dakle, riječ je o metodi koja se koristi pri predviđanju odluka nekoliko sudionika koji istovremeno donose odluke, u slučaju kada odluke svakog pojedinog sudionika ovise o planovima svih ostalih sudionika.

Skupina sudionika se općenito nalazi u *Nash*-ovoj ravnoteži ukoliko svaki od sudionika donosi za sebe najbolju odluku koju može, vodeći pri tome računa o ostalim sudionicima uključenima u igru. Analogno tome, u konkurentskom okruženju u kojem se nalaze dva sudionika, sudionici su u poziciji *Nash*-ove ravnoteže ukoliko prvi sudionik donosi najbolju odluku za sebe, uzimajući u obzir ciljeve drugog sudionika, dok drugi sudionik također donosi najbolju odluku koju može, uzimajući u obzir ciljeve prvog sudionika. Na slici 3.22. je prikazan primjer utvrđivanja *Nash*-ove ravnoteže, odnosno izbora optimalnih strategija dvaju sudionika na telekomunikacijskom tržištu, pri čemu prvi sudionik ima ukupno tri, a drugi dvije različite strategije. Cilj utvrđivanja ravnoteže vezan je uz određivanje optimalnih strategija koje omogućuju ostvarenje najvećih mogućih ukupnih koristi za pojedine sudionike [32], npr. iznose isplata (engl. *payoff*), poput onih navedenih u tablicama na slici.

Brojni izvori opisuju primjenu teorije igara u različitim telekomunikacijskim sustavima pri opisivanju različitih problema. U području telekomunikacija teoriju igara je moguće primijeniti pri rješavanju problema kao što su kontrola toka i zagušenja, mrežno usmjeravanje, dodjela adresa, dodjela resursa te očuvanje kvalitete usluga i sigurnosti u telekomunikacijskim mrežama [60], ali i mnogih drugih.

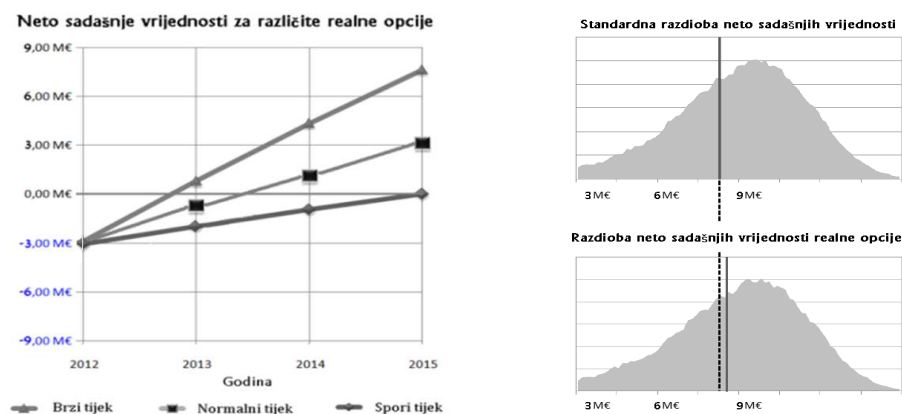


Slika 3.22. Izbor optimalnih strategija dvaju sudionika na telekomunikacijskom tržištu [32]

S obzirom da koncept traženja ravnoteže u telekomunikacijskim sustavima ovisi o promatranom okruženju, u području teorije igara se uz opisani koncept *Nash*-ove ravnoteže primjenjuju i drugi koncepti traženja optimalnih odluka. Pri modeliranju te rješavanju igara u pojedinim mrežnim okruženjima uz primjenu teorije igara naglasak je moguće staviti na nekooperativne igre i koncepte ravnoteže koji se, uz *Nash*-ovu ravnotežu, primjenjuju u takvim okruženjima (*Stackelberg*-ova ravnoteža, *Wardrop*-ova ravnoteža i dr.) [60].

3.3.4.5. Realne opcije

Realne opcije uvode fleksibilnosti u statične parametre poslovnih modela. One omogućuju predviđanje i analiziranje mogućnosti poduzimanja odluka koje mijenjaju početni poslovni model u trenutku nakon pokretanja projekta.



Slika 3.23. Utjecaj realnih opcija na iznose neto sadašnjih vrijednosti

Realne opcije	Postupak	Opis
Investiranje Rast	Povećanje opsega <i>(eng. Scale up)</i>	<i>Postupno investiranje u kasnijim trenutcima kada se tržište proširi.</i>
	Promjena <i>(eng. Switch up)</i>	<i>Zamjene usluga, opreme ili procesa uvjetovane promjenama zahtjeva ili cijena.</i>
	Proširenje područja <i>(eng. Scope up)</i>	<i>Investiranje na drugom području, čim ono postane isplativo.</i>
Odgoda Učenje	Učenje/započinjanje <i>(eng. Study/start)</i>	<i>Odgoda investiranja dok se ne prikupi više informacija ili dok se ne steknu potrebna nova znanja.</i>
Dezinvestiranje Smanjenje	Smanjivanje opsega <i>(eng. Scale down)</i>	<i>Smanjenje ili zaustavljanje investiranja ukoliko nove informacije smanje očekivanu isplativost.</i>
	Promjena <i>(eng. Switch down)</i>	<i>Prebacivanje na isplativija ili fleksibilnija sredstva nakon dobivanja novih informacija.</i>
	Smanjivanje područja <i>(eng. Scope down)</i>	<i>Ograničavanje opsega poslovanja u pojedinom području ukoliko nema mogućnosti za daljnji razvoj.</i>

Slika 3.24. Okvirom definirane realne opcije [32]

Često je odgovarajućim studijama potrebno dokazati da je odabrani projekt najbolja, odnosno najisplativija opcija. Izvješće o isplativosti sadrži podatke o ekonomskom okruženju, predviđenoj potražnji, dostupnoj tehnologiji, planu i rasponu projekta te vremenu i fazama njegove provedbe. Na slici 3.24. su prikazane okvirom definirane realne opcije, tzv. "the 7S framework" [32], a na slici 3.23. način na koji izbor određene opcije može utjecati na konačnu isplativost kreiranog projekta [61].

3.4. Pregled primjene tehno-ekonomskih metoda i modela

Kroz brojna provedena istraživanja razmotrene su različite vrste širokopojasnih pristupnih rješenja i načinjene tehno-ekonomske analize pomoću kojih se vrednovala isplativost implementacije pristupnih rješenja u različitim scenarijima. Pri tome su primijenjene različite vrste tehno-ekonomskih metoda i modela.

Stoga je potrebno dati pregled primijenjenih tehno-ekonomskih postupaka i metoda te kreiranih modela koji doprinose teoriji i praksi tehno-ekonomskog modeliranja u pojedinim područjima. Razmotrena problematika, primijenjene metode i predloženi modeli opisani su u nastavku.

3.4.1. Pregled i usporedba primijenjenih metoda za vrednovanje tehničkih mogućnosti i ekonomskih aspekata uvođenja širokopoljnih pristupnih rješenja

S obzirom na primijenjene metode za tehno-ekonomsku procjenu određenih širokopoljnih pristupnih rješenja, provedene se analize, navedene u nastavku, razlikuju prema njihovoj složenosti. Primijenjene metode navedene su redom od osnovnih prema složenijima.

a) Usporedba scenarija:

Među najosnovnijim provedenim metodama, primijenjenima u [59], [62], [63], [57], [64], [65], [66], [67], [68], [56], [69] i [58], nalazi se metoda usporedbe scenarija. Pri tome se uspoređuje nekoliko scenarija koji se razlikuju najčešće s obzirom na vrste razmatranih uvjeta uključenih u analize.

b) Analize osjetljivosti:

U cilju smanjivanja rizika do kojih dolazi pri procjenama isplativosti određenih rješenja, kao naprednija metoda koriste se analize osjetljivosti, primijenjene u [59], [62], [65], [66], [67], [68], i [58]. Pri takvim analizama se za pojedine ključne parametre za koje se utvrdi kako najviše utječu na isplativost razmatranog rješenja unose različite ulazne vrijednosti iz skupova mogućih vrijednosti. Na temelju dobivenih rezultata tada je lakše donijeti odluku o izboru najboljih rješenja u promatranim scenarijima.

c) Monte Carlo simulacije:

S obzirom na činjenicu da primjena *Monte Carlo* simulacija smanjuje nedostatke analiza osjetljivosti uključujući istovremeno u postupak modeliranja rizika više ulaznih parametara, preporučuje se njena primjena [59].

U tablici 3.2. navedene su analizirane tehnologije kategorizirane prema vrstama pristupnih rješenja, podijeljenima na žična i bežična te fiksna i mobilna rješenja. Za pojedine tehno-ekonomske analize različitih pristupnih rješenja naznačene su i metode primijenjene pri procjeni tehničkih mogućnosti i ekonomskih aspekata njihove implementacije.

Tablica 3.2. Usporedni pregled provedenih tehno-ekonomskih analiza

Vrsta pristupa:	Analizirane tehnologije:	Primijenjene metode:	Izvor:
ŽIČNI FIKSNI	PLC	Usporedba scenarija / Analize osjetljivosti / <i>Monte Carlo</i> simulacije	[59]
ŽIČNI I BEŽIČNI FIKSNI	PLC i WiMAX	Usporedba scenarija / Analize osjetljivosti	[62]
	FTTH i WiMAX	Usporedba scenarija	[63]
	EPON i WiMAX	Usporedba scenarija	[57]
BEŽIČNI FIKSNI	Fiksni WiMAX	Usporedba scenarija	[64]
		Usporedba scenarija / Analize osjetljivosti	[65]
		Usporedba scenarija / Analize osjetljivosti	[66]
BEŽIČNI MOBILNI	Mobilni WiMAX	Usporedba scenarija / Analize osjetljivosti	[67]
	3G	Usporedba scenarija / Analize osjetljivosti	[68]
		Usporedba scenarija	[56]
	4G	Usporedba scenarija	[69]
		Usporedba scenarija / Analize osjetljivosti	[58]

d) Realne opcije:

Nadalje, kako bi se detaljnije analizirao utjecaj izbora određenih opcija na konačnu isplativost kreiranog projekta primjenjuje se metoda realnih opcija. Brojni izvori opisuju primjenu metode realnih opcija pri vrednovanju određenih telekomunikacijskih rješenja. Tako je metode realnih opcija moguće primijeniti pri vrednovanju modela u kojima se analiziraju različita konkurentska te nekonkurentska okruženja. Na primjer, realne opcije mogu se primijeniti kako bi se prikazao utjecaj fleksibilnosti ulaznih postavki na procjenu isplativosti implementiranja mreže koja se postavlja u okruženju u kojem je konkurencija zanemariva [70]. Pri tome primjena tradicionalnog pristupa modeliranju bez primjene metode realnih opcija navodi na postavljanje krivih zaključaka. Nadalje, uz primjenu kombinacije metoda realnih opcija s drugim naprednim metodama moguće je analizirati alternativna informacijsko-komunikacijska tehnološka rješenja u konkurentskom okruženju [71].

Metode realnih opcija primjenjuju se i pri vrednovanju modela u kojima se analiziraju i uspoređuju različita rješenja, aspekti i uvjeti. Tako je, na primjer, moguće s gledišta operatora, dobavljača mrežne opreme te korisnika analizirati problem prijelaza na mrežu sljedeće generacije, pri čemu se metoda realnih opcija koristi pri donošenju odluka o ulaganju, a rezultati provedene analize trebaju ukazati na ključne čimbenike u opisanom investicijskom procesu [72]. Nadalje, metode realnih opcija moguće je primijeniti i pri razmatranju

nesigurnosti procjene isplativosti implementacije pristupnih rješenja uvjetovanih različitim regulatornim, tehničkim i tržišnim uvjetima na promatranom području, a rezultati provedenih analiza tada ukazuju na najbitnije uvjete koji na promatranom području utječu na nesigurnost procjene [73]. Moguće je razmotriti i primjenu različitih strategija implementacije određenih pristupnih rješenja s obzirom na razlike u područjima pokrivanja te primjeni dostupnih tehnologija [74]. Tada je usporedbu efikasnosti pojedinih strategija moguće je načiniti na temelju usporedbe cijena usluga te stupnja razvijenosti pristupne infrastrukture.

e) Teorija igara:

Teoriju igara moguće je primijeniti u području telekomunikacija pri određivanju cijena telekomunikacijskih usluga ili isplativosti uvođenja određenih telekomunikacijskih rješenja. Tako je teoriju igara moguće je primijeniti pri razmatranju interesa telekomunikacijskih tvrtki koje međusobno konkuriraju cijenama te kvalitetom ponuđenih telekomunikacijskih usluga unutar promatranog tržišnog okruženja [75]. Pri tome je potrebno razmotriti primjenu strategija koje omogućuju optimalan izbor cijene i kvalitete telekomunikacijskih usluga, ali i maksimizaciju ostvarenog profita tvrtki. Nadalje, *Nash*-ovu ravnotežu u sustavu je moguće tražiti i pri analizi isplativosti uvođenja pristupnih rješenja postojećeg operatora te novog operatora na tržištu [76] ili pri formiranju cijena usluga internetskih operatora u konkurentskom okruženju [77].

Uz opisano, teoriju igara moguće je primijeniti i pri analizama interakcija više sudionika na različitim razinama unutar promatranog telekomunikacijskog sustava. Tako je, na primjer, pri analizi alternativnih informacijsko-komunikacijskih tehnoloških rješenja za pristup Internetu u konkurentskom okruženju uz razmatranje postojeće hijerarhije u telekomunikacijskom sustavu moguće primijeniti teoriju igara za donošenje optimalnih poslovnih odluka [71]. Uz razmatranje postojeće hijerarhije u sustavu moguće je analizirati i učinak potpora na razvoj telekomunikacijskih mreža, pri čemu se teorija igara može primijeniti pri utvrđivanju najboljih strategija za operatore u konkurentskom okruženju [78], [79].

Nadalje, primjenom teorije igara pri odlučivanju moguće je zahvatiti široki spektar različitih sudionika unutar promatranog telekomunikacijskog sustava. Tako, na primjer, krajnjim korisnicima koji se nalaze u heterogenim mrežnim okruženjima u kojima koegzistira veći broj mreža zasnovan na različitim pristupnim tehnologijama koje uvode različiti operatori,

primjena teorije igara omogućuje lakši izbor mreže koja jamči usluge s definiranom razinom kvalitete [80].

U tablici 3.3. navedene su primjene metode realnih opcija i teorije igara pri tehnno-ekonomskom modeliranju. Na temelju prikaza načinjenog u tablici 3.3. vidljivo je kako je metode realnih opcija i teorije igara moguće primjenjivati pri usporedbi i analizi različitih rješenja i određivanju najboljih rješenja.

Tablica 3.3. Pregled primjene metoda realnih opcija i teorije igara

Metode:	Primjena:	Izvor:
Realne opcije	- Određivanje isplativosti rješenja u nekonkurentskom okruženju.	[70]
	- Usporedba isplativosti alternativnih rješenja u konkurentskom okruženju.	[71]
	- Usporedna analiza ključnih čimbenika koji utječu na isplativost rješenja.	[72]
	- Analiza ključnih uvjeta koji utječu na nesigurnost pri procjeni isplativosti rješenja.	[73]
	- Usporedba efikasnosti različitih strategija.	[74]
Teorija igara	- Određivanje optimalnih rješenja.	[75] [77] [80]
	- Usporedba isplativosti alternativnih rješenja.	[76]
	- Analiza optimalnih poslovnih odluka koje maksimiziraju isplativost rješenja.	[71]
	- Utvrđivanje najboljih strategija u konkurentskom okruženju.	[78] [79]

Na temelju opisa postojećih tehnno-ekonomskih metoda te njihove primjene i usporedbe, moguće je zaključiti kako se pri postupcima vrednovanja tehničkih i ekonomskih aspekata uvođenja širokopoljanskih pristupnih rješenja navedene tehnno-ekonomske metode mogu primjenjivati na različite načine. Isto tako, vidljivo je kako je u cilju dobivanja preciznijih rezultata tehnno-ekonomskih analiza metode potrebno kombinirati.

3.4.2. Izdvojena problematika vezana uz postupke vrednovanja tehničkih mogućnosti i ekonomskih aspekata uvođenja širokopoljanskih pristupnih rješenja i pregled postojećih rješenja

Prilikom provedbe tehnno-ekonomskih analiza implementacije širokopoljanskih pristupnih rješenja, s obzirom na brojne aspekte koje je nužno razmotriti pri takvim analizama, bitno je

definirati postojeću problematiku. Stoga je u nastavku dan pregled izdvojene problematike vezane uz primjenu tehno-ekonomskih postupaka i metoda te kreiranih modela koji doprinose teoriji i praksi tehno-ekonomskog modeliranja u pojedinim područjima. Razmotrena problematika i predloženi modeli navedeni su u nastavku.

➤ ***Primjena tehno-ekonomskih modela pri kreiranju isplativih poslovnih modela.***

Motivi istraživanja: izrađivanje tehno-ekonomskog modela koji se koristi za određivanje isplativosti i održivosti poslovnih modela vezanih uz implementaciju širokopojasnih pristupnih mreža, kao i potrebnih iznosa subvencija kako bi neisplativi modeli postali isplativi.

Doprinosi modela [81]: definiranje smjernica za procjenu izvedivosti projekata pristupnih mreža i određivanje dostatnih razina subvencija za takve projekte. Rezultati provedenih tehno-ekonomskih analiza su ukazali na činjenicu da neuspjeh projekata izgradnje pristupnih gradskih mreža nije samo rezultat primjene neodgovarajućih poslovnih modela, već da su pojedini projekti bez subvencije jednostavno neisplativi.

Ograničenja modela [81]: načinjene pretpostavke o vremenu izgradnje mreže su fiksne, pa je nužan daljnji razvoj tehno-ekonomskog modela koji, osim neto sadašnjih vrijednosti kao ekonomske metrike, treba koristiti i metodu realnih opcija.

➤ ***Upravljanje nesigurnostima procijenjenih rezultata tehno-ekonomskih analiza.***

Motivi istraživanja: upravljanje nesigurnostima pri donošenju odluka o investiranju u širokopojasne pristupne mreže.

Doprinosi modela [82]: upravljanje nesigurnošću pri investiranju u širokopojasne pristupne mreže kroz pronalazak kritičnih parametara ulaganja; analiziranje teorijskog modela za ulaganje te vrednovanje investicija uz primjenu metode realnih opcija u načinjenom studijskom primjeru ulaganja u pristupne mreže.

Ograničenja modela [82]: pri provedbi analiza zanemarena je konkurencija među operatorima te su primijenjeni samo osnovni modeli za predviđanje ukupnog broja korisnika.

➤ ***Primjena tehno-ekonomskih modela za analizu konkurentskih okruženja.***

Motivi istraživanja: vrednovanje kreiranih tehno-ekonomskih modela u konkurentskim okruženjima uz primjenu teorije igara.

Doprinosi modela [83]: načinjene usporedbe različitih scenarija uvođenja nove korisničke opreme za mobilni pristup Internetu nakon provedene kvalitativne analize dostupnih podataka


te provedena analiza uvođenja takve opreme za mobilne operatore u konkurentskom okruženju uz primjenu teorije igara.

Ograničenja modela [83]: primjena kvalitativnih analiza podataka ne omogućuje dovoljno preciznu usporedbu scenarija.

➤ ***Primjena tehno-ekonomskih modela pri analizi različitih industrijskih arhitektura.***

Motivi istraživanja: definiranje te analiziranje alternativnih industrijskih arhitektura određenih različitim odnosima sudionika unutar telekomunikacijske industrije.

Doprinosi modela [19]: izgrađeni okvir za tehno-ekonomsko modeliranje eksplicitno definiranih industrijskih arhitektura. Predloženi okvir proširuje i dograđuje postojeći okvir koji je definiran u [84], a koji se dugo koristio kao glavna referenca pri kreiranju brojnih tehno-ekonomskih modela, kako je prikazano na slici 3.25.. Novi okvir daje nekoliko metodoloških doprinosa teoriji i praksi tehno-ekonomskog modeliranja, a osnovni su vezani upravo uz definiranje načina na koje se tehno-ekonomske metode modeliranja mogu koristiti pri analizi i usporedbi izvedivosti različitih industrijskih arhitektura.



Slika 3.25. Model dopunjen okvirom koji definira industrijske arhitekture [19]

Ograničenja modela [19]: izostavljanje metoda za predviđanje načina budućeg razvoja tehnologija i industrijskih arhitektura pri planiranju tehno-ekonomskih scenarija koje je potrebno analizirati.

Na posljertku, potrebno je načiniti kritički osvrt na razmotrenu problematiku vezanu uz provedbu tehno-ekonomskih analiza i ograničenja primijenjenih modela te navesti smjernice koje je potrebno slijediti pri tehno-ekonomskom modeliranju.

Budući da se komunikacijske tehnologije ubrzano razvijaju, to uzrokuje nastanak različitih opcija te neizvjesnosti pri kreiranju investicijskih projekata. Poteškoće pri predviđanju broja pretplatnika i drugih kritičnih parametara koji utječu na vrijednost projekta čini donošenje investicijskih odluka o investiranju teškim zadatkom. Osnovni korak za upravljanje nesigurnošću pri donošenju investicijskih odluka vezan je uz utvrđivanje i procjene rizika i budućih opcija. Stoga je pri donošenju odluka nužno pri tehno-ekonomskom modeliranju uz metode usporedbe scenarija i *Monte Carlo* simulacija primjenjivati i realne opcije. Isto tako, nužno je uz osnovne modele koji se koriste za predviđanje ukupnog broja korisnika novih tehnologija i usluga primijeniti i alternativne empirijske modele. Tada se dobiveni rezultati procjena mogu usporediti i poboljšati proces donošenja odluka.

Nadalje, kako bi se metode tehno-ekonomskog modeliranja mogle koristiti u analizi i usporedbi izvedivosti alternativnih industrijskih arhitektura, nužno je provesti tehno-ekonomsko vrednovanje određenih industrijskih scenarija. Isto tako, s obzirom na činjenicu da neuspjeh infrastrukturnih investicijskih projekata nije uvijek rezultat primjene neodgovarajućih poslovnih modela, već da su pojedini projekti bez subvencije jednostavno neisplativi, za takve je modele potrebno kvantitativno odrediti potrebne iznose subvencija.

3.5. Analize isplativosti širokopojasnih pristupnih rješenja za ruralna područja

Provedba tehno-ekonomskih analiza koje razmatraju aspekte implementacije širokopojasnih pristupnih rješenja pretpostavlja rješavanje određene problematike vezane uz različite tehno-ekonomske aspekte. Isto vrijedi i za provedbu analiza koje razmatraju tehničke i ekonomske aspekte implementacije širokopojasnih pristupnih rješenja u ruralnim područjima. Stoga je nužno definirati osnovne postupke i metode koje je potrebno primijeniti pri rješavanju postojećih problema koji se javljaju pri provedbi tehno-ekonomskih analiza vezanih uz uvođenje širokopojasnog pristupa Internetu u ruralnim područjima.

Nadalje, kako bi se definirala najisplativija pristupna rješenja u pojedinim tipovima ruralnih područja potrebno je prikazati rezultate provedenih tehno-ekonomskih analiza koje razmatraju isplativosti različitih širokopojasnih pristupnih rješenja opisanih u drugom poglavlju rada. Navedena rješenja potrebno je definirati ovisno o promatranim tipovima ruralnih područja.

Isto tako, potrebno je kreirati tehno-ekonomske modele koji točno opisuju postojeće ruralne scenarije budući da to povećava relevantnost rezultata tehno-ekonomskih analiza. Tada je rezultate provedenih analiza koje vrednuju tehničke i ekonomske aspekte uvođenja širokopojasnih pristupnih rješenja moguće koristiti kao putokaz pri analizama svih ostalih ruralnih scenarija sličnog tipa.

3.5.1. Opis problematike vezane uz provedbu tehno-ekonomskih analiza uvođenja širokopojasnog pristupa Internetu u ruralna područja i prikaz predloženih rješenja

Pri analiziranju tehno-ekonomskih aspekata uvođenja širokopojasnog pristupa Internetu i internetskih usluga u ruralna područja potrebno je razmotriti postojeću problematiku. U nastavku su navedeni osnovni problemi vezani uz provedbu tehno-ekonomskih analiza te su definirani postupci primijenjeni za njihovo rješavanje [9], [85], [86], [87], [88], [89] i [90]. U razmatrane aspekte ubrajaju se različiti tržišni, tehnički i ekonomski aspekti. Pojedini postupci primijenjeni za rješavanje navedene problematike objašnjeni su na konkretnim primjerima.

A) Tržišni aspekti:

- *Definiranje industrijskih arhitektura:*

S obzirom na veliki broj različitih sudionika na telekomunikacijskim tržištima, prije provedbe samih analiza potrebno je definirati ciljne skupine za koje se utvrđuje opravdanost uvođenja širokopojasnog pristupa Internetu [9]. Budući da bez potrebne pristupne infrastrukture ne postoji mogućnost primjene širokopojasnih usluga, opravdanost uvođenja širokopojasnog pristupa Internetu potrebno je analizirati prvenstveno s gledišta mrežnih operatora [85], [86], [87] i [88]. Takve je analize potrebno provoditi s ciljem procjenjivanja ekonomske isplativosti implementacije razmatranih tehničkih rješenja, odnosno širokopojasnih pristupnih mreža. Provedba tehno-ekonomskih analiza uvođenja širokopojasnog pristupa Internetu za mrežne operatore u odabranim ruralnim područjima trebala bi uključivati razmatranje većeg broja različitih pristupnih tehnologija [89]. Analiza različitih tehnologija omogućuje bolji uvid u dostupna rješenja te olakšava izbor najprikladnijih rješenja u pojedinim tipovima ruralnih područja.

- *Definiranje scenarija:*

Prije provedbe tehno-ekonomskih analiza potrebno je odabrati prikladne scenarije u kojima je potrebno provesti analize budući da izbor najprikladnijih širokopojsnih pristupnih rješenja uvelike ovisi o odabranom scenariju [85], [86], [87], [88] i [89]. Nakon izbora scenarija potrebno je prikupiti i analizirati podatke o razmatranom području (npr. geografske i demografske podatke). Primjer definiranja scenarija opisan je u tablici 3.4.

Tablica 3.4. Definiranje promatranog područja i izbor scenarija

Promatrano područje	Površina [km ²]		Demografski podaci
	Ukupno područje	Ciljno područje	Ukupan broj kućanstava
Odabrani ruralni scenarij	40	32	1.903

- *Modeliranje tržišta:*

Pri modeliranju tržišta potrebno je predvidjeti dinamiku usvajanja tehnologija i usluga u promatranom scenariju. Pri tome je potrebno u obzir uzeti i podatke o udjelu postojećih operatora na tržištu koji nude istovrsne usluge [88]. Uz pretpostavku o podjeli tržišta između više operatora, u odabranom scenariju prikazanom u tablici 3.4. definirano ciljno područje pokrivenosti uslugom manje je u odnosu na ukupno područje.

Nadalje, s obzirom na udio operatora na tržištu, pri procjeni ciljnog broja kućanstava koja trebaju biti pokrivena uslugom određen je njihov udio u ukupnom broju kućanstava, kako je prikazano u tablici 3.5.. Za procjenu broja kućanstava u godinama unutar definiranog perioda promatranja potrebno je primijeniti neki od modela koji predviđaju usvajanje novih usluga (npr. logistički model - primijenjen pri određivanju podataka prikazanih u tablici 3.5.). Pri tome je pri predviđanju moguće koristiti dostupne povijesne podatke o brzini usvajanja istovrsnih ili sličnih usluga, kako je detaljnije opisano u poglavlju 3.3.2.1..

Tablica 3.5. Definiranje razmatranog tržišnog segmenta

Ciljani tržišni segment i zahtjevi za kapacitetom u odabranom scenariju											
Period promatranja (godine)	G1	G2	G3	G4	G5	G6	G7	G8	G9	G10	
Ukupni ciljni broj kućanstava	27	42	67	90	123	155	180	199	211	217	
Ukupni zahtjevi za kapacitetom	Dolazni smjer [Mbit/s]	0,58	0,90	1,43	1,92	2,62	3,31	3,84	4,25	4,50	4,63
	Odlazni smjer [Mbit/s]	0,29	0,45	0,71	0,96	1,31	1,65	1,92	2,12	2,25	2,31

B) Tehnički aspekti:

- *Planiranje pristupnih mreža:*

Ovisno o vrstama analiziranih tehnologija za širokopojasni pristup, pri provedbi tehničkog dijela tehnološko-ekonomskih analiza potrebno je posebno razmotriti problem izbora prikladnih modela za planiranje pristupnih mreža. Ovisno o tome radi li se o žičnom ili bežičnom pristupu te o razmatranoj vrsti tehnologija (fiksne / mobilne), metode modeliranja pristupnih mreža potrebno je prilagoditi i samom scenariju, odnosno tipu ruralnog područja [87]. Pri planiranju pristupnih mreža posebnu je pažnju potrebno posvetiti određivanju količine potrebnih mrežnih komponenata kako bi bili zadovoljeni ukupni zahtjevi za kapacitetom [88]. Tako je načinjeno i u primjeru iz tablice 3.5. u kojem je, uz primjenu softverskog alata [91], određen potreban broj WiMAX baznih stanica za različite podscenarije označene oznakama SA, SB, SC i SF (ovisno o dostupnim širinama frekvencijskih kanala, tehnikama kodiranja i načinu prijenosa podataka) unutar scenarija definiranog u tablici 3.6..

Pri tome je ukupne zahtjeve za kapacitetom potrebno je proračunati na temelju podataka o prosječnim zahtjevima za kapacitetom po korisniku te o ukupnom broju korisnika (kućanstava) u pojedinom vremenskom razdoblju, kako je prikazano u tablici 3.5..

Tablica 3.6. Planiranje pristupne mreže

Broj potrebnih baznih stanica za implementiranje odabrane WiMAX pristupne mreže u definiranom scenariju												
Mobilni WiMAX										Fiksni WiMAX		
Širina frekvencijskog kanala, multipleksiranje:	Višestruki prijenos:	Broj antena (odašiljanje/prijem):	Tehnike kodiranja:	Ozn. scenarija:	Frekv. pojas: 2.3 GHz	Ozn. scenarija:	Frekv. pojas: 2.5 GHz	Ozn. scenarija:	Frekv. pojas: 3.5 GHz	Širina frekvencijskog kanala, multipleksiranje:	Ozn. scenarija:	Frekv. pojas: 3.5 GHz
5 MHz, TDD	-	1 x 1	-	SA-01	3	SB-01	3	SC-01	3	3.5 MHz, TDD or FDD	SF-01	7
	MIMO	1 x 2	-	SA-02	2	SB-02	2	SC-02	3		SF-02	5
			Matrix A (STC)	SA-03	2	SB-03	2	SC-03	3		SF-03	5
		2 x 2	-	SA-04	3	SB-04	3	SC-04	3		SF-04	7
			Matrix A (STC)	SA-05	2	SB-05	2	SC-05	2		SF-05	4
	10 MHz, TDD	-	1 x 1	-	SA-06	4	SB-06	4	SC-06		5	7 MHz, TDD or FDD
MIMO		1 x 2	-	SA-07	3	SB-07	3	SC-07	3	SF-07	7	
			Matrix A (STC)	SA-08	3	SB-08	3	SC-08	3	SF-08	7	
		2 x 2	-	SA-09	4	SB-09	4	SC-09	5	SF-09	9	
			Matrix A (STC)	SA-10	2	SB-10	2	SC-10	3	SF-10	5	

- *Planiranje nadogradnje postojeće mrežne infrastrukture:*

Kroz tehnički dio tehno-ekonomskih analiza potrebno je definirati modele i provesti planiranje pristupnih mreža za različite tehnologije. Budući da je prilikom razmatranja različitih pristupnih rješenja potrebno razmotriti i činjenicu da ne zahtijevaju sva rješenja pri implementaciji jednake postupke, pristupna rješenja je nužno razlikovati prema potrebnim ulaganjima u pristupnu infrastrukturu, ovisno o tome postoji li mogućnost za nadogradnju postojeće infrastrukture ili je potrebna u potpunosti nova infrastruktura. Uvijek kada je moguće, potrebno je nadograditi postojeći dio pristupne infrastrukture budući da su tada potrebna manja ulaganja [87].

C) Ekonomski aspekti:

- *Definiranje troškova:*

Pri provedbi ekonomskog dijela tehno-ekonomskih analiza, u svrhu procjene izdataka pri uvođenju širokopojasnog pristupa, potrebno je definirati razlike između izdataka ovisno o njihovom opsegu te vremenu u kojem nastaju [85], [86], [87], [88] i [89]. Izdatke je potrebno podijeliti na jednokratne i godišnje te kapitalne i operativne.

- *Određivanje cijene mrežne opreme:*

Pri provedbi tehno-ekonomskih analiza često se javlja problem određivanja cijene mrežne opreme koja se koristi u analizama budući da podaci mogu biti preuzeti iz različitih izvora. Stoga je potrebno na temelju svih prikupljenih dostupnih podataka odrediti prosječne iznose cijena opreme i njih uključiti u izračune, a nakon toga u analizu uključiti i raspon mogućih vrijednosti cijena uz primjenu neke od raspodjela vjerojatnosti navedenih u poglavlju 3.3.4. [85], [86], [87], [88] i [89].

- *Definiranje perioda ulaganja:*

Prije provedbe ekonomskog dijela tehno-ekonomskih analiza nužno je definirati i odgovarajuće vremenske periode unutar kojih se vrše kapitalna ulaganja budući da je ulaganja u mrežnu infrastrukturu moguće vršiti jednokratno ili unutar dužeg vremenskog perioda, što utječe na konačne periode isplativosti projekata [85], [86], [87], [88] i [89]. Ukoliko se pristupne mreže grade korak po korak moguće je ograničiti rizike i povećati operativnu fleksibilnost projekta jer je na temelju naknadnog odgovora dobivenog s tržišta moguće odlučiti hoće li i u kojem roku mreža biti nadograđena.

- *Prikazivanje rezultata:*

Pri ocjenjivanju ekonomske isplativosti ulaganja u širokopojasnu infrastrukturu, rezultate je moguće prezentirati na različite načine. Navedeni problem potrebno je riješiti izborom najprikladnijih načina za prezentiranje rezultata. Najčešće su to mjere isplativosti koje obuhvaćaju period povrata ulaganja, neto sadašnje vrijednosti ulaganja i unutarnje stope povrata ulaganja [85], [86], [87], [88] i [89].

- *Analiziranje osjetljivosti:*

Kako bi problem nesigurnosti procjena dobivenih rezultata analiza bio što manji, potrebno je provesti analize osjetljivosti. One mogu uključivati pretpostavke o različitim pokrivenostima područja uslugom, zahtijevanim kapacitetima i primijenjenim diskontnim stopama u razmatranim scenarijima te dr. [85], [86], [87], [88] i [89].

Tablica 3.7. Procjena isplativosti različitih pristupnih rješenja

Neto sadašnje vrijednosti [€] u scenariju u kojem se razmatra uvođenje mobilne WiMAX pristupne infrastrukture												
Usporedba:	Oznaka scenarija:	Broj baznih stanica:	G1	G2	G3	G4	G5	G6	G7	G8	G9	G10
Širina frekvencijskog kanala	SC-05	2	-52,333	-102,025	-108,962	-103,331	-87,655	-61,744	-28,285	6,653	43,435	80,106
	SC-10	3	-93,720	-152,087	-164,330	-163,658	-152,616	-131,036	-101,444	-66,907	-30,059	3,892
Tehnike kodiranja	SC-09	5	-135,108	-202,149	-255,847	-267,710	-265,937	-253,020	-231,524	-204,552	-174,776	-144,414
	SC-10	3	-93,720	-152,087	-164,330	-163,658	-152,616	-131,036	-101,444	-66,907	-30,059	3,892
Način prijenosa	SC-06	5	-135,108	-202,149	-255,847	-267,710	-265,937	-253,020	-231,524	-204,552	-174,776	-144,414
	SC-07	3	-93,720	-152,087	-164,330	-163,658	-152,616	-131,036	-101,444	-66,907	-30,059	3,892
Neto sadašnje vrijednosti [€] u scenariju u kojem se razmatra uvođenje fiksne WiMAX pristupne infrastrukture												
Usporedba:	Oznaka scenarija:	Broj baznih stanica:	G1	G2	G3	G4	G5	G6	G7	G8	G9	G10
Širina frekvencijskog kanala	SF-05	4	-93,720	-152,087	-200,479	-207,384	-200,977	-183,728	-158,184	-127,429	-94,117	-60,451
	SF-10	5	-135,108	-202,149	-255,847	-267,710	-265,937	-253,020	-231,524	-204,552	-174,776	-144,414
Tehnike kodiranja	SF-09	9	-217,882	-340,952	-413,369	-473,893	-493,104	-497,511	-492,207	-480,368	-464,733	-447,588
	SF-10	5	-135,108	-202,149	-255,847	-267,710	-265,937	-253,020	-231,524	-204,552	-174,776	-144,414
Način prijenosa	SF-06	9	-217,882	-340,952	-413,369	-473,893	-493,104	-497,511	-492,207	-480,368	-464,733	-447,588
	SF-07	7	-176,495	-252,211	-311,214	-361,821	-371,764	-367,508	-354,108	-334,703	-311,997	-288,244

- *Analiziranje rizika:*

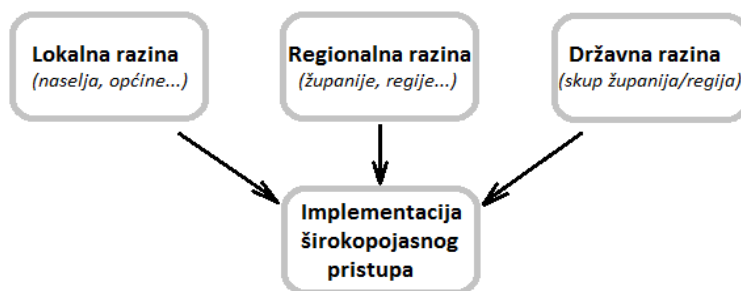
Nakon utvrđivanja ključnih čimbenika koji određuju isplativost ulaganja u širokopojasnu infrastrukturu, u cilju smanjivanja rizika nesigurnosti procjene isplativosti u pojedinim

scenarijima, potrebno je provesti analize rizika za ključne parametre, tj. za one parametre koji najviše utječu na konačnu cijenu širokopojsnih rješenja.

Tako je načinjeno i u primjeru u tablici 3.7., gdje su prikazani različiti iznosi neto sadašnjih vrijednosti, ovisni o količini mrežne opreme koju uvjetuju razlike u dostupnim širinama frekvencijskih kanala, primijenjenim tehnikama kodiranja i načinima prijenosa podataka u mobilnoj te u fiksnoj WiMAX mreži.

3.5.2. Usporedba isplativosti različitih širokopojsnih pristupnih rješenja za ruralna područja

Izbor širokopojsnih pristupnih tehnologija ovisi o veličini promatranog područja obuhvaćenog pojedinim scenarijem, odnosno o postojećoj hijerarhiji scenarija. Stoga je pri izboru najprikladnijih tehnologija u pojedinim ruralnim scenarijima, odnosno pri izboru najisplativijih pristupnih rješenja analizu potrebno vršiti s obzirom na postojeću hijerarhiju scenarija.



Slika 3.26. Hijerarhija ruralnih scenarija

Pri tome se, ovisno o veličini razmatranog područja, razlikuju sljedeće hijerarhijske razine: lokalna razina (koja obuhvaća naselja i općine), regionalna razina (koja obuhvaća županije i regije) te državna razina, kako je prikazano na slici 3.26.. Usporedbu isplativosti različitih širokopojsnih pristupnih rješenja potrebno je izvršiti s obzirom na navedene razine.

3.5.2.1. Usporedba isplativosti uvođenja širokopojasnih pristupnih rješenja u ruralna područja na lokalnoj razini

Izbor najprikladnijih širokopojasnih tehnologija ovisi o promatranim scenarijima. Kao prvo, budući da je prije provedbe svake tehno-ekonomske analize prisutan problem izbora prikladnih scenarija za koje je potrebno provesti analizu, na temelju definiranih kriterija za klasifikaciju ruralnih naselja potrebno je definirati razmatrane scenarije, tj. odabrati naselja koja predstavljaju pojedine tipove ruralnih naselja [85], [86]. Za svaki tip ruralnog naselja moguće je odabrati naselje predstavnika. Navedeni se scenariji međusobno razlikuju i prema broju potencijalnih krajnjih korisnika širokopojasnog Interneta, kako je prikazano u tablici 3.8..

Prije provedbe samih analiza često je potrebno riješiti i problem izbora odgovarajućih pristupnih tehnologija. Budući da nisu sve tehnologije za širokopojasni pristup Internet prikladne za sve tipove ruralnih područja, potrebno je izvršiti analize različitih pristupnih tehnologija [9].

Tablica 3.8. Tipovi ruralnih naselja

Tipovi ruralnih naselja	Mali gradić – prigradsko naselje	Disperzno selo	Osamljeno gospodarstvo
Broj potencijalnih korisnika	80	40	10
Udaljenost od mjesta pristupa mreži (km)	10	15	40

Na temelju dobivenih rezultata izvršenih analiza moguće je definirati najprikladnija rješenja za pojedine tipove područja. Kada se pri izboru tehnologija promatraju manja ruralna područja, scenariji koji obuhvaćaju različite tipove ruralnih naselja – osamljena gospodarstva, disperzna sela te prigradska naselja, rezultati analize provedene u [9] navode na zaključke definirane u nastavku.


U osamljenim gospodarstvima analiza kapitalnih izdataka, godišnjih troškova i trenutne vrijednosti u određenom periodu, pokazuje da su među najisplativijim tehnološkim rješenjima WiMAX i PLC. WiMAX predstavlja pristupno rješenje koje je, zbog veće širine frekvencijskog pojasa i niže cijene, konkurentnije od satelitskog pristupa. Premda se 3G/4G mobilni radijski pristup čini skupim, njegova se cijena smanjuje ukoliko je postavljen dio potrebne pristupne infrastrukture. Izgradnja nove fizičke infrastrukture potrebna za HFC i

FTTU tehnologije je skupo rješenje. Budući da je nadogradnja HFC-a, zbog nepostojanja ranije izgrađene infrastrukture kabela televizije, nemoguća, ova je tehnologija isključena pri analizi osamljenih gospodarstava.

U disperznim selima analiza pokazuje da su među najisplativijim rješenjima WiMAX, ADSL i PLC tehnologije. Naravno, uvođenje HFC-a uz nadogradnju kabela infrastrukture je, na ograničenom broju područja u kojima ona od ranije postoji, isplativije rješenje nego uvođenje HFC-a uz postavljanje nove infrastrukture. Međutim, HFC je svakako skupo rješenje. Izgradnja nove fizičke infrastrukture potrebne za FTTU tehnologiju ima najvišu cijenu.

U malim gradićima – prigradskim naseljima među najisplativijim rješenjima nalazi se ADSL tehnologija. Najskuplje rješenje je uvijek postavljanje nove infrastrukture. Zato se nadogradnji HFC-a u ograničenom području u kojem od ranije postoji kabela infrastruktura, daje prednost.


Dakle, kao zaključak moguće je izdvojiti da su u svim promatranim tipovima ruralnih naselja među najisplativijim pristupnim rješenjima ADSL, WiMAX i PLC te 3G/4G. Na slici 3.27. su prikazane topologije navedenih pristupnih mreža za širokopojasni pristup u ruralnim područjima [9].



Slika 3.27. ADSL, WiMAX, PLC i mobilne 3G (UMTS) / 4G (LTE) pristupne mreže

Kreiranje scenarija koji točno opisuju i modeliraju predviđene situacije povećava relevantnost rezultata tehno-ekonomske analize. Stoga se dobiveni rezultati analize provedene za definirane scenarije mogu koristiti kao putokaz pri analizi svih ostalih naselja sličnog tipa.

Nadalje, izvršena je i međusobna usporeba navedenih žičnih i bežičnih pristupnih tehnologija [85], odnosno fiksnih žičnih (ADSL i PLC) i fiksnih bežičnih (WiMAX) širokopoljnih tehnologija za pristup Internetu u ruralnim područjima [86]. Dobiveni rezultati prikazani su na slici 3.28..



Slika 3.28. Usporedba isplativosti fiksnih žičnih i fiksnih bežičnih širokopoljnih pristupnih rješenja [86]


Iako je PLC tehnologija između navedenih fiksnih rješenja najisplativije rješenje, s obzirom na činjenicu da pristup Internetu preko elektroenergetske mreže još uvijek nije dostupan u mnogim europskim državama, pa tako ni u Republici Hrvatskoj, PLC nije uključen u naknadno provedene analize. Dakle, od prikazanih rješenja za promatrana ruralna područja među najprikladnijim su rješenjima ADSL, WiMAX i 3G/4G tehnologije koje redom predstavljaju fiksna žična, fiksna bežična i mobilna bežična pristupna rješenja.

3.5.2.2. Usporedba isplativosti uvođenja širokopojsnih pristupnih rješenja u ruralna područja na regionalnoj razini

S obzirom na činjenicu da problem digitalnog jaza zahvaća i površinom veća područja, kreirani su i scenariji koji su obuhvaćali veća ruralna područja u odnosu na prethodno provedene analize. Tako je analizirana implementacija širokopojsnog pristupa na području jedne općine podijeljene na ruralni, suburbani i urbani dio [88]. Usporedba uvođenja različitih mobilnih bežičnih pristupnih rješenja (mobilni WiMAX i LTE) je načinjena za različite tipove područja unutar te općine koja se nalazi u ruralnoj županiji [88].


Nadalje, analizirana je i implementacija širokopojsnog pristupa na području jedne ruralne županije (veći broj naselja i područja) podijeljene na ruralni i urbani dio [87], pri čemu je razmotrena problematika vezana uz provedbu tehno-ekonomskih analiza uvođenja fiksnih žičnih (ADSL), fiksnih bežičnih (WiMAX) te mobilnih bežičnih (UMTS) širokopojsnih pristupnih rješenja [87].

Na temelju dobivenih rezultata moguće je provesti usporedbu većeg broja različitih tipova pristupnih rješenja (ADSL, fiksni i mobilni WiMAX i LTE) – usporedbu fiksnih tehnologija (ADSL i WiMAX), usporedbu mobilnih tehnologija (LTE i WiMAX) te međusobnu usporedbu različitih žičnih i bežičnih tehnologija. Dobivene rezultate moguće je usporediti ukoliko se razmotre sve pretpostavke koje su uzete u obzir prilikom definiranja pojedinih scenarija [89].



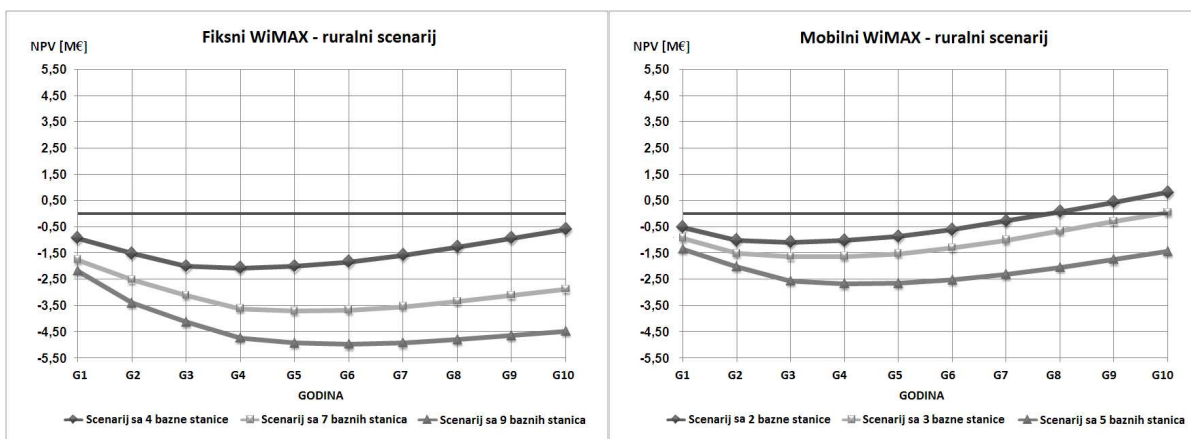
Slika 3.29. Usporedba isplativosti fiksnih žičnih i bežičnih pristupnih rješenja [87]

Usporedba isplativosti različitih fiksnih pristupnih tehnologija čiji su rezultati prikazani na slici 3.29. ukazala je na činjenicu da u cilju povećanja isplativosti fiksnog pristupa treba iskoristiti svu dostupnu mrežnu infrastrukturu. Tako je nadograđeno parično rješenje (ADSL) isplativije je u odnosu na u potpunosti novo fiksno bežično rješenje (WiMAX) [87].



Slika 3.30. Usporedba isplativosti mobilnih pristupnih rješenja [88]

Nadalje, usporedba isplativosti mobilnih i fiksnih pristupnih tehnologija ukazala je na činjenicu da u odnosu na fiksna pristupna rješenja (ADSL i WiMAX) prikazana na slici 3.29. mobilna rješenja (WiMAX i LTE) prikazana na slici 3.30. općenito imaju duži period povrata incijalnih ulaganja [88].



Slika 3.31. Usporedba isplativosti fiksnih i mobilnih bežičnih pristupnih rješenja

Usporedba isplativosti žičnih i bežičnih pristupnih tehnologija ukazala je na činjenicu da su u slučajevima kada je moguća nadogradnja postojeće žične infrastrukture, nadograđena žična rješenja (ADSL) prikazana na slici 3.29. općenito isplativija u odnosu na nova bežična

pristupna rješenja (WiMAX) prikazana na slici 3.31.. Međutim, nove mobilne mreže (mobilni WiMAX) predstavljaju ekonomski prihvatljivo rješenje kada nije dostupna fiksna infrastruktura koju je moguće nadograditi (fiksni WiMAX), kako je prikazano usporedbom rezultata na slici 3.31.. Rezultati prikazani na slici 3.31. dobiveni su za scenarije definirane u poglavlju 3.5.1.

3.5.3. Pregled metoda i analiziranih vrsta širokopojsnih pristupnih rješenja za ruralna područja

S obzirom na definiranu problematiku, provedena je usporedba isplativosti svih analiziranih tehnologija za širokopojsni pristup Internetu u ruralnim područjima uključenima u provedene analize [9], [85], [86], [87], [88], [89] i [90]. U tablici 3.9. nalazi se usporedni pregled svih načinjenih analiza širokopojsnih pristupnih rješenja. Dan je pregled hijerarhijskih razina pojedinih scenarija, analiziranih vrsta pristupnih rješenja i tehnologija te metoda primjenjenih pri analizama.

Usporedba odabranih tehnologija dala je uvid u sličnosti i razlike između pojedinih vrsta pristupnih rješenja te naznačila smjernice za izbor najprikladnijih rješenja u pojedinim tipovima ruralnih područja, ovisno o njihovoj hijerarhiji.

Na temelju dobivenih rezultata analize izvršen je izbor najprikladnijih širokopojsnih tehnologija za ruralna područja koje se razlikuju ovisno o vrstama pristupa – fiksni žični (ADSL), fiksni bežični (WiMAX) te mobilni bežični (3G/4G).

Upravo se navedene tehnologije uključuju u daljnji postupak kreiranja modela za vrednovanje tehničkih i ekonomskih aspekata uvođenja širokopojsnih pristupnih rješenja u ruralna područja opisanog u idućem poglavlju rada.

Tablica 3.9. Usporedba provedenih analiza uvođenja širokopojasnog pristupa

Usporedba analiziranih scenarija i skupina, pristupnih rješenja i tehnologija te primijenjenih metoda		Izvor:						
		[9]	[85]	[86]	[87]	[88]	[89]	[90]
Hijerarhija analiziranih scenarija:								
Naselje:	različiti tipovi ruralnih naselja	✓	✓	✓			✓	
Općina:	jedna općina podijeljena na ruralni, suburbani i urbani dio					✓	✓	
Županija:	ruralna županija podijeljena na ruralni, suburbani i urbani dio				✓			
Država:	različite ruralne i urbane županije	✓						✓
Skupina za koju je provedena analiza:								
Krajnji korisnici		✓						✓
Mrežni operatori		✓	✓	✓	✓	✓	✓	✓
Vrsta širokopojasnog pristupnog rješenja:								
Fiksni žični pristup		✓	✓	✓	✓		✓	✓
Fiksni bežični pristup		✓	✓	✓	✓		✓	✓
Mobilni bežični pristup		✓			✓	✓	✓	✓
Vrsta širokopojasne tehnologije za pristup Internetu putem:								
Digitalnih pretplatničkih linija (ADSL)		✓	✓	✓	✓		✓	✓
Kabelske mreže (HFC)		✓						✓
Elektroenergetske mreže (PLC)		✓		✓				
Optičkog vlakna do korisnika (FTTU)		✓						✓
WMAN mreža (fiksni WiMAX)		✓	✓	✓	✓		✓	✓
WMAN mreža (mobilni WiMAX)						✓	✓	✓
Mobilnih mreža treće generacije (UMTS)		✓			✓			✓
Mobilnih mreža četvrte generacije (LTE)						✓	✓	✓
Satelitski pristup		✓						✓
Primijenjene metode:								
Kvalitativna analiza		✓						✓
Analiza troškova i koristi		✓						
Analiza scenarija		✓	✓	✓	✓	✓	✓	
Analiza osjetljivosti			✓	✓	✓	✓	✓	
Analiza rizika					✓			
Komparativna analiza		✓	✓	✓	✓	✓	✓	✓
Ekonometrijska kvantitativna analiza								✓

4. ANALIZE ČIMBENIKA BITNIH ZA UVOĐENJE ŠIROKOPOJASNOG PRISTUPA INTERNETU U RURALNIM PODRUČJIMA

Razvoj širokopojasnog pristupa Internetu i dostupnost širokopojasnih usluga pokreće ekonomski rast, povećava stopu zaposlenosti i konkurentnosti, a dostupnost širokopojasnog pristupa povećava kvalitetu života krajnjih korisnika, pa je zaostajanje brojnih ruralnih područja u gustoći broja korisnika širokopojasnog pristupa potrebno smanjiti posebnim mjerama što prije i u što većem postotku kako bi se dostigli ciljevi postavljeni na europskoj [1] te na globalnoj razini.

Budući da će pri uvođenju širokopojasnog pristupa Internetu troškovi po stanovniku u ruralnim područjima uglavnom biti veći od troškova po stanovniku u urbanim područjima, ali i da je pristup u ruralnim područjima nužan pokretač ekonomskog razvoja područja te da je razvoj ruralnih područja ključan za razvoj ostatka cjeline (države, regije itd.), osim kriterija koji vrednuju samo isplativost uvođenja širokopojasnog pristupa Internetu, potrebno je voditi računa i o nužnosti uvođenja širokopojasnog pristupa u ruralna područja. Stoga je potrebno definirati najbitnije kriterije za vrednovanje uvođenja širokopojasnog pristupa Internetu u ruralnim područjima. Takvi kriteriji trebali bi biti zasnovani na provedenim analizama ključnih čimbenika za uvođenje širokopojasnog pristupa Internetu u ruralnim područjima te uključivati interese, kako samih operatora, tako i potencijalnih krajnjih korisnika.

Dakle, prisutan je nedostatak kriterija nužnih za vrednovanje uvođenja širokopojasnog pristupa Internetu u ruralnim područjima zasnovanih na provedenim analizama ključnih čimbenika. Kriteriji bi trebali ukazati na opravdanost uvođenja širokopojasnog pristupa u ruralnim područjima i u onim slučajevima kada ekonomska isplativost nije značajna. Postojeće tehno-ekonomske modele tada bi bilo moguće prilagoditi za analizu uvođenja širokopojasnog pristupa u ruralna područja, odnosno proširiti okvirom koji bi uključivao kriterije zasnovane na interesima operatora, ali i zahtjevima potencijalnih krajnjih korisnika u ruralnim područjima.

Prilikom analiziranja povezanosti različitih čimbenika s razinom usvajanja širokopojasnog pristupa Internetu na određenom području potrebno je provesti analize intenziteta i načina na koji su navedeni čimbenici povezani, tj. korelirani sa usvajanjem širokopojasnog pristupa -

tzv. regresijske analize čimbenika. Stoga je u ovoj cjelini rada potrebno prvo definirati postojeće vrste regresijskih analiza čimbenika i ukazati na probleme do kojih dolazi pri provedbi takvih analiza.

Nadalje, potrebno je odabrati čimbenike za koje će se provesti regresijske analize. Kako je prethodno navedeno, potrebno je razmotriti dva aspekta – aspekt mrežnih operatora te onaj potencijalnih krajnjih korisnika i to kroz provedbu kvantitativnih analiza:

- regresijske analize ključnih čimbenika bitnih za uvođenje širokopojasnog pristupa u ruralnim područjima i
 - analize ključnih čimbenika koji utječu na operatorovu odluku o uvođenju širokopojasnog pristupa Internetu u ruralnim područjima
- te kvalitativnih analiza:
- analize podataka o potencijalnim krajnjim korisnicima novih širokopojasnih usluga u ruralnim područjima i
 - analize ključnih čimbenika pri investiranju u širokopojasni pristup u ruralnim područjima iz perspektive mrežnih operatora.

Dobiveni rezultati provedenih analiza trebali bi omogućiti vrednovanje uvođenja širokopojasnog pristupa Internetu u ruralnim područjima iz perspektive potencijalnih krajnjih korisnika i mrežnih operatora. Isto tako, na temelju na provedenih analiza čimbenika bilo bi moguće definirati kriterije nužne za vrednovanje uvođenja širokopojasnog pristupa Internetu u ruralnim područjima. Na definiranim kriterijima trebalo bi se zasnivati kreiranje novog okvira koji bi mogao biti implementiran u tehno-ekonomske modele za vrednovanje uvođenja različitih širokopojasnih pristupnih rješenja u ruralnim područjima.

4.1. Regresijska analiza čimbenika bitnih za uvođenje širokopojasnog pristupa Internetu

Na uvođenje širokopojasnog pristupa Internetu utječe veliki broj različitih regulatornih, tehnoloških, zemljopisnih, socio-demografskih, ekonomskih, kulturalnih te psihografskih čimbenika, kako je navedeno i u [92]. Općenito su broj širokopojasnih priključaka i cijene širokopojasnih usluga na određenom području uvjetovani interakcijom čimbenika na strani

ponude te čimbenika na strani potražnje [93]. Nadalje, i na ponudu i na potražnju utječu brojni socio-demografski, ekonomski i regulatorni čimbenici. Na primjer, potražnja za širokopojasnim pristupom Internetu ovisi o prihodima, dobi, obrazovanju i stupnju računalne pismenosti stanovništva, dok ponuda ovisi o čimbenicima kao što su gustoća naseljenosti, broj stanovnika, tip terena, broj prisutnih operatora na tržištu kao i o postojećim poticajima za uvođenje širokopojasnog pristupa na promatranom području.

Prilikom analiziranja povezanosti različitih čimbenika s razinom usvajanja širokopojasnog pristupa Internetu na određenom području potrebno je provesti analizu svih dostupnih podataka - empirijsku analizu čimbenika. Nakon prikupljanja svih dostupnih podataka o čimbenicima bitnima za analizu uvođenja širokopojasnog pristupa na nekom području, pristupa se analizi intenziteta i načina na koji su navedeni čimbenici povezani, odnosno korelirani sa usvajanjem širokopojasnog pristupa. Polazišta ovakvih analiza, koje se nazivaju regresijskim analizama, sastoje se u ispitivanju istovremenih promjena čimbenika. Čimbenici čiji se odnosi analiziraju predloženi su varijablama. Pri tome se varijabla čija se promjena objašnjava (npr. broj širokopojasnih priključaka) naziva zavisnom, a varijable pomoću kojih se objašnjavaju promjene (npr. različiti čimbenici bitni za usvajanje širokopojasnog pristupa), nezavisnim varijablama. U nastavku su detaljnije objašnjene vrste korelacija između čimbenika, vrste regresijskih analiza čimbenika, kao i osnovni problemi do kojih dolazi pri provedbi regresijskih analiza.

4.1.1. Korelacije između čimbenika

Povezanost, odnosno usklađenost u promjenama vrijednosti dviju ili više analiziranih čimbenika, tj. varijabli (npr. broja korisnika širokopojasnih usluga i čimbenika bitnih za usvajanje širokopojasnih usluga) moguće je izračunati primjenom određenih statističkih postupaka te prikazati korelacijama. Korelacija je u pravilu veća što je manji broj različitih vrijednosti zavisne varijable koje se vežu uz određenu vrijednost nezavisne varijable. Dok djelomična korelacija označava slučaj u kojem određenoj vrijednosti nezavisne varijable odgovara više različitih vrijednosti zavisne varijable, potpuna korelacija ili funkcionalna veza, odnosno najveći mogući stupanj usklađenosti u promjenama vrijednosti dviju varijabli, postoji u slučaju kada svakoj vrijednosti nezavisne varijable odgovara samo jedna vrijednost zavisne varijable. Najjednostavniji je oblik korelacije slučaj u kojem su zavisna i nezavisne varijable u linearnom odnosu.

Vrijednost korelacije brojčano se iskazuje koeficijentom korelacije r . Koeficijent korelacije pokazuje u kojoj su mjeri promjene vrijednosti jedne varijable povezane s promjenama vrijednosti druge varijable. Najčešće se koriste Pearsonov koeficijent korelacije, koji se označava sa r_p , i Spearmanov koeficijent korelacije, koji se označava oznakom r_s [94]. Pearsonov koeficijent korelacije koristi se za brojčane varijable koje se iskazuju u intervalima ili omjerima, ukoliko su podaci za barem jednu od varijabli normalno raspodijeljeni, varijable se međusobno nalaze u linearnom odnosu, a ispitivani uzorak je velik. Za razliku od Pearsonovog koeficijenta korelacije koji podrazumijeva linearnu povezanost, za Spearmanov koeficijent korelacije linearna povezanost nije uvjet. Spearmanov koeficijent izračunava se kada raspodjela podataka značajno odstupa od normalne raspodjele ili kada postoje podaci koji značajno odstupaju od većine izmjerenih.

Postupak izračunavanja korelacije često se koristi neispravno, kako je navedeno i u [94]. Najčešće pogreške koje nastaju pri određivanju korelacije vezane su uz uvjete izračunavanja korelacije, značajnost i tumačenje koeficijenta korelacije, pretpostavljanje uzročno-posljedičnih veza i jačine povezanosti promatranih varijabli. Kako bi se izbjegle pogreške pri zaključivanju nužno je razlikovati postojeće vrste korelacija, kao i uvjete za njihovo izračunavanje i tumačenje.

Prije izračunavanja korelacije potrebno je provjeriti zadovoljavaju li izmjereni podaci uvjete za izračunavanje Pearsonove korelacije. Ukoliko uvjeti za izračunavanje Pearsonove korelacije nisu zadovoljeni, može se izračunati Spearmanov koeficijent korelacije. Nadalje, nakon izračuna koeficijenta korelacije važno je točno protumačiti dobiveni rezultat, odnosno objasniti značenje vrijednosti koeficijenta korelacije. Stoga se u prikazu rezultata korelacija, uz iznos koeficijenta korelacije r , obavezno navodi i značajnost koeficijenta korelacije p .

Dakle, procijenjena vrijednost koeficijenta korelacije prikazuje se uz određenu razinu vjerojatnosti p , kojom se iskazuje značajnost koeficijenta korelacije. Ukoliko je koeficijent korelacije značajan, odnosno ukoliko je njegova vrijednost manja u odnosu na postavljenu granicu značajnosti (uobičajeno $p \leq 0.01$ ili $p \leq 0.05$), koeficijent korelacije smije se tumačiti. Ukoliko je vrijednost p veća u odnosu na postavljenu granicu, koeficijent korelacije nije značajan i tada se, bez obzira na njegovu vrijednost, ne smije tumačiti.

Koeficijent korelacije prikazuje stupanj i smjer korelacije. Prilikom tumačenja vrijednosti koeficijenta korelacije r vrijede ista pravila i za Pearsonov i za Spearmanov koeficijent. Ovisno o vrijednosti koeficijenta korelacije, razlikuju se negativna korelacija ('-1'), pozitivna korelacija ('+1') te slučaj kada ne postoji povezanost ('0') između promatranih varijabli.

Koeficijent korelacije moguće je interpretirati kao grubu aproksimaciju razine povezanosti promatranih varijabli. Pri tome se koristi sljedeća interpretacija - ukoliko je vrijednost koju poprima koeficijent korelacije u rasponu:

- od ± 0.00 do ± 0.20 – među promatranim varijablama ne postoji povezanost / postoji neznatna povezanost,
- od ± 0.20 do ± 0.40 – među promatranim varijablama postoji slaba povezanost,
- od ± 0.40 do ± 0.70 – među promatranim varijablama postoji značajna povezanost,
- od ± 0.70 do ± 1.00 – među promatranim varijablama postoji visoka povezanost.

Pozitivan smjer korelacije, tj. pozitivan predznak koeficijenta korelacije, pokazuje da je porast vrijednosti nezavisne varijable povezan sa porastom vrijednosti zavisne varijable. Analogno tome, negativan smjer korelacije, tj. negativan predznak koeficijenta korelacije, pokazuje da je porast vrijednosti nezavisne varijable povezan sa smanjenjem vrijednosti zavisne varijable.

Bitno je naglasiti da korelacija govori o povezanosti, a ne o uzročno-posljedičnoj vezi među varijablama, kako je istaknuto i u [94]. Korelacija nikada ne dokazuje uzročno-posljedičnu vezu. U istraživanjima se korelacija koristi za postavljanje hipoteza, a ne za njihovo testiranje. Ukoliko se utvrdi postojanje povezanosti između varijabli, uzročno-posljedičnu vezu tek je potrebno dokazati.

Nadalje, izračunati koeficijent korelacije nije mjera jačine povezanosti varijabli. Pokazatelj jačine linearne povezanosti, odnosno zajedničkih udjela varijabli - zavisne i nezavisnih, uključenih u korelacijsku analizu naziva se koeficijentom determinacije, označava se sa R i određuje prema sljedećem:

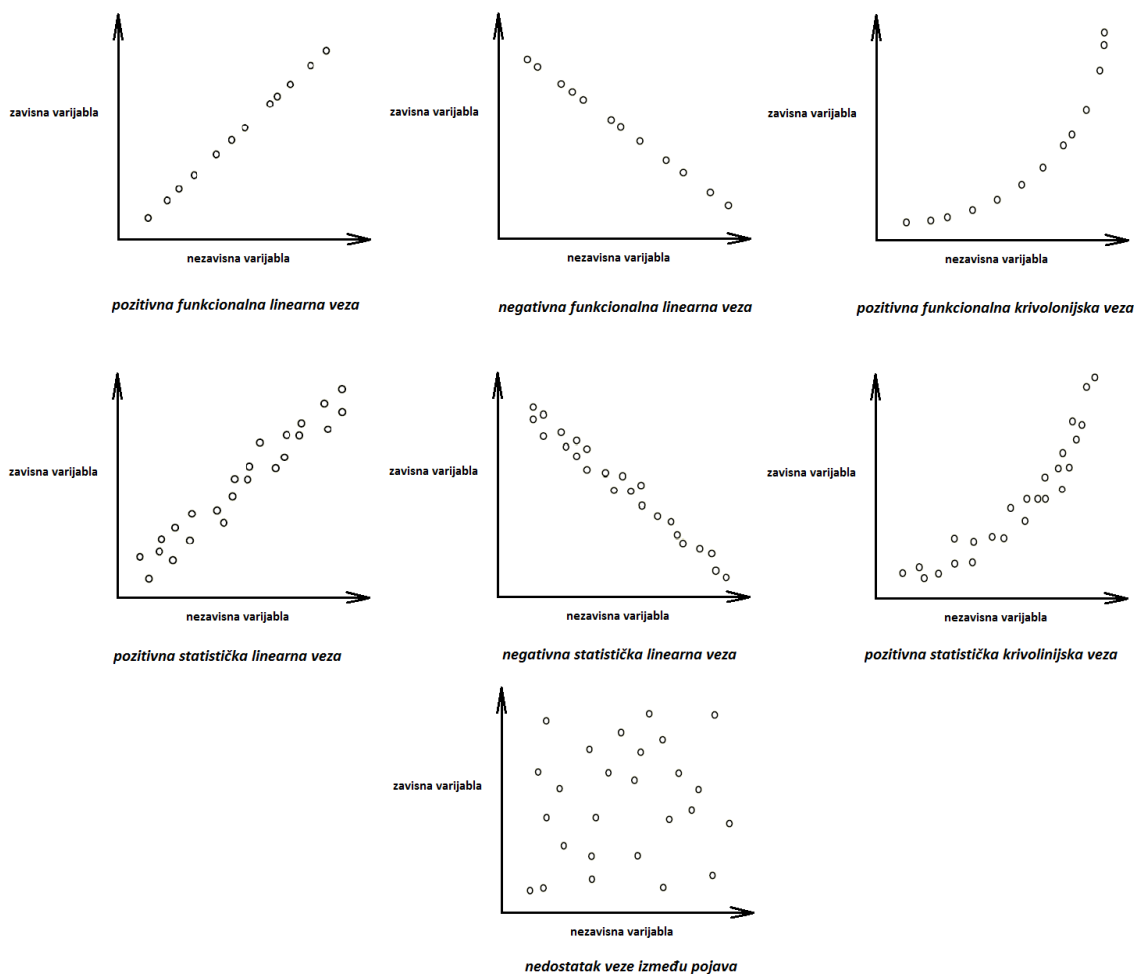
$$R = r^2. \quad (4.1)$$

Iz gornje relacije je vidljivo da povećanje vrijednosti koeficijenta korelacije, značajno utječe na povećanje koeficijenta determinacije.

Dakle, opisanu metodu za određivanje korelacija između određenih varijabli moguće je primijeniti i pri utvrđivanju povezanosti između broja korisnika širokopojsnih usluga i čimbenika koji utječu na usvajanje širokopojsnih usluga. Međutim, pomoću korelacija nije moguće utvrditi uzročno-posljedičnu vezu među varijablama (dakle, moguće je utvrditi postoji li povezanost između promatranih čimbenika i broja korisnika širokopojsnih usluga, ali nije moguće utvrditi utječu li promatrani čimbenici na broj korisnika širokopojsnih usluga), već je u tu svrhu potrebno koristiti regresijske analize.

4.1.2. Jednostavna linearna i nelinearna regresijska analiza čimbenika

Jednostavna regresijska analiza ispituje ovisnost zavisne varijable (tj. posljedice, npr. broja korisnika širokopojsnih usluga) o jednoj nezavisnoj varijabli (tj. uzroku, npr. čimbenika bitnog za usvajanje širokopojsnih usluga) s ciljem utvrđivanja analitičkog izraza (tj. regresijskog modela) koji opisuje takvu pretpostavljenu uzročno-posljedičnu povezanost.



Slika 4.1. Regresijska veza između čimbenika

U pravilu, ovisnosti zavisnih varijabli o nezavisnim varijablama mogu biti statističke ili funkcionalne, kako je prikazano na slici 4.1.. Dok kod statističkih kovarijacija veze između čimbenika nemaju svojstvo predvidivosti, kod funkcionalnih kovarijacija su takvi odnosi postojani te se izražavaju zakonitostima predočenima formulama ili jednadžbama.

Jednostavna regresijska analiza se primjenjuje i u slučaju kada je potrebno istražiti mogućnost procjenjivanja vrijednosti zavisne varijable na temelju poznatih vrijednosti nezavisnih varijabli. Tako je na primjer, moguće procijeniti broj korisnika širokopojsnih usluga (zavisne varijable) na temelju poznatih vrijednosti razmatranih čimbenika (nezavisnih varijabli).

Prikupljene podatke moguće je prikazati parovima vrijednosti koji sadrže podatke o nezavisnoj i zavisnoj varijabli. Parovi rezultata se prikazuju kao točke u koordinatnom sustavu. Spajanjem točaka nastaje grafički prikaz regresije. Time se dobiva prikaz odnosa između promatranih varijabli. Ako je dobiven pravac, povezanost je linearna i određena jednadžbom pravca regresije. Ukoliko nije dobiven pravac, riječ je o zakrivljenoj korelaciji. Dakle, regresijska analiza se zasniva na modelu - jednadžbi s odgovarajućim parametrima i varijablama koja opisuje ovisnosti među pojavama.

U regresijskoj analizi određuju se zavisne i nezavisne varijable, pribavljaju podaci o varijablama, ispituje njihova točnost, izrađuje dijagram rasipanja, odabire oblik modela, procjenjuju parametri te se, na posljetku, dobiveni model koristi za predviđanje. Pri tome se za utvrđivanje pokazatelja jakosti i smjera statističkih veza među čimbenicima predočenim statističkim varijablama može koristiti korelacijska analiza.

Dijagram rasipanja, dobiven kroz postupak regresijske analize, primjenjuje se kao pomoćno sredstvo pri odabiru modela statističkog odnosa između dviju pojava. Dijagram prikazuje parove vrijednosti dviju promatranih numeričkih varijabli. Prema rasporedu točaka u dijagramu rasipanja može se zaključiti jesu li korelacije između varijabli pozitivne ili negativne. U slučaju kada porast vrijednosti nezavisne varijable prati porast vrijednosti zavisne varijable radi se o pozitivnoj korelaciji, a u suprotnom - kada porast vrijednosti nezavisne varijable prati pad vrijednosti zavisne varijable, o negativnoj korelaciji. Također, moguće je odrediti i stupanj jakosti statističke povezanosti među varijablama. Pokazatelji jakosti statističkih veza nazivaju se koeficijentima korelacije.

Ukoliko se promatranjem dijagrama rasipanja može predočiti pravac koji se prilagođuje danom rasporedu točaka, radi se o linearnoj regresiji. U slučaju linearne regresije, regresijska jednadžba koja opisuje ovisnosti zavisne (y) o nezavisnoj (x) varijabli ima sljedeći oblik:

$$\hat{y}_N = \beta_0 + \beta \cdot x_N, \quad (4.2)$$

pri čemu postoji N regresijskih vrijednosti ordinata \hat{y}_i . Regresijske vrijednosti \hat{y}_i razlikuju se od stvarnih vrijednosti y_i budući da je veza između pojava statistička.

Takve razlike se nazivaju rezidualnim odstupanjima, a određuju se na sljedeći način:

$$u_i = y_N - \hat{y}_N. \quad (4.3)$$

Koeficijent β_0 , konstantni član, prikazuje regresijsku vrijednost zavisne varijable kada nezavisna varijabla poprimi vrijednost nula:

$$\beta_0 = \bar{y} - \beta \cdot \bar{x}. \quad (4.4)$$

Pri tome \bar{y} označava srednju vrijednost od ukupno N regresijskih vrijednosti ordinata \hat{y}_i .

Koeficijent β , regresijski koeficijent, pokazuje za koliko se prosječno promijeni vrijednost zavisne varijable u slučaju jedinične promjene vrijednosti nezavisne varijable:

$$\beta = \frac{\sum x_i y_i - N \bar{x} \bar{y}}{\sum x_i^2 - N \bar{x}^2}. \quad (4.5)$$

Budući da se povezanost dvije pojave ne može se uvijek izraziti linearnim modelom, u izgradnji modela regresije koriste se različiti oblici funkcija, nelinearni modeli regresije. Kod svih modela regresije je ovisnost zavisne (y) o nezavisnoj (x) varijabli statistička. Budući da su osnovni regresijski modeli linearni modeli, većina nelinearnih modela se pokušava linearizirati.

Od modela koji se mogu transformirati u modele jednostavne linearne regresije često se koriste modeli opisani potencijalnim funkcijama, pri čemu se potencijalne funkcije koriste u svrhu modeliranja ponude, potražnje, cijena ili proizvodnje.

Potencijalna funkcija oblika:

$$y = \beta_0 \cdot x^\beta \quad (4.6)$$

može se transformirati u linearni sustav oblika:

$$\ln y = \ln \beta_0 + \beta \ln x \quad (4.7)$$

Vrijednosti parametara β_0 i β koji se procjenjuju pomoću empirijskih vrijednosti dobivaju se pomoću izraza:

$$\beta_0 = \exp \left(\frac{\sum_i y_i^2 \ln y_i}{\sum_i y_i^2} - \beta \bar{x} \right) \quad (4.8)$$

$$\beta = \frac{\sum_i y_i^2 \ln y_i (\ln x_i - \bar{x})}{\sum_i y_i^2 (\ln x_i - \bar{x})^2} \quad (4.9)$$

pri čemu je:

$$\bar{x} = \frac{\sum_i y_i^2 \ln x_i}{\sum_i y_i^2} \quad (4.10)$$

Pri tome vrijednost parametra β pokazuje relativnu promjenu zavisne varijable za jedinično relativno povećanje nezavisne varijable te se tumači kao postotna promjena.

Analize transformiranih modela provode se na isti način kao kod linearnih modela, međutim pri interpretaciji rezultata nužno je voditi računa o tome koje su varijable ili parametri transformirani.

Ukoliko je u navedenom modelu izvršena transformacija zavisne varijable, koriste se njene logaritamske vrijednosti, dok se vrijednost parametara originalnog modela dobiva antilogaritmiranjem.

Analiza rezidualnih odstupanja provodi se izračunavanjem istih pokazatelja reprezentativnosti kao kod linearnog modela.

4.1.3. Višestruka linearna i nelinearna regresijska analiza čimbenika

Višestruka regresijska analiza razmatra povezanost zavisne varijable y (npr. broja korisnika širokopojasnih usluga) te više različitih nezavisnih varijabli x_1, x_2, \dots, x_k (npr. nekoliko čimbenika bitnih za usvajanje širokopojasnih usluga) Ta povezanost može biti linearna ili nelinearna, pa se razlikuju linearni i nelinearni modeli višestruke regresije.

Pod nelinearnim regresijskim modelom podrazumijeva se regresijski model nelinearan u parametrima. Budući da je osnovni regresijski model linearan, većina nelinearnih modela se pokušava svesti na linearan model. Postoji li transformacija kojom se polazni nelinearni model linearizira, model je moguće analizirati kao model višestruke linearne regresije. Međutim, ako model nije moguće linearizirati, takav je model pravi nelinearni model.

Regresijski model je jednadžba koja sadrži zavisnu varijablu y , niz nezavisnih varijabli x_1, x_2, \dots, x_k , slučajnu varijablu e te parametre. Primjer opisa određenog linearnog regresijskog modela prikazan je sljedećom jednadžbom:

$$y = f(x_1, x_2, \dots, x_k) + e \quad (4.11)$$

Pri tome, slučajna varijabla e predstavlja nepoznata odstupanja od funkcionalnog odnosa. Kod linearnih regresijskih modela, poput modela prikazanog gornjim izrazom, slučajna varijabla se pojavljuje kao aditivni član. Kod nelinearnih regresijskih modela ona je čimbenik umnoška s funkcionalnim dijelom modela.

U ekonometrijskim modelima se linearna regresijska veza između zavisne te nezavisnih varijabli određuje na osnovu n različitih uzoraka, pa se gornja vektorska jednadžba zapisuje u obliku sustava od n jednadžbi:

$$\begin{aligned} y_1 &= \beta_0 + \beta_1 \cdot x_{11} + \dots + \beta_k \cdot x_{1k} + e_1 \\ y_2 &= \beta_0 + \beta_1 \cdot x_{21} + \dots + \beta_k \cdot x_{2k} + e_2 \\ &\vdots \\ y_n &= \beta_0 + \beta_1 \cdot x_{n1} + \dots + \beta_k \cdot x_{nk} + e_n \end{aligned} \quad (4.12)$$

Ukoliko se koristi matrični zapis, gornji zapis je moguće prikazati kraće:

$$y = X \cdot \beta + e. \quad (4.13)$$

Pri tome je X matrica, a y , β i e su vektori u kojima se nalaze vrijednosti uzoraka:

$$y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}, X = \begin{bmatrix} 1 & x_{11} & \dots & x_{1k} \\ 1 & x_{21} & \dots & x_{2k} \\ \vdots & \vdots & \vdots & \vdots \\ 1 & x_{n1} & \dots & x_{nk} \end{bmatrix}, \beta = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_k \end{bmatrix} \text{ i } e = \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_n \end{bmatrix}. \quad (4.14)$$

U ekonometrijskim modelima veze između varijabli vrijede samo približno, pa su moguća određena slučajna odstupanja, koja su u modelu sadržana u slučajnoj pogrešci. U regresijskoj analizi se razlikuju relevantne od nerelevantnih varijabli. Relevantne varijable izravno se uključuju u model (matrica X). U modelu se utjecaj nerelevantnih varijabli na zavisnu varijablu nalazi sadržan u slučajnom članu, tj. slučajnoj pogrešci. Ona opisuje nesustavno ponašanje u modelu. Takva slučajna pogreška javlja se uvijek, neovisno o tome da li su u model uključene sve relevantne varijable. Uz navedeno, u vrijednost slučajne pogreške uključene su i pogreške koje nastaju prilikom određivanja vrijednosti varijabli. Ako je vrijednost slučajne pogreške mala te ako su u model uključene sve značajne varijable, moguće je pretpostaviti da je pogreška nastala slučajno i da u prosjeku ne utječe na zavisnu varijablu.

Model višestruke linearne regresije koji opisuje vezu između zavisne i većeg broja nezavisnih varijabli, ima sljedeći oblik:

$$y = \beta_0 + \beta_1 \cdot x_1 + \beta_2 \cdot x_2 + \dots + \beta_k \cdot x_k + e. \quad (4.15)$$

Pri tome se u regresijskoj analizi polazi od pretpostavke da je veza između zavisne i nezavisnih varijabli linearna, da su varijable x_i ($i=1, 2, \dots, k$) u matrici X međusobno nezavisni vektori (u suprotnom se javlja problem autokorelacije) te da slučajne varijable e_i ($i=1, 2, \dots, n$) imaju normalnu razdiobu sa konstantnom varijancom i očekivanjem jednakim nuli.

Zadatak regresijske analize je procjenjivanje nepoznatih parametara vektora β i nepoznate varijance slučajnih varijabli e_i . Najčešća metoda ocjenjivanja nepoznatih parametara je metoda najmanjih kvadrata (engl. *Ordinary Least Squares*, skr. OLS). Cilj metode najmanjih kvadrata je minimiziranje zbroja kvadrata odstupanja slučajnih varijabli e_i na temelju dobivenih uzoraka. Metoda najmanjih kvadrata pronalazi najbolje linearne procjene parametara vektora β , odnosno procjene parametara koji imaju svojstvo nepristranosti, efikasnosti i nekonzistentnosti.

U regresijskoj analizi primjenjuju se sljedeći statistički pokazatelji:

- $se_1; se_2; \dots; se_n$ - vrijednosti standardne pogreške za koeficijente $\beta_1; \beta_2; \dots; \beta_n$;
- se_{β_0} - vrijednost standardne pogreške za konstantu β_0 ;
- $R=r^2$ - koeficijent determinacije koji uspoređuje procijenjene i stvarne vrijednosti y te poprima vrijednost u intervalu od 0 do 1 (ukoliko je $R=1$, radi se o savršenoj korelaciji u uzorku, tj. nema razlike između procijenjene i stvarne y vrijednosti, a ako je $R=0$, regresijska jednadžba nije pogodna za predviđanje y vrijednosti);
- se_y - standardna pogreška za procijenjenu y vrijednost;
- F - statistika pomoću koje se utvrđuje događaju li se promatrani odnosi između zavisnih i nezavisnih varijabli slučajno;
- df - stupnjevi slobode za pronalaženje kritičnih vrijednosti za F u statističkoj tablici;
- ss_{reg} - regresijski zbroj kvadrata;
- ss_{resid} - rezidualni zbroj kvadrata.

Za svaku točku se u regresijskoj analizi računa kvadrat razlike između procijenjene vrijednosti y za tu točku i trenutne vrijednosti y . Zbroj kvadrata ovih razlika naziva se rezidualni zbroj kvadrata, ss_{resid} . Nakon toga, računa se ukupni zbroj kvadrata, ss_{total} . Regresijski zbroj kvadrata, ss_{reg} , se može dobiti iz izraza:

$$ss_{reg} = ss_{total} - ss_{resid}. \quad (4.16)$$

Što je manji rezidualni zbroj kvadrata, u usporedbi s ukupnim zbrojem kvadrata, to je veća vrijednost koeficijenta determinacije, $R=r^2$. Koeficijent determinacije pokazuje koliko točno jednadžba nastala regresijskom analizom objašnjava odnos između varijabli, jer vrijedi relacija:

$$R = ss_{reg} / ss_{total}. \quad (4.17)$$

U nekim se slučajevima uklanjanjem određenih x varijabli mogu jednako točno predvidjeti y vrijednosti. U modelu u kojem se određena varijabla x može izraziti kao zbroj više potrebnih x varijabli postoji kolinearnost. U tom se slučaju takve suvišne varijable izostavljaju iz regresijskog modela. Uklonjene varijable imaju zanemarive vrijednosti β koeficijenata i vrijednosti se . Ukoliko se jedna ili više varijabli ukloni, promijenit će se vrijednost df budući da ona ovisi o broju x varijabli koje se koriste za predviđanje, a promijenit će se i vrijednosti se_y i F . Za određivanje statističke značajnosti pojedinih ulaznih varijabli i pojednostavljenje regresijskog modela koristi se stupanjska regresija s postupnim smanjivanjem.

4.1.4. Testiranje hipoteza u modelima višestruke linearne regresije

U modelima višestruke linearne regresije, opisanima formulom (4.15), pretpostavlja se da su slučajne varijable e_i normalno raspodijeljene:

$$e_i \sim N(0, \sigma^2), \quad i = 1, 2, \dots, n; \quad (4.18)$$

te da su slučajne varijable međusobno nezavisne:

$$\text{Cov}(e_i, e_j) = E(e_i e_j) = 0, \quad i \neq j; \quad i, j = 1, 2, \dots, n. \quad (4.19)$$

Ukoliko pretpostavka o nezavisnosti slučajnih varijabli u modelu višestruke linearne regresije nije ispunjena, odnosno ukoliko vrijedi:

$$E(e_t e_{t-s}) \neq 0, \quad t > s; \quad (4.20)$$

javlja se problem autokorelacije, odnosno korelacije slučajnih varijabli unutar promatranog stohastičkog procesa. Ako je u modelu prisutan problem autokorelacije, izračunavanje standardnih pogrešaka procijenjenih parametara dovodi do pogrešnih zaključaka, a provedeni testovi značajnosti nisu relevantni. Uzroci autokorelacije mogu biti:

- pogrešna specifikacija modela,
- pogrešna specifikacija svojstava slučajnih varijabli i
- transformacije izvornih vrijednosti varijabli, izraženih u obliku vremenskih nizova.

Kako bi se uočile posljedice autokorelacije na procjenjivanje parametara regresijskog modela potrebno je odrediti vrstu postojeće autokorelacije. Najčešće se pretpostavlja da su slučajne varijable generirane autoregresijskim modelom prvog reda, koji se opisuje pomoću relacije:

$$e_t = \rho \cdot e_{t-1} + u_t. \quad (4.21)$$

Kako se vidi iz prikazane relacije, slučajna varijabla e_t ovisi o svojim lagiranim vrijednostima te o dodatnoj slučajnoj vrijednosti u_t , koja se definira kao inovacija u trenutku t . Model je prvog reda budući da ovisi samo o jednoj prethodnoj vrijednosti slučajne varijable e .

Općenito se za dani stohastički proces autokorelacijska funkcija procesa definira kao niz koeficijenata autokorelacije:

$$\{\rho(k), k = 0, \pm 1, \pm 2, \dots\}. \quad (4.22)$$

Koeficijent autokorelacije prvog reda $\rho(1)$ pokazuje smjer i jakost linearne veze među članovima procesa razmaknutih za jedno vremensko razdoblje, koeficijent autokorelacije drugog reda $\rho(2)$ pokazuje smjer i jakost linearne veze među članovima procesa razmaknutima za dva vremenska razdoblja, itd.

U slučaju kada u modelu nema autokorelacije ne postoji sustavno ponašanje reziduala. Za razliku od navedenog, pozitivnu autokorelaciju karakterizira cikličko ponašanje reziduala tijekom vremena, a negativnu autokorelaciju alternirajuće ponašanje reziduala.

U svrhu utvrđivanja autokorelacije u regresijskim modelima potrebno je provesti testiranje. Najčešći oblik autokorelacije u regresijskim modelima je problem autokorelacije prvog reda. Durbin-Watsonov test ispituje postojanje problema autokorelacije prvog reda, pri čemu se razlikuju jednosmjerni testovi (ukoliko je promjena moguća u samo jednom smjeru - ili povećanje ili smanjenje) i dvosmjerni testovi (ukoliko je promjena moguća u oba smjera) [95].

Hipoteze se u testu formuliraju na sljedeći način:

$$H_0: \rho = 0 \quad (4.23)$$

$$H_1: \rho \neq 0. \quad (4.24)$$

Ovaj se test ne može primijeniti na model u kojem se kao regresorska varijabla pojavljuje zavisna varijabla s pomakom u vremenu, na model u kojem su vrijednosti varijabli diferencirane te u slučaju kada su regresorske varijable stohastičke.

Empirijska test veličina za Durbin-Watsonov test izračunava se na temelju reziduala prema sljedećem:

$$DW = d = \frac{\sum_{t=2}^n (\hat{e}_t - \hat{e}_{t-1})^2}{\sum_{t=1}^n \hat{e}_t^2} \approx 2 \cdot (1 - \hat{\rho}). \quad (4.25)$$

Ukoliko je iznos koeficijenta korelacije:

$$\rho \approx -1, \text{ tada je } d \approx 4$$

$$\rho \approx 0, \text{ tada je } d \approx 2$$

$$\rho \approx 1, \text{ tada je } d \approx 0.$$

Jednosmjerni test o pozitivnoj korelaciji provodi se ukoliko je $0 \leq d \leq 2$. Pri takvom testiranju se eksperimentalno utvrđen iznos veličine d uspoređuje s kritičnim vrijednostima d_l i d_u koje se očitavaju iz tablica za Durbin-Watsonov test, ovisno o zadanoj razini signifikantnosti α , broju regresorskih varijabli u modelu k i veličini uzorka n . Odlučivanje o postojanju autokorelacije provodi se na sljedeći način:


- ukoliko je $d < d_l$, postoji pozitivna autokorelacija,
- ukoliko je $d_l < d < d_u$, odluka se ne može donijeti,
- ukoliko je $d > d_u$, ne postoji pozitivna autokorelacija.

Jednosmjerni test o negativnoj korelaciji provodi se ukoliko je $2 \leq d \leq 4$. Pri takvom testiranju se veličina d uspoređuje s kritičnim vrijednostima $4-d_u$ i $4-d_l$ koje se očitavaju iz tablica.

Odlučivanje o postojanju autokorelacije provodi se na sljedeći način:

- ukoliko je $d > 4-d_l$, postoji negativna autokorelacija,
- ukoliko je $4-d_u < d < 4-d_l$, odluka se ne može donijeti,
- ukoliko je $d < 4-d_u$, ne postoji negativna autokorelacija.

Područja prihvaćanja i odbacivanja nulte hipoteze, te područja neadekvatnosti primjene jednosmjernih Durbin-Watsonovih testova o pozitivnoj, odnosno negativnoj autokorelaciji prvog reda prikazani su na slici 4.2..



Slika 4.2. Kriteriji za Durbin-Watsonov test autokorelacije

Dakle, kako bi se utvrdilo postojanje autokoreliranih čimbenika u specificiranom regresijskom modelu u kojem se razmatra ovisnost jedne zavisne varijable (npr. broja korisnika širokopojasnih usluga) te više nezavisnih varijabli (npr. različitih čimbenika bitnih za usvajanje širokopojasnih usluga) te kako bi se izbjeglo donošenje pogrešnih zaključaka o međuovisnosti promatranih varijabli, nužno je provođenje autokorelacijskih testova. Tada u regresijskom modelu (npr. u modelu koji opisuje uvođenje širokopojasnog pristupa ili usvajanje širokopojasnih usluga) ostaju samo relevantni i međusobno nekorelirani čimbenici.

4.2. Čimbenici bitni za uvođenje širokopojasnog pristupa Internetu u ruralnim područjima

Danas postoji veliki broj područja u kojima uvođenje pristupa Internetu nije komercijalno privlačno, poput brojnih ruralnih područja. Istovremeno raste jaz između pojedinaca koji imaju te onih koji nemaju mogućnost pristupa informacijsko-komunikacijskim tehnologijama i Internetu [96]. Riječ je o digitalnom jazu, koji osjećaju određene skupine stanovnika.

Prema aktualnim podacima o broju širokopojasnih priključaka moguće je zaključiti da, iako se ukupan broj širokopojasnih priključaka uvelike povećao u posljednjih nekoliko godina, i dalje postoji veliki nerazmjer u gustoći priključaka između urbanih područja te slabije naseljenih ruralnih područja, kako između pojedinih država i regija tako i unutar njih.

Gospodarske promjene su u slabije naseljenim područjima utjecale na smanjenje broja radnih mjesta u poljoprivredi i industriji, a zanemarivanje gospodarskog razvoja tih područja uzrokovalo ekonomski i socijalni pad, koji je uvjetovao daljnja iseljavanja mladog i obrazovanog, odnosno radno aktivnog stanovništva. S obzirom na svoju raširenost i trajanje, depopulacija je obilježila brojna ruralna područja, te ona bilježe sve izraženije smanjenje broja stanovnika, negativne migracijske bilance i izumiranje stanovništva.

Preduvjete za razvoj svakog područja čine uvjeti zasnovani na znanju, primjeni suvremenih tehnoloških rješenja i razvijenoj infrastrukturi [97]. Stoga se zaostajanje pojedinih ruralnih područja u razvoju nastoji smanjiti posebnim mjerama koje ističu važnost konkurentnosti, odnosno stupanj razvijenosti ruralnih područja [98]. Ruralna konkurentnost definira mogućnost ruralnog područja za podupiranje ekonomske aktivnosti kako bi stanovnici ruralnih područja uživali ekonomsku dobrobit. Pri ispitivanju konkurentnosti područja u obzir se uzimaju elementi na koje se odnosi razvitak - socio-demografski i geo-ekonomski čimbenici. Svi su oni bitni pri razmatranju konkurentnosti.

Stupanj konkurentnosti područja ovisi i o stupnju razvijenosti i korištenja informacijske i komunikacijske infrastrukture. Razvoj širokopojasnih komunikacija omogućuje stvaranje i primjenu novih, zahtjevnijih usluga, tehnologija i aplikacija te poboljšanje postojećih, čime se potiče gospodarski rast kroz stvaranje novih vrijednosti, privlačenje novih ulaganja i otvaranje

radnih mjesta [99]. Nadalje, razvoj širokopojasnih komunikacija utječe i na proizvodnost različitih gospodarskih procesa [100].

Na ponudu i potražnju za širokopojasnim pristupom Internetu i širokopojasnim uslugama utječu brojni čimbenici, pa određivanje najbitnijih čimbenika koji utječu na uvođenje širokopojasnog pristupa Internetu nije jednostavno. Kako pokazuju brojna provedena istraživanja, poput npr. [28] i [101], čimbenici kao što su viši stupanj obrazovanja, viši prihodi i veći udio radnog stanovništva na određenom području pozitivno utječu na usvajanje i primjenu internetskih usluga.

Budući da na dostupnost širokopojasnih usluga, osim spomenutih čimbenika, utječe i puno drugih, pri analizi je bitno obuhvatiti što više dostupnih informacija kako bi se dobila potpunija slika o potencijalnom tržištu širokopojasnih usluga. Stoga se, u cilju osiguravanja jednakog pristupa znanju i informacijama za sve stanovnike, bez obzira na zemljopisne, socijalne, generacijske ili bilo koje druge razlike, kroz analizu različitih čimbenika, analiziraju i aspekti uvođenja širokopojasnog pristupa u područjima u kojima postoji manji interes za primjenom takvih tehnologija – u slabije naseljenim, odnosno ruralnim područjima. Kao mjera ostvarene razine uvođenja širokopojasnog pristupa Internetu na određenom području definira se omjer broja širokopojasnih priključaka i broja stanovnika (ili broja kućanstava).

Neke do sada provedene studije i analize, poput [102], [103], [104] i [105], navode različite socio-demografske i tehničke čimbenike koji utječu na potražnju za širokopojasnim uslugama. Oni uključuju čimbenike poput razine i raspodjele dohotka po glavi stanovnika, dobne strukture stanovništva, razine obrazovanja stanovništva, razine opremljenosti kućanstava informatičkom opremom i razine informatičke pismenosti stanovništva. Analizu načina na koje takvi čimbenici utječu na potražnju za širokopojasnim uslugama dodatno komplicira činjenica da su širokopojasne pristupne usluge relativno nove usluge te je vrlo izvjesno da će se postupno broj njihovih korisnika nastaviti povećavati kako korisnici budu postajali svjesniji mogućnosti koje pruža širokopojasni pristup, pa se iz tog razloga budu odlučili na njegovo uvođenje.

Jedan od ključnih ekonomskih čimbenika koji utječe na uvođenje širokopojasnog pristupa svakako je i izdatak za nabavu te postavljanje potrebne pristupne mrežne infrastrukture. Dakle, cijena implementacije širokopojasne infrastrukture smatra se ključnim čimbenikom pri

donošenju odluka o uvođenju širokopojasnog pristupa, dok se pri tome, gustoća stanovništva smatra osnovnim čimbenikom koji utječe na cijenu implementacije širokopojasne infrastrukture po korisniku. U slabije naseljenim područjima stanovništvo nije gusto koncentrirano na malim površinama, pa su fiksne pristupne linije koje povezuju lokalne centrale s krajnjim korisnicima u takvim područjima dulje nego u gusto naseljenim područjima. Isto tako, u slabije naseljenim područjima manji broj pretplatnika dijeli trošak implementacije zajedničke opreme. Iz navedenih je razloga cijena izgradnje fiksnih pristupnih širokopojasnih mreža u tim područjima viša u odnosu na gusto naseljena područja. Slično, i troškovi izgradnje mobilnih bežičnih pristupnih širokopojasnih mreža po korisniku su u slabije naseljenim područjima viši, budući da relativno mali broj krajnjih korisnika snosi troškove postavljanja potrebnih pristupnih kapaciteta.

Osim navedenih razloga, i razlike u zemljopisnim značajkama terena, odnosno geografski čimbenici, također mogu utjecati na razlike u troškovima implementacije širokopojasnog pristupa te u njegovoj dostupnosti, što je pokazano i analizom provedenom u [99]. Tako je, primjerice, zbog nepristupačnijih terena obično skuplje graditi mrežu u planinskim nego u nizinskim područjima.

Nadalje, i regulatorni čimbenici utječu na uvođenje širokopojasnog pristupa. Razina konkurencije među operatorima također utječe na cijenu implementacije širokopojasnog pristupa [106]. U pravilu bi povećanje broja operatora koji konkuriraju na istom tržištu trebalo smanjiti cijene uvođenja širokopojasnog pristupa. Međutim, u slabije naseljenim područjima često ne postoji potreba za izgradnjom većeg broja različitih pristupnih mreža.

Navedeni čimbenici koji utječu na ponudu i potražnju za širokopojasnim uslugama razlikuju se od područja do područja, pa čak i unutar iste države. Tako se gustoća stanovništva i broj operatora koji konkuriraju na istom tržištu razlikuju ovisno o tipu područja. Korisnici u većini gusto naseljenih područja mogu birati između nekoliko različitih operatora koji nude širokopojasni pristup.

Nadalje, na potražnju za širokopojasnim pristupom Internetu može utjecati i država određenim regulatornim mjerama, detaljnije opisanima u [107], [108] i [109]. Potražnju je moguće potaknuti, primjerice, dodjeljivanjem poticaja za kupnju računala ili za pretplate na širokopojasni pristup Internetu onim kućanstvima koja imaju niska primanja te


organiziranjem besplatnih obuka stanovništva u digitalnom opismenjavanju, kako je istaknuto i u [110]. Nadalje, širokopojasne usluge moguće je popularizirati omogućavanjem jednostavnog pristupa internetskim uslugama i informacijama određenih državnih službi.

Kako je navedeno u [111], država može utjecati na uvođenje širokopojasnog pristupa uključivanjem u izgradnju širokopojasne mreže koja bi ostala u njenom vlasništvu ili pružanjem financijske potpore operatorima za izgradnju širokopojasnih mreža u područjima u kojima ne postoje dostatni poslovni interesi za to. Moguće je i smanjivanje troškova implementacije širokopojasnog pristupa ponudom poreznih olakšica i pojednostavljenjem postupaka za dobivanje prava pristupa postojećoj mrežnoj infrastrukturi. Konačno, moguć je i utjecaj na povećanje konkurentnosti među operatorima kroz smanjivanje regulatornih prepreka za ulazak novih operatora na tržište ili kroz postavljanje zahtijeva za dijeljenjem infrastrukture pred one operatore koji imaju monopol na tržištu. Nadalje, budući da lokalne uprave danas imaju sve značajniju ulogu u razvoju širokopojasnih usluga i sadržaja i one mogu preuzeti aktivniju ulogu u razvoju i izgradnji širokopojasne infrastrukture koja bi potencijalnim krajnjim korisnicima omogućila korištenje širokopojasnih usluga [112], [113]. Kako je istaknuto u [111], povećanje broja širokopojasnih priključaka u ruralnim područjima moguće je poticati kroz definiranje optimiziranih poslovnih modela koji će stimulirati uvođenje cjenovno prihvatljivih širokopojasnih rješenja na regionalnim i lokalnim razinama. Takvi poslovni modeli uključuju sudjelovanje države te regionalnih i lokalnih uprava i zajednica u razvoju i izgradnji i subvencioniranju širokopojasne infrastrukture, kako je navedeno i u [114], [78], [115], [116], [117], [118] te [119].

Iako su donedavno u pojedinim državama postojali otpori uključivanju regionalnih i lokalnih uprava u razvoj i izgradnju širokopojasne infrastrukture, danas postoje brojni primjeri uspješnih implementacija širokopojasnih pristupnih rješenja u mnogim državama, regijama i općinama, poput primjera opisanih u [120], [121], [122], [123], [124] i [125].

Osim navedenih socio-demografskih, geo-ekonomskih i regulatornih čimbenika, na uvođenje širokopojasnog pristupa Internetu utječu i drugi čimbenici, npr. razina razvijenosti već postojeće telekomunikacijske infrastrukture [126], način na koji su na određenom području raspoređene platforme za žični i bežični širokopojasni pristup te raznolikost postojeće ponude usluga mobilnog i fiksnog širokopojasnog pristupa i interes korisnika za navedene usluge i dr.

Na slici 4.3. se nalazi pregled i podjela čimbenika bitnih za uvođenje širokopojasnog pristupa i usvajanje širokopojasnih tehnologija i usluga s obzirom na potražnju i na ponudu širokopojasnih rješenja.



Slika 4.3. Prikaz relevantnih čimbenika za usvajanje i uvođenje širokopojasnih rješenja

4.2.1. Preduvjeti za usvajanje širokopojasnih tehnologija i usluga u ruralnim područjima i izbor čimbenika za regresijsku analizu

Razvoj širokopojasnog pristupa Internetu te širokopojasnih aplikacija i usluga prepoznati su kao ključni pokretači ekonomskog rasta, zaposlenosti, konkurentnosti i učinkovitosti te kao čimbenik osiguravanja učinkovitijeg sustava zdravstva, obrazovanja, znanosti, kulture, turizma i dr. Činjenica je da širokopojasnost povećava kvalitetu života stanovništva i potiče razvoj gospodarstva tako što omogućuje veću zaposlenost, ekonomski rast i rast u informatičkom sektoru.

Dakle, pristup širokopojasnim tehnologijama i uslugama može revitalizirati ruralna područja kroz poticanje gospodarskog razvoja tih područja [99]. Razvoj ruralnih područja bi trebao zaustaviti daljnje iseljavanje mladog stanovništva, omogućiti povratak školovanih kadrova, povećati ukupni intelektualni potencijal i ukupni ostvareni dohodak u tim područjima.

Stoga je zaostajanje pojedinih područja po pitanju gustoće broja širokopojasnih korisnika potrebno smanjiti koliko je god moguće. Na taj način trebali bi se stvoriti preduvjeti za uključivanje svih europskih ruralnih područja u okvire u skladu s europskim inicijativama.

Kroz analizu različitih kvantitativnih čimbenika (broja širokopojasnih priključaka, broja stanovnika, gustoće naseljenosti područja i bruto domaćeg proizvoda po glavi stanovnika) moguće je analizirati aspekte usvajanja širokopojasnog Interneta. Ovo je posebno značajno za područja u kojima trenutno postoji niži stupanj primjene širokopojasnih tehnologija i usluga - u ruralnim područjima. Rezultate takvih analiza zatim je moguće usporediti s rezultatima dobivenima za urbana područja.

Prema pretpostavci, čimbenici koji bi trebali imati značajan utjecaj na povećanje stope usvajanja širokopojasnih tehnologija i usluga su dohodak po stanovniku, prosječna gustoća naseljenosti, obrazovni sastav stanovništva i dobna struktura stanovništva. Ovi su podaci bitni za uvođenje širokopojasnog pristupa Internetu, jer viši dohodak, veća gustoća naseljenosti određenog ruralnog područja, veći udio mladog stanovništva i viši stupanj obrazovanja znače veću vjerojatnost za njegovo uvođenje.

Unatoč brojnim koristima koje proizlaze iz primjene širokopojasnih internetskih tehnologija i usluga, pri provedbi analiza često je prisutan problem predviđanja zainteresiranosti potencijalnih korisnika u ruralnim područjima za primjenom širokopojasnih aplikacija i usluga.

Tada je, uz analizu kvantitativnih čimbenika, potrebno izvršiti i kvalitativnu analizu skupa pokazatelja o potencijalnim krajnjim korisnicima širokopojasnih usluga u ruralnim područjima, kao čimbenika koji omogućuju predviđanje ponašanja potencijalnih krajnjih korisnika širokopojasnog pristupa Internetu. Takve pokazatelje moguće je podijeliti na kulturno-obrazovne, sociološke, psihološke i individualne [9]. Dobiveni rezultati trebali bi omogućiti donošenje kvalitetnijih procjena o zainteresiranosti krajnjih korisnika za primjenom širokopojasnih aplikacija i usluga.

4.2.2. Socio-demografski i tehno-ekonomski čimbenici i usvajanje širokopojsnih tehnologija i usluga

Analize dostupnih podataka imaju za cilj ukazati na utjecaj koji određeni čimbenici imaju na usvajanje internetskih usluga, odnosno usvajanje usluga širokopojsnog pristupa Internetu*. Pri analizama je bitno obuhvatiti što više podataka, pa se razmatraju različiti socio-demografski i ekonomski čimbenici o korisnicima – npr. njihov stupanj obrazovanja, zaposlenost i prihodi te dobna struktura [127], kako je prikazano u tablicama 4.1. i 4.2..

Tablica 4.1. Korisnici Interneta prema radnom statusu [127]

Radni status	Učenici i studenti	Zaposleni	Umirovljenici	Ostali
	[%]	[%]	[%]	[%]
2007.	86	51	27	7
2008.	90	58	28	8
2009.	92	62	39	15
2010.	98	74	41	16
2011.	99	84	58	21
2012.	100	88	58	27

Tablica 4.2. Korisnici Interneta prema dobi [127]


Dob	16-24	25-34	35-44	45-54	55-64	65-74
	[%]	[%]	[%]	[%]	[%]	[%]
2007.	73	54	46	30	14	2
2008.	85	61	50	35	14	4
2009.	83	72	54	37	17	8
2010.	92	84	73	47	22	6
2011.	97	92	80	59	31	11
2012.	98	95	85	64	39	17

Podaci ukazuju na postojanje pozitivnih korelacija između promjena vrijednosti pojedinih čimbenika i ukupnog broja korisnika Interneta, što je moguće objasniti na sljedeći način:

- učenjem se stječe spoznaja o uporabi suvremenih informacijskih tehnologija, a o stupnju izobrazbe ovisi hoće li, te koje će vrste internetskih tehnologija i usluga biti odabrane;
- povoljnije ekonomske prilike zaposlenih povećavaju mogućnost izdvajanja za naknade za korištenje internetskih tehnologija i usluga;
- prihodi uvjetuju mogućnosti i izbor internetskih tehnologija i usluga;
- dob određuje sklonost u preferiranju određenih internetskih tehnologija i usluga.

* Bitno je naznačiti kako se, zbog vrlo malog postotka internetskih korisnika koji koriste *dial-up* i ISDN priključke, broj korisnika širokopojsnog Interneta može približno promatrati kroz ukupni broj korisnika. Prema dostupnim podacima, krajem 2007. godine samo malo više od 10% internetskih korisnika nije imalo širokopojsni pristup, dok je krajem 2011. godine taj postotak iznosio svega 1% .

Analiza preduvjeta za usvajanje širokopojasnog pristupa kroz socio-demografske i ekonomske statističke podatke provodi se uz pretpostavku da viši prihodi po stanovniku, veća gustoća naseljenosti određenog područja, veći udio mladog stanovništva i viši stupanj obrazovanja znače veću vjerojatnost za njegovo usvajanje.



Slika 4.4. Prikaz udjela Internet korisnika prema dobi, zaposlenosti i stupnju obrazovanja te korisnika širokopojasnog pristupa Internetu [127]

Slika 4.4. usporedno prikazuje pozitivan trend, odnosno porast broja korisnika Interneta u pojedinim socio-demografskim i ekonomskim skupinama stanovništva (udio prema dobi, zaposlenosti i stupnju obrazovanja) te porast postotka priključaka širokopojasnog pristupa Internetu po glavi stanovnika u Republici Hrvatskoj u razdoblju od 2007. do 2011. godine [127]. Zbog detaljnije predodžbe i usporedbe, u tablici 4.3. su za isto razdoblje prikazani podaci o postotku kućanstava opremljenih informacijskim i komunikacijskim tehnologijama - računalima, pristupom Internetu te mobilnim telefonima [127]. Vidi se pozitivan trend usvajanja internetskih usluga.

Tablica 4.3. Opremljenost kućanstva informacijskim i komunikacijskim tehnologijama [127]

Opremljenost kućanstva IKT-om	Osobno računalo	Pristup Internetu	Mobilni telefon
	[%]	[%]	[%]
2007.	49	41	77
2008.	53	45	81
2009.	55	50	82
2010.	60	57	-
2011.	64	61	-
2012.	68	66	-

Prema statističkim podacima brojnih objavljenih OECD i EU izvješća, vidljivo je da na razine penetracije širokopojsnih priključaka Internetu ne utječe samo dostupnost širokopojsne pristupne infrastrukture, koja čini osnovni preduvjet za njegovo uvođenje, već je razina penetracije priključaka rezultat potražnje za dostupnim širokopojsnim uslugama [128].

Nadalje, i sama razina kvaliteta dostupnih javnih usluga utječe na razinu usvajanja širokopojsnog pristupa, budući da usluge više kvalitete imaju veću vrijednost za krajnje korisnike usluga, kako je navedeno i u [129] te [130].

U praćenju dostupnosti i razina kvalitete javnih *e*-usluga, *Bangemann*-ovim izvješćem su definirane razine informatiziranosti *e*-usluga, koje se mjere na skali od '0' do '4', pri čemu prikazane razine informatiziranosti opisuju mogući razvoj elektroničkih usluga u Europskoj uniji [131]. Značenje razina informatiziranosti opisano je u tablici 4.4..

Tablica 4.4. Razine informatiziranosti javnih usluga [131]


Razina informatiziranosti:	Značenje:
0 – Nema informacija	Informacija o usluzi nije dostupna na mreži.
1 – Informacija	Na mreži je dostupna samo informacija o usluzi (npr. opis postupka, pravilnici i sl.)
2 – Jednosmjerna interakcija	Dostupnost formulara u elektroničkom obliku za pohranjivanje na računalu. Prazne formulare moguće je i ispisati.
3 – Dvosmjerna komunikacija	Interaktivno ispunjavanje formulara i prijava uz autentikaciju. Ispunjavanjem formulara pokreće se pojedina usluga.
4 – Transakcija	Cijela usluga je dostupna na mreži (popunjavanje formulara, autentikacija, plaćanje i isporuka potvrda, narudžbe ili drugi oblici potpune usluge putem mreže).

U tablici 4.5. se nalazi prikaz dostupnih podataka o razinama informatiziranosti javnih usluga u Republici Hrvatskoj u razdoblju od 2005. do 2008. godine.

Tablica 4.5. Kvaliteta dostupnih javnih usluga [132]

Broj dostupnih javnih usluga prema razinama kvalitete i godinama	0	1	2	3	4	3+4
2005.	17	56	32	5	1	6
2006.	0	27	66	7	7	14
2007.	0	26	55	18	12	30
2008.	0	19	48	15	26	41

S ciljem utvrđivanja korelacija između razina kvalitete dostupnih javnih *e*-usluga te razine penetracije širokopojsnih priključaka Internetu, na slici 4.5. je prikazana usporedba između porasta broja priključaka širokopojsnog Interneta te porasta broja dostupnih javnih *e*-usluga treće i četvrte razine u Republici Hrvatskoj [132]. Prikazani su dostupni podaci za razdoblje od 2005. do 2008. godine*, međutim prikazani trend porasta kvalitete dostupnih javnih usluga i broja korisnika širokopojsnog pristupa se nastavio do danas.



Slika 4.5. Prikaz broja priključaka širokopojsnog Interneta te dostupnih javnih *e*-usluga [132]

Kako je vidljivo sa slike 4.5., postoji pozitivna korelacija između promjene broja dostupnih javnih *e*-usluga viših razina kvalitete te ukupnog broja širokopojsnih priključaka, budući da trend porasta dostupnih javnih *e*-usluga treće i četvrte razine prati trend porasta broja korisnika širokopojsnog pristupa.

* Unutar navedenog perioda postojala je jednoznačna klasifikacija objavljenih podataka, a na temelju navedene klasifikacije podaci su prikazani sumarno za pojedine razine kvalitete.

4.2.3. Regresijska analiza socio-demografskih i tehno-ekonomskih čimbenika i usvajanja širokopojasnih tehnologija i usluga u ruralnim područjima

Uzročno-posljedična veza između razine usvojenosti širokopojasnog pristupa Internetu u kućanstvima te različitih gospodarskih i demografskih čimbenika može se procijeniti primjenom linearnog regresijskog modela. Primjer takvog modela prikazan je sljedećom formulom:

$$PstKuSP_{ix} = \beta_0 + \beta_1 Stan_{ix} + \beta_2 GuNas_{ix} + \beta_3 BDP_{ix} + PstObrStan_{ix} + e_{ix} \quad (4.26)$$

gdje oznaka i prikazuje određeno područje, oznaka x godinu, $PstKuSP$ predstavlja postotak kućanstava sa širokopojasnim pristupom, $Stan_{ix}$ predstavlja ukupan broj stanovnika u regiji, $GuNas_{ix}$ prikazuje gustoću naseljenosti, tj. broj stanovnika na kvadratni kilometar, a BDP_{ix} bruto domaći proizvod po glavi stanovnika. U gornji model moguće je uključiti i varijablu $PstObrStan_{ix}$ koja prikazuje udio stanovništva sa završenom srednjom školom, a postoje i druge varijable koje mogu utjecati na stopu usvajanja širokopojasnog pristupa - broj stanovnika koji upisuje fakultet, broj zaposlenih, stupanj nezaposlenosti, udio starog stanovništva u ukupnom broju stanovnika i dr. Ipak, navedene varijable uključene u model su najdostupnije. Pri provedbi regresijskih analiza potrebno je pripaziti na nekoliko činjenica navedenih u nastavku.

Stopa usvajanja širokopojasnog Interneta često se definira pomoću omjera broja širokopojasnih priključaka i broja stanovnika na određenom području. Međutim, to nije uvijek najprikladnije mjerilo, barem ne u slučaju fiksnog pristupa Internetu, kada većina kućanstava uzima jednu fiksnu vezu koju tada koriste svi članovi unutar kućanstva. Za mobilne bežične širokopojasne tehnologije takvo je mjerilo prikladnije, budući da je manja vjerojatnost da će korisnik mobilnog pristupa dijeliti podatkovni uređaj s ostalim članovima unutar kućanstva.

Pri provođenju postupka regresijske analize, važno je voditi računa o njenim ograničenjima. Kao i u svakoj regresiji, kauzalna interpretacija regresijskih parametara zahtijeva da pogreška, koja se reflektira kroz iznos parametra e_{ix} , bude strogo egzogena, tj. da ne postoji korelacija između regresora i pogreške. Bez postojanja stroge egzogenosti, procijenjeni koeficijenti mogu se, u najboljem slučaju, tumačiti kao uvjetne korelacije između nezavisnih varijabli i

zavisne varijable (npr. postotka kućanstava sa širokopojasnim pristupom u promatranom području). Korelacija između regresora i pogreške, tj. odsustvo stroge egzogenosti, može nastati iz više razloga. Neki od razloga su izostavljanje određenih značajnih varijabli, endogenost ili pogreške mjerenja. Parametarska regresijska analiza je uvijek ograničena dostupnim podacima [133]. Stoga, ovakve analize ne mogu uzeti u obzir druge čimbenike koji također mogu imati značajan utjecaj na ponudu i potražnju za širokopojasnim pristupom. Bilo koji faktor koji nije eksplicitno modeliran u regresiju implicitno je uključen u pogrešku, e_{ix} . Za razliku od parametarske, u neparametarskoj analizi je, uz procjenu vrijednosti parametara, cilj procijeniti i oblik samog regresijskog modela jer se početni model sažima nakon izostavljanja nerelevantnih parametara [133]. Dakle, u slučaju kada su dostupni podaci o velikom broju parametara, moguće je primijeniti neparametarsku analizu u kojoj se značajni parametri određuju u naknadnim koracima analize, dok se ostali parametri izostavljaju bez gubitaka informacije.

Nadalje, pojedine varijable mogu biti endogene varijable u regresijskom modelu. Na primjer, u prikazanom modelu, vrijednost BDP-a po glavi stanovnika u promatranom području može utjecati na uvođenje i usvajanje širokopojasnih usluga, ali dostupnost širokopojasnog pristupa vjerojatno utječe na vrijednost BDP-a po glavi stanovnika, dok na obje varijable utječu i drugi egzogeni faktori. Svaka endogenost između razine usvajanja širokopojasnog pristupa i prihoda dovodi do korelacija između BDP-a i pogreške te do pristranosti u procjeni koeficijenata.

Na posljetku, bitno je utvrditi i jesu li pri analizi varijable u različitim područjima međusobno izravno usporedive. Nezavisne varijable u modelu su i same dobivene procjenom nepoznatih parametara te su uvrštene u izračun skupa s njihovim vlastitim standardnim pogreškama. Sve razlike u definiranju varijabli i tehnikama uzorkovanja u različitim područjima onemogućuju interpretaciju koeficijenata kao uzročne posljedice.

Unatoč navedenim nedostacima, provođenje regresijske analize se pokazalo kao koristan postupak pri određivanju odnosa između stope usvajanja širokopojasnog pristupa i demografskih varijabli iz modela. Tome u prilog govori i činjenica da se u analizi provedenoj u [134], veliki dio razlika u stopama usvajanja širokopojasnog pristupa jednostavno objašnjava primjenom četiriju socio-demografskih varijabli u modelu - brojem stanovnika

(*Stan*), gustoćom naseljenosti (*GuNas*), bruto domaćim proizvodom po glavi stanovnika (*BDP*) i postotkom stanovništva sa završenom srednjom školom (*PstObrStan*).

Gospodarski i demografski podaci uključeni u provedenu analizu [134] prikupljeni su iz OECD-ove baze podataka. Prikazani su podaci za veliki broj država u svijetu. Rezultati su ukazali na postojanje jakih pozitivnih korelacija između stope usvajanja širokopojasnog pristupa i BDP-a po glavi stanovnika te jakih pozitivnih korelacija između stope usvajanja širokopojasnog pristupa i postotka stanovništva sa završenom srednjom školom. Isto vrijedi i za područja s višim dohotkom po stanovniku.

Nadalje, prilikom kreiranja modela potrebno je u obzir uzeti činjenicu da je dostupni skup ulaznih podataka često ograničen. Stoga se prilikom modeliranja najčešće primjenjuju rezultati parametarske regresijske analize nad dostupnim podacima. Primjenjuju se podaci o vrijednostima parametara za koje je pretpostavljeno kako značajno utječu na zavisnu varijablu.

U nastavku rada su, u cilju povećanja točnosti rezultata provedenih regresijskih analiza, izloženi rezultati provedenih linearnih i nelinearnih regresijskih analiza utjecaja socio-demografskih i tehnno-ekonomskih čimbenika na usvajanje širokopojasnog pristupa Internetu u odabranim studijskim primjerima u ruralnim i urbanim područjima.

Budući da se skale promatranih varijabli razlikuju, logaritamski zapis se koristi za točniju procjenu. Takav zapis eliminira razlike u skalama i omogućuje tumačenje rezultata pomoću postotnih promjena regresijskih koeficijenata (za razliku od tumačenja promjena pomoću razlika u iznosima).

4.2.3.1. Studijski primjer: Linearna regresijska analiza utjecaja socio-demografskih i ekonomskih čimbenika na usvajanje širokopojasnih tehnologija i usluga u hrvatskim ruralnim županijama

Provedena je regresijska analiza za područje Republike Hrvatske, točnije za prostor njenih županija (prema podjeli načinjenoj u studijskom primjeru) u cilju analize čimbenika koji imaju značajan utjecaj na povećanje stope usvajanja širokopojasnih usluga - broja stanovnika

(*Pop*), gustoće naseljenosti stanovništva (*GuNas*) i bruto domaćeg proizvoda po glavi stanovnika (*BDP*) u hrvatskim županijama.

Prvi korak pri analizi podataka je prikazivanje dijagrama raspršenja čestica pri korelacijama između stope usvajanja širokopojasnog pristupa Internetu (*PstKuSP*) te triju nezavisnih varijabli - broja stanovnika (*Pop*), gustoće naseljenosti stanovništva (*GuNas*) i bruto domaćeg proizvoda po glavi stanovnika (*BDP*). Primjenom korelacijske analize moguće je utvrditi jakost i smjer statističkih veza između promatranih čimbenika.

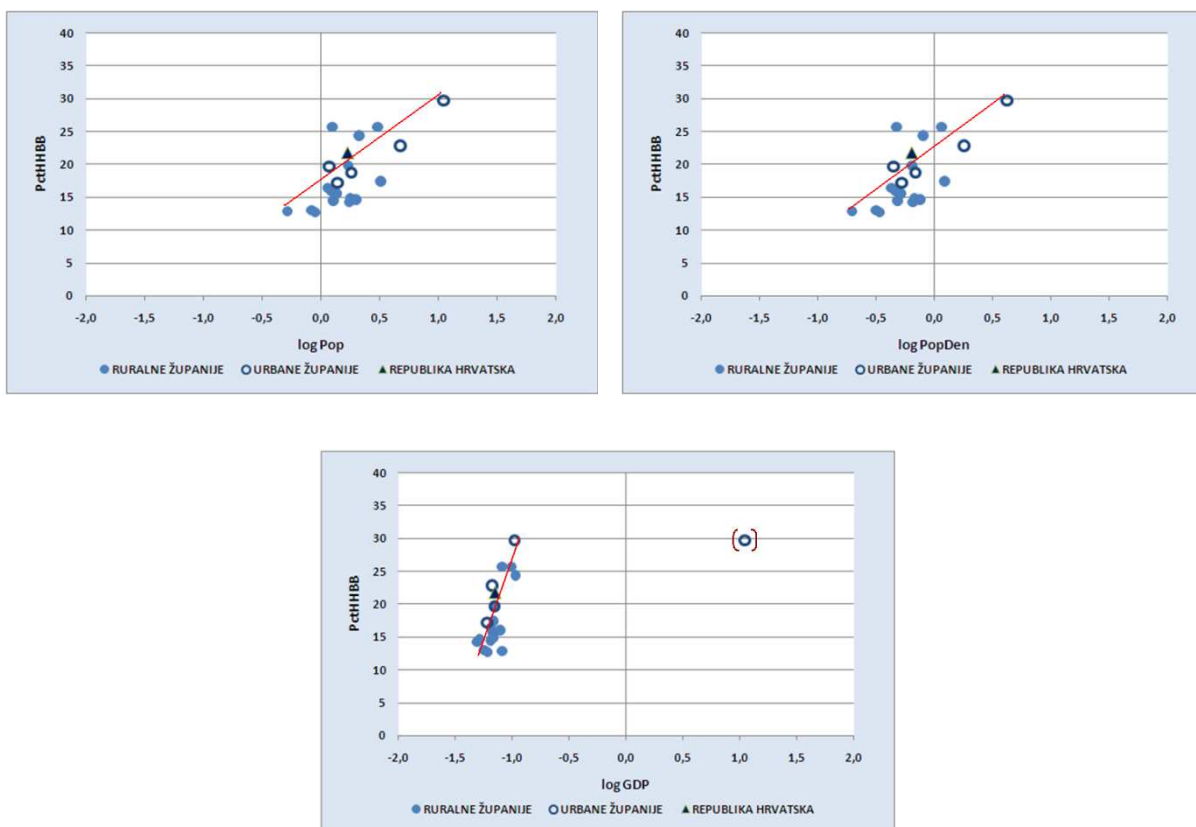
Prema dijagramima prikazanim na slici 4.6. vidljivo je da na svim prikazima postoje pozitivne statističke veze između promatranih čimbenika - postotka kućanstava sa širokopojasnim pristupom Internetu i ukupnog broja stanovnika, postotka kućanstava sa širokopojasnim pristupom Internetu i gustoće naseljenosti te postotka kućanstava sa širokopojasnim pristupom Internetu i bruto domaćeg proizvoda po glavi stanovnika, jer što su veće vrijednosti bilo koje od navedenih nezavisnih varijabli (*Pop*, *GuNas* ili *BDP*) to su veće i vrijednosti zavisne varijable (*PstKuSP*).

Također, vidljive su slabije korelacije između postotka kućanstava sa širokopojasnim pristupom Internetu i ukupnog broja stanovnika te slabije korelacije između postotka kućanstava sa širokopojasnim pristupom Internetu i gustoće naseljenosti.

Vidljivo je i postojanje jakih korelacija između stope usvajanja širokopojasnog pristupa Internetu i bruto domaćeg proizvoda po glavi stanovnika, jer mala povećanja u razinama *BDP*-a po stanovniku uzrokuju velika povećanja stope usvajanja širokopojasnog pristupa Internetu.

Na grafovima su posebno prikazane sve ruralne te sve urbane županije u Republici Hrvatskoj. Vidljive su razlike u nezavisnim čimbenicima - broju stanovnika, gustoći naseljenosti i dohodcima, koji su u ruralnim županijama uglavnom manji u odnosu na one u urbanim županijama.

Iz prikazanog, moguće je zaključiti sljedeće - kada bi ruralne županije dostigle razine dohodaka po stanovniku istovjetne onima (ili veće od onih) u urbanim županijama, povećao bi se i udio kućanstava koja se pretplaćuju na širokopojasni Internet.



Slika 4.6. Dijagrami raspšenja čestica pri korelacijama između stope usvajanja širokopojasnog pristupa Internetu te nezavisnih varijabli - broja stanovnika (*Pop*), gustoće naseljenosti stanovništva (*GuNas*) i bruto domaćeg proizvoda po glavi stanovnika (*BDP*)

4.2.3.2. Analiza rezultata provedene linearne regresijske analize socio-demografskih i ekonomskih čimbenika

U cilju analize čimbenika koji imaju značajan utjecaj na povećanje stope usvajanja širokopojasnih usluga provedena je linearna regresijska analiza utjecaja nekoliko socio-demografskih i ekonomskih čimbenika - broja stanovnika, gustoće naseljenosti stanovništva i bruto domaćeg proizvoda po glavi stanovnika na usvajanje širokopojasnog pristupa u hrvatskim županijama.

Usporedba dohotka po glavi stanovnika u ruralnim i urbanim područja često ukazuje na to da je dohodak po glavi stanovnika u ruralnim područjima niži u odnosu na prosječni dohodak po glavi stanovnika, što pokazuju i rezultati provedene analize.

Nadalje, ruralna područja često imaju nižu gustoća naseljenosti od prosjeka, što je također vidljivo i iz dobivenih rezultata. Ovaj podatak smatra se bitnim jer veći broj potencijalnih krajnjih korisnika širokopojasnog pristupa znači i potencijalno veću isplativost ulaganja u uvođenje širokopojasnih tehnologija.

Udio stanovništva sa završenom srednjom školom bitan je čimbenik analize jer završena srednja stručna sprema često čini preduvjet uspješnog usvajanja i primjene novih tehnologija i usluga. Kako je prikazano i kroz provedenu analizu, u većini ruralnih područja udio stanovnika sa završenom srednjom školom manji je od prosjeka.

Na temelju dobivenih rezultata moguće je zaključiti da, uz stupanj obrazovanja, i dobne skupine statistički doprinose značaju širokopojasnog pristupa. Mladi obrazovani stanovnici, kojih u ruralnim područjima često ima manje, češće koriste pristup Internetu.

4.2.3.3. Studijski primjer: Nelinearna regresijska analiza utjecaja socio-demografskih i tehnno-ekonomskih čimbenika na usvajanje širokopojasnih tehnologija i usluga u hrvatskim ruralnim županijama

S ciljem utvrđivanja prikladnih strategija za poticanje širokopojasnog pristupa Internetu u ruralnim područjima te smanjivanja postojećeg digitalnog jaza [90], razmotreni su najbitniji čimbenici pomoću kojih je moguće objasniti razlike u razinama usvajanja širokopojasnog pristupa Internetu u ruralnim i urbanim županijama.

Podaci koji su korišteni u ekonometrijskoj analizi odnose se na hrvatske županije unutar desetogodišnjeg perioda promatranja, od 2002. do 2011. godine [135]. Oni uključuju prosječni dohodak po glavi stanovnika, prosječnu gustoću naseljenosti područja, određenu obrazovnu i dobnu strukturu stanovništva, udio zaposlenog stanovništva i stanovništva zaposlenog u primarnom sektoru djelatnosti, karakterističnom za ruralna područja. Ovi su podaci bitni budući da utječu na uvođenje širokopojasnog pristupa. Kako bi se dobio što točniji opis, umjesto linearnog modela je primijenjen sljedeći nelinearni regresijski model:

$$\ln(SP_{ix}) = \alpha + \beta_1 \cdot \ln(Dob_{ix}) + \beta_2 \cdot \ln(Obr_{ix}) + \beta_3 \cdot \ln(BDP_{ix}) + \beta_4 \cdot \ln(Zap_{ix}) + \beta_5 \cdot \ln(PrimSek_{ix}) + \beta_6 \cdot \ln(GuNas_{ix}) + \eta_i + e_{ix} \quad (4.27)$$

gdje SP_{ix} prikazuje broj korisnika širokopojasnog pristupa na području i u godini x , Dob_{ix} stanovništvo starosti između 15 i 45 godina, Obr_{ix} stanovništvo koje je završilo srednju školu ili fakultet, BDP_{ix} bruto domaći proizvod po glavi stanovnika, Zap_{ix} zaposleno stanovništvo, $PrimSek_{ix}$ stanovništvo zaposleno u primarnom sektoru djelatnosti karakterističnom za ruralna područja, a $GuNas_{ix}$ gustoću naseljenosti. Konstanta η_i je fiksni čimbenik u pojedinoj državi (engl. *country fixed effect*), a varijabla e_{ix} predstavlja standardnu pogrešku.

Prije provedbe analize, načinjeno je nekoliko polaznih pretpostavki. Prvo, pretpostavljene su pozitivne komplementarnosti između udjela mladog i obrazovanog stanovništva te broja korisnika širokopojasnog pristupa, iskazane redom kroz koeficijente β_1 i β_2 , budući da veći udio mladog i obrazovanog stanovništva povećava vjerojatnost primjene širokopojasnih tehnologija i usluga. Nadalje, pretpostavljena je i pozitivna vrijednost koeficijenta β_3 budući da viši dohodak može odražavati bolju širokopojasnu pristupnu infrastrukturu te platežnu moć korisnika. Također, pretpostavljen je pozitivan utjecaj povećanja udjela zaposlenog stanovništva, β_4 i β_5 , na usvajanje širokopojasnog pristupa. Na posljetku, pretpostavljen je i pozitivan utjecaj veće gustoće naseljenosti na implementaciju širokopojasnog pristupa, β_6 .

Dobiveni rezultati su prikazani u tablici 4.6. posebno za ruralnu te posebno za urbanu skupinu županija. Prema dobivenim rezultatima moguće je zaključiti da u obje skupine povećanje bruto društvenog proizvoda od 1% rezultira približno 10%-tnim povećanjem broja korisnika širokopojasnog pristupa. Nadalje, u ruralnoj skupini županija, 1%-tno povećanje promatranog udjela obrazovne, odnosno dobne strukture stanovništva uzrokuje povećanje broja širokopojasnih priključaka za 7.23%, odnosno 1.27%. Manji, ali ipak pozitivan učinak na usvajanje širokopojasnog pristupa Internetu u ruralnoj skupini županija (0.55%) ima udio stanovništva zaposlenog u primarnom sektoru djelatnosti.

U urbanoj skupini županija, 1%-tno povećanje promatranog udjela obrazovne, odnosno dobne strukture stanovništva uzrokuje povećanje broja širokopojasnih priključaka od 5.28%, odnosno 3.55%, a 1%-tno povećanje udjela stanovništva zaposlenog u primarnom sektoru djelatnosti uzrokuje povećanje broja širokopojasnih priključaka od 4.39%.

Tablica 4.6. Statistički pokazatelji nelinearnog modela

Nelinearna regresija	Ruralne županije	Urbane županije
<i>Procijenjeni koeficijenti:</i>		
ln <i>Dob</i>	1.271	3.547
ln <i>Obr</i>	7.229	5.284
ln <i>BDP</i>	9.942	10.810
ln <i>Zap</i>	-7.875	4.391
ln <i>PrimSek</i>	0.549	-1.492
ln <i>GuNas</i>	-0.497	-4.253
(<i>Konstanta</i>)	(-81.06)	(-92.99)
<i>Statistički pokazatelji:</i>		
Ukupan broj podataka	150	60
Koeficijent determinacije	0.586	0.704

Nadalje, rezultati ukazuju na nekoliko razlika između pojedinih pretpostavljenih te određenih predznaka koeficijenata budući da je u posljednjih desetak godina u Republici Hrvatskoj prisutan trend smanjivanja ukupnog broja stanovnika, a da, unatoč tome, raste ukupan broj korisnika širokopojasnog Interneta.

Tako je, na primjer, u obje grupe utvrđen negativan odnos između gustoće naseljenosti i broja korisnika širokopojasnog pristupa. Ovu činjenicu moguće je objasniti s obzirom na postojeći trend porasta broja korisnika širokopojasnog pristupa, neovisno o negativnom prirastu stanovništva prisutnom u većini hrvatskih županija. Slično vrijedi i za slučaj u ruralnim županijama, gdje je prisutan porast broja korisnika širokopojasnog pristupa neovisno o smanjenju udjela zaposlenih stanovnika s obzirom na opći trend smanjenja zaposlenosti.

Nadalje, u urbanim županijama je zamijećen negativan odnos između udjela zaposlenih u primarnom sektoru i broja korisnika širokopojasnog pristupa, što je moguće objasniti činjenicom kako manji udio stanovništva zaposlenog u primarnom sektoru podrazumijeva veći udio zaposlenih u drugim sektorima djelatnosti, gdje se širokopojasni pristup primjenjuje intenzivnije.

Provedbu empirijske analize implementacije širokopojasnog pristupa otežava činjenica da proces usvajanja širokopojasnog pristupa nije na svim područjima jednakog intenziteta. S obzirom na razlike u trenutku uvođenja širokopojasnog pristupa na različitim prostorima te na

moгуće razlike u čimbenicima koji utječu na stope usvajanja novih tehnologija i usluga u različitim područjima, pri analizi treba uzeti u obzir i podatak o tome koliko su daleko pojedina područja odmakla u procesu usvajanja širokopojasnih usluga.

Prethodno opisani regresijski model ne razmatra trenutno stanje u procesima usvajanja širokopojasnog pristupa. Stoga je, u cilju poboljšanja modela, primijenjen sljedeći model koji uključuje jedan dodatni čimbenik – broj korisnika širokopojasnog pristupa u prethodnom razdoblju (SP_{ix-1}):

$$\ln(SP_{ix}) = \alpha + \beta_1 \cdot \ln(Dob_{ix}) + \beta_2 \cdot \ln(Obr_{ix}) + \beta_3 \cdot \ln(BDP_{ix}) + \beta_4 \cdot \ln(Zap_{ix}) + \beta_5 \cdot \ln(PrimSek_{ix}) + \beta_6 \cdot \ln(GuNas_{ix}) + \beta_7 \cdot \ln(KoSP_{ix-1}) + \eta_i + e_{ix} \quad (4.28)$$


Dobiveni rezultati su prikazani u tablici 4.7.. Rezultati pokazuju da se uključivanjem u model podataka o broju korisnika širokopojasnog pristupa u prethodnom periodu povećava efikasnost modela, prikazana kroz iznos koeficijenta determinacije. Dobiveni koeficijent determinacije ukazuje na postojanje vrlo jakih veza između nezavisnih varijabli i zavisne varijable (SP_{ix}) u promatranim slučajevima. Koeficijent determinacije ima vrijednost 0.925 (ruralne županije), odnosno 0.896 (urbane županije). Dakle, broj korisnika širokopojasnog pristupa Internetu u prethodnoj godini predstavlja jaku odrednicu pri procjeni broja korisnika u tekućoj godini budući da ukupni broj postojećih korisnika utječe na procjenu korisnosti koja proizlazi iz primjene širokopojasnog Interneta.

Tablica 4.7. Statistički pokazatelji dopunjenog nelinearnog modela

Nelinearna regresija	Ruralne županije	Urbane županije
Procijenjeni koeficijenti:		
$\ln Dob$	0.452	1.808
$\ln Obr$	1.094	1.665
$\ln BDP$	1.140	0.358
$\ln Zap$	-0.352	1.316
$\ln PrimSek$	0.047	-0.048
$\ln GuNas$	-0.162	-0.352
$\ln KoSP_{ix-1}$	0.547	0.603
(Konstanta)	(-18.12)	(-17.68)
Statistički pokazatelji:		
Ukupan broj podataka	150	60
Koeficijent determinacije	0.925	0.896

U ovom dopunjenom modelu utjecaj pojedinih čimbenika uključenih u analizu pokazuje slične relacije kao u prethodnom modelu. Analogno je moguće uključiti i veći broj čimbenika kako bi se dobio bolji uvid u najbitnije čimbenike koji utječu na usvajanje širokopojasnog pristupa u različitim tipovima ruralnih područja.

Nadalje, analizirane su razlike između utjecaja pojedinih demografskih i socio-ekonomskih čimbenika na usvajanje širokopojasnog pristupa Internetu. Određivanje razlika između utjecaja različitih čimbenika na usvajanje širokopojasnog pristupa u ruralnim i urbanim županijama omogućuje kreiranje i primjenu odgovarajućih strategija koje bi za cilj trebale imati povećanje broja korisnika širokopojasnog pristupa, odnosno smanjenje postojećeg digitalnog jaza između ruralnih i urbanih županija.



Slika 4.7. Utjecaj socio-demografskih i ekonomskih čimbenika na primjenu širokopojasnog Interneta u ruralnim te urbanim županijama

Na grafovima prikazanim na slici 4.7. prikazan je utjecaj različitih prediktora, tj. socio-demografskih i ekonomskih čimbenika, na usvajanje širokopojasnog pristupa Internetu. Prikazani grafovi pokazuju utjecaj promjene vrijednosti različitih čimbenika (od minimalnih prema maksimalnima) na usvajanje širokopojasnog pristupa. Kružićima su označene prosječne vrijednosti utjecaja svakog pojedinog čimbenika. Horizontalne linije prikazuju interval pouzdanosti za pojedine čimbenike. Prikazane vrijednosti su određene za svaki pojedini čimbenik dok su iznosi ostalih čimbenika fiksno postavljeni na prosječne vrijednosti.

Prikazane prosječne vrijednosti pokazuju kako najveću vrijednost na usvajanje širokopojasnog pristupa u ruralnoj skupini županija ima zaposlenost, nakon čega slijedi

obrazovanje, pa dohodak. U ruralnoj skupini županija najutjecajniji čimbenik je dohodak po glavi stanovnika, nakon čega slijede obrazovna i dobna struktura stanovništva te zaposlenost.

Za razliku od toga, najmanje značajni čimbenici u obje skupine županija su primarni sektor djelatnosti te gustoća naseljenosti područja. Na kraju, moguće je zaključiti kako najčešće razmatran čimbenik u analizama implementacije širokopojasnog pristupa – gustoća naseljenosti područja nije među najznačajnijim čimbenicima niti u jednoj od skupina.

Za razliku od najučestalijih pretpostavki vezanih uz određivanje preduvjeta i najutjecajnijih čimbenika na implementaciju širokopojasnog pristupa, rezultati provedene analize pokazuju kako gustoća naseljenosti nije jedan od njih niti u urbanim, niti u ruralnim područjima.

4.2.3.4. Analiza rezultata provedene nelinearne regresijske analize socio-demografskih i tehno-ekonomskih čimbenika

S ciljem povećanja točnosti rezultata provedene linearne analize, provedena je nelinearna regresijska analiza utjecaja socio-demografskih i tehno-ekonomskih čimbenika na usvajanje širokopojasnog pristupa u hrvatskim županijama u svrhu utvrđivanja prikladnih strategija za poticanje širokopojasnog pristupa Internetu u ruralnim područjima te smanjivanja postojećeg digitalnog jaza. Razmotreni su najbitniji čimbenici pomoću kojih je moguće objasniti razlike u razinama usvajanja širokopojasnog pristupa Internetu u ruralnim i urbanim područjima. Određivanje razlika između utjecaja različitih čimbenika na usvajanje širokopojasnog pristupa u ruralnim i urbanim područjima utječe na kreiranje i primjenu odgovarajućih strategija koje bi za cilj trebale imati povećanje broja korisnika širokopojasnog pristupa, odnosno smanjenje postojećeg digitalnog jaza između ruralnih i urbanih područja. Ovakva analiza provodi se uz uvažavanje činjenice da se iste razvojne strategije ne mogu primjenjivati i na ruralna i na urbana područja, kako je navedeno i u [136].

Provedbu empirijske analize implementacije širokopojasnog pristupa otežala je činjenica da proces usvajanja širokopojasnog pristupa nije na svim područjima jednakog intenziteta. S obzirom na razlike u trenutku uvođenja širokopojasnog pristupa na različitim prostorima te na moguće razlike u čimbenicima koji utječu na stope usvajanja novih tehnologija i usluga u

različitim područjima, pri analizi je potrebno uzeti u obzir i podatak o tome koliko su daleko područja odmakla u procesu usvajanja širokopojasnih usluga. Stoga je, u cilju poboljšanja modela, naknadno primijenjen model koji uključuje dodatni čimbenik – broj korisnika širokopojasnog pristupa u prethodnom razdoblju, koji je povećao preciznost procjena.

S obzirom na dobivene rezultate moguće je, na primjer, uočiti kako se zbog važnosti utjecaja obrazovanja na uvođenje širokopojasnog pristupa u ruralnim područjima treba potaknuti daljnje informatičko opismenjavanje stanovništva. Navedeno je u skladu i s rezultatima analize provedene u [137], gdje je istaknuto kako, s obzirom na nižu razinu digitalne pismenosti stanovnika u ruralnim područjima, u ruralnim područjima postoji i niža razina percepcije o korisnosti širokopojasnih usluga nego u urbanim područjima.

Isto tako je, zbog važnosti iznosa dohotka po glavi stanovnika, moguće zaključiti da je u ruralnim područjima potrebno posebnu pažnju posvetiti određivanju prikladnih iznosa cijena širokopojasnih usluga, te bi one trebale biti u skladu sa prihodima potencijalnih krajnjih korisnika u ruralnim područjima.

Zaključno, potrebno je istaknuti kako je u cilju zatvaranja postojećeg digitalnog jaza koji postoji između ruralnih i urbanih područja, potrebno razmotriti dobivene rezultate ekonometrijskih analiza kako bi se mogle primijeniti prikladne strategije za daljnje poticanje usvajanja širokopojasnog pristupa Internetu, nakon čega je moguće uskladiti ponudu širokopojasnih usluga s interesima i mogućnostima korisnika te specifičnostima pojedinih ruralnih područja. Navedeno je u skladu s rezultatima analize provedene u [138], koji ukazuju na činjenicu da u slučaju kada se zanemare socio-ekonomski i demografski čimbenici te dostupnost širokopojasne pristupne infrastrukture, ne postoje nikakve razlike između vjerojatnosti usvajanja širokopojasnog pristupa Internetu u ruralnim i urbanim područjima.

Upravo su dobiveni rezultati ukazali na potrebu kreiranja novog okvira tehno-ekonomskog modela za vrednovanje širokopojasnog pristupa Internetu, koji bi trebao uključivati analizu najbitnijih čimbenika koji utječu na uvođenje širokopojasnog pristupa Internetu u ruralnim područjima te u obzir uzeti zahtjeve potencijalnih krajnjih korisnika širokopojasnog Interneta kako bi se potakla značajnija primjena širokopojasnih usluga.

4.2.4. Problemi pri provedbi regresijskih analiza čimbenika

Kako bi se postupak provedbi regresijskih analiza izvodio ispravno potrebno je u obzir uzeti i postojeća ograničenja regresijskih analiza. Provedbu regresijske analize usvajanja širokopojasnog pristupa Internetu otežava nekoliko činjenica. Prva činjenica koja otežava analizu vezana je uz međusobnu usporedivost podataka. Primjerice, širokopojasni pristup Internetu moguće je uvoditi kroz različite platforme - preko telefonske mreže, kabelske mreže, optičke mreže, elektroenergetske mreže, mobilne ili fiksne radijske mreže, te putem satelita. Sve ove platforme nude širokopojasne usluge koje se razlikuju u nekim bitnim karakteristikama, kao što su maksimalne moguće raspoložive brzine prijenosa podataka ili podržavanje mobilnosti korisnika. Osim toga, isti operator može ponuditi pakete širokopojasnih usluga koji se mogu razlikovati u pogledu maksimalnih brzina ili maksimalnih količina podataka uključenih u paket. Te različite karakteristike usluga utječu na spremnost korisnika za izdvajanjem određenih iznosa za mjesečne naknade te u posljedku na ukupan broj korisnika koji će se odlučiti na uvođenje pojedinih usluga.

Iduća činjenica koja otežava empirijsku analizu prikupljenih podataka, istaknuta u [139], je činjenica da nije točno određeno da li korisnici širokopojasnog Interneta fiksne i mobilne tehnologije smatraju nadomjesnim tehnologijama ili mobilni pristup smatraju suplementarnim pristupom fiksnom pristupu, kako je navedeno u [140]. Dakle, analiza usvajanja širokopojasnog pristupa je dodatno posložena činjenicom da se mnogi korisnici pretplaćuju na obje tehnologije. Primjerice, ako veći broj korisnika koristi i fiksne i mobilne širokopojasne usluge, ovisno o primijenjenom načinu mjerenja, procijenjeni postotak usvojenosti širokopojasnih usluga može dostići (ili čak prijeći) sto posto, iako se mnogi korisnici ne pretplaćuju niti na jednu vrstu širokopojasnih usluga.

Ove činjenice upućuju na to da je, u slučaju provođenja preciznije empirijske analize čimbenika koji utječu na potražnju i ponudu širokopojasnog pristupa Internetu, korisno imati usporedive, detaljne te grupirane podatke.

Navedeni podaci trebaju uključivati:

- detaljne demografske podatke (o prihodima, obrazovanju, informatičkoj pismenosti stanovništva, posjedovanju računala i prosječnoj veličini kućanstava) grupirane prema područjima;

- podatke za procjenu troškova implementacije različitih širokopojasnih tehnologija;
- podatke koji prikazuju implementirane alternativne širokopojasne tehnologije na promatranim područjima (prikaz različitih tehnologija širokopojasnog pristupa, broja pružatelja koji nude širokopojasni pristup te raspoložive pristupne brzine);
- postojeći broj pretplatnika različitih širokopojasnih usluga (u slučaju različitih paketa usluga, definirane pristupne brzine te vrste aplikacija koje se koriste);
- podatke o cijenama usluga širokopojasnog pristupa Internetu.

Kako bi se poboljšao postupak prikupljanja podataka koji se koriste u empirijskim analizama danas su u Europi donijete brojne preporuke. One uključuju razvrstavanje prikupljenih podataka prema zemljopisnim područjima, brzinama, broju konkurentskih operatora na tržištu i vrsti tehnologija (fiksne i mobilne, žične i bežične). Nadalje, odnose se na prikupljanje podataka o obrazovanju, prihodima, starosti stanovništva i tipu kućanstava te stupnju urbaniziranosti promatranog područja. Preporuke nastoje omogućiti lakšu usporedbu podataka te provedbu strožih empirijskih analiza.

4.3. Analiza čimbenika bitnih operatorima pri odlučivanju o uvođenju širokopojasnog pristupa u ruralnim područjima

Opći interes svih sudionika na telekomunikacijskim tržištima trebao bi biti uvođenje širokopojasnih mreža posvuda. Međutim, promicanje razvoja brzih širokopojasnih komunikacijskih mreža u ruralnim područjima često ne daje dovoljno dobre rezultate budući da je u takvim područjima isplativost ulaganja u širokopojasni pristup često minimalna.

Kako je već navedeno, na konačnu isplativost ulaganja u širokopojasni pristup utječe mnoštvo čimbenika. Određivanjem kritičnih čimbenika za investiranje u širokopojasni pristup u ruralnim područjima iz perspektive mrežnih operatora bavi se magistarski rad [141]. Provedena istraživanja u sklopu navedenog rada daju bitne informacije namijenjene razumijevanju i unaprjeđivanju ulaganja u širokopojasni pristup u ruralnim područjima. Navedeno istraživanje definira kritične čimbenike pri ulaganju u širokopojasni pristup u ruralnim područjima iz perspektive različitih tipova mrežnih operatora. Istraživanje se zasniva na podacima prikupljenima intervjuiranjem operatora. U istraživanju se međusobno

nadopunjuju kvalitativna metoda intervjua i kvantitativna metoda primjene kreiranih tehnno-ekonomskih modela. Rezultati istraživanja ukazuju na ključne čimbenike bitne operatorima koji ulažu u širokopojasni pristup u ruralnim područjima, navedenih redom.

Kao prvo, u radu je navedeno kako u ruralnim područjima ulaganja u širokopojasni pristup moraju biti koordinirana s glavnim strategijama operatora. Koordinacija mora biti prisutna na svim razinama, kao što su zemljopisna obilježja i lokacija razmatranog područja, način poslovanja, cijene i planovi operatora. Nadalje, koordinacija je potrebna i pri definiranju isplativosti te ciljane isplativosti subvencioniranih projekata. Potencijal isplativosti projekata je glavni razlog za ograničavanje investicija, čak i u slučaju mogućeg korištenja javnih subvencija. Razlike u aktivnostima operatora mogu se djelomično objasniti različitim definicijama isplativosti različitih operatora. U praksi, definiranje isplativosti kroz mjere kao što su očekivano vrijeme povrata ulaganja i stopa povrata, omogućuju operatorima definiranje isplativih investicija. Projekti imaju ograničenu potencijalnu dobit, stoga se definicija isplativosti operatorima mora uklopiti u definirane granice.

Kao drugo, navedeno je kako zbog slabe naseljenosti ruralnih područja penetracije širokopojasnih priključaka obično moraju dostići pedesetak posto ukupnog broja stanovnika u ruralnim područjima u kojima se žele vratiti sredstva uložena u širokopojasni pristup. Dakle, razina penetracije je drugi značajan razlog za razlike u aktivnostima operatora u ruralnim područjima. Različite razine penetracije se mogu objasniti kroz različite razine cijena te različitu namjenu priključaka u subvencioniranim projektima.

Na posljertku, kao treće, navedeno je da je za ulaganja u širokopojasni pristup u ruralnim područjima nužno uključivanje općina i lokalnih zajednica. Nedostatak njihove aktivnosti obično rezultira slabim prodorom tehnologije u ruralnim područjima. Svi operatori slažu se oko važnosti uloge lokalne zajednice u subvencioniranju projekata, provođenju ispitivanja tržišta, podržavanju izgradnje i pomoći pri planiranju mreže te promoviranju širokopojasnih usluga.

Dobiveni rezultati istraživanja potvrđuju opravdanost podjele operatora na tipove na temelju njihovih karakteristika. Upravo navedene razlike utječu na operatorovu odluku o uključivanju ili ne uključivanju u subvencionirane projekte uslijed izazova koje takvi projekti nose.

4.4. Analiza troškova i koristi od uvođenja širokopojasnog pristupa Internetu u ruralnim područjima

Nakon odabira najbolje opcije između mogućih opcija te utvrđivanja isplativosti projekta, potrebno je ispitati i njegovu održivost. U tu svrhu provodi se kvantificiranje i vrednovanje troškova i koristi projekta. Propisi Europske komisije za veće projekte zahtijevaju analizu troškova i koristi. Analiza troškova i koristi treba istaknuti glavne socijalne i ekonomske ciljeve na koje projekt utječe. U pojedinim se slučajevima koristi i troškovi mjereni novcem razlikuju od privatnih vrijednosti i interesa, pa je potrebno detaljno definirati jesu li ukupne dobiti koje proizlaze iz projekta veće od ukupnih troškova.

Brojne koristi projekta vezanih s infrastrukturnim ulaganjima, mogu biti korisne i pojedincima koji nisu direktno povezani s projektom. Dakle, koristi se mogu odnositi na direktne korisnike određenih proizvoda i usluga, ali i na strane kojima nisu bile namijenjene.

Svrha analize troškova i koristi širokopojasnog pristupa Internetu u ruralnim područjima je procjena eksternih troškova i koristi pri njegovom uvođenju, pri čemu se smatra da je ulaganje u širokopojasni pristup Internetu opravdano ukoliko su ukupne društvene koristi veće od ukupnih troškova.

Na dostupnost širokopojasnog pristupa Internetu utječu brojni čimbenici, među kojima su i troškovi njegovog uvođenja, koji su u ruralnim područjima iz nekoliko razloga viši od onih u urbanim područjima. Jedan od razloga viših troškova u ruralnim područjima moguće je objasniti činjenicom da su udaljenosti korisnika od mjesta pristupa mreži (tj. od lokalne centrale, odnosno, od bazne stanice) u ruralnim područjima često veće nego što je to slučaj u urbanim područjima, pa su nužni dodatni izdaci za veze koje se koriste za povezivanje u srednjoj milji. Osim toga, budući da su širokopojasne tehnologije često ovisne o skupim platformama koje poslužuju do nekoliko stotina priključaka, u ruralnim se područjima, zbog manjeg broja korisnika po pristupnoj platformi, često ne može ostvariti isti ekonomski omjer isplativosti uvođenja određene širokopojasne tehnologije kao u urbanim područjima. Stoga raste i cijena širokopojasnog pristupa. Isto tako, u ruralnim područjima nepristupačni tereni često predstavljaju dodatne izazove postavljanju mrežne infrastrukture, koju je tada potrebno dodatno prilagoditi, što često iziskuje dodatne izdatke.

Analiza čimbenika o kojima ovisi mogućnost i isplativost uvođenja širokopojasnog Interneta, ukazuje i na korisnost širokopojasnog pristupa Internetu. Ovisno o promatranom tipu korisnika, koristi se mogu podijeliti u nekoliko kategorija [142].

Prva kategorija obuhvaća izravne koristi koje od uvođenja širokopojasnog pristupa Internetu imaju privatni korisnici, poput bržeg pristupa Internetu potrebnog mnogim aplikacijama koje zahtijevaju širokopojasne kapacitete pri prijenosu podataka. Nadalje, uvođenje širokopojasnog pristupa Internetu može pozitivno djelovati i na dohodak po glavi stanovnika, tj. korisnika, jer povećanje prihoda gospodarskih subjekata u ruralnim područjima temeljeno na povećanju obujma i kvalitete njihove djelatnosti, rezultira povećanjem proizvodnosti rada, broja radnih mjesta i prihoda zaposlenih.

Druga kategorija je vezana uz koristi koje od širokopojasnog pristupa imaju poslovni korisnici, poput povećanja proizvodnosti [143]. Tvrtke koje koriste širokopojasne komunikacijske usluge pri proizvodnom procesu, povećavaju ukupnu proizvodnost. Pri tome neke tvrtke imaju jako veliku korist, dok kod drugih korist može biti zanemariva. Posebno značajno povećanje proizvodnosti, povećanje količine učinka proizvodnje u jedinici vremena, vezano je uz proces kreiranja i stvaranja određenih proizvoda i usluga, pri čemu ušteda vremena ima vrlo bitnu ulogu. Na sličan način, širokopojasni pristup Internetu poslovnim korisnicima pruža neograničene mogućnosti njegove primjene u nizu aktivnosti koje mogu pomoći pri stvaranju kvalitetnog proizvoda, tržišno prihvatljive cijene, prodaje i distribucije proizvoda primjerene potrebama korisnika. Nadalje, širokopojasni Internet omogućuje i brzo i učinkovito komuniciranje, pri čemu su informacije pregledne, troškovi niži, a time je značenje širokopojasnog Interneta, kao tehnološke platforme elektroničkog poslovanja, veće.

Posljednja kategorija je vezana uz mrežne eksternalije, poput povećanja kvalitete usluga postojećim korisnicima širokopojasnih usluga. Dakle, povećanje broja novih kućanstava koja se priključuju na određenu mrežu, donosi koristi postojećim korisnicima te mreže. Oni tada mogu komunicirati s većim brojem korisnika, iako ne sudjeluju u troškovima za priključenje novih kućanstava.

5. TEHNO-EKONOMSKI MODEL ZA UVOĐENJE ŠIROKOPOJASNOG PRISTUPA INTERNETU U RURALNIM PODRUČJIMA

Zbog brojnih specifičnosti ruralnih područja uvođenje širokopojasnog pristupa u tim je područjima potrebno posebno razmotriti. Stoga je potrebno definirati tehno-ekonomski model čiji se fokus treba staviti na razmatranje uvođenja širokopojasnog pristupa Internetu u ruralnim područjima. Takvim modelom potrebno je povezati potrebe korisnika u ruralnim područjima i interese mrežnih operatora, što bi trebalo rezultirati većom primjenjivošću i dostupnošću širokopojasnog Interneta u ruralnim područjima.

Kako je pokazano i rezultatima brojnih provedenih tehno-ekonomskih analiza navedenima u trećem poglavlju rada, uvođenje širokopojasnog pristupa Internetu u ruralnim područjima nije uvijek isplativo. Stoga bi definiranje navedenog tehno-ekonomskog modela trebalo pomoći pri smanjivanju rizika vezanog uz izbor te mogućnost implementacije pojedinih širokopojasnih pristupnih rješenja u različitim tipovima ruralnih područja, a njihove specifičnosti uključiti u postupak modeliranja.

Model se treba temeljiti na teorijskim i metodološkim osnovama koje su rezultat brojnih provedenih istraživačkih projekata vezanih uz tehno-ekonomske postupke te na prethodno prezentiranim rezultatima provedenih regresijskih analiza ključnih čimbenika za uvođenje širokopojasnog pristupa Internetu u ruralnim područjima koji omogućuju vrednovanje uvođenja širokopojasnog pristupa Internetu u ruralnim područjima iz perspektive potencijalnih krajnjih korisnika i mrežnih operatora, kako je opisano u četvrtom poglavlju.

5.1. Razmatrana problematika i prijedlog tehno-ekonomskog modela za uvođenje širokopojasnog pristupa Internetu u ruralnim područjima

Različite metode tehno-ekonomskog modeliranja od devedesetih godina prošlog stoljeća koristile su se za analizu i usporedbu tehničkih mogućnosti i ekonomske opravdanosti uvođenja različitih širokopojasnih pristupnih rješenja. Kroz brojne projekte analizirani su različiti aspekti uvođenja širokopojasnih mreža i usluga na različitim tržištima. Provedene

analize međusobno su se razlikovale ovisno o primijenjenim metodama te ovisno o analiziranim aspektima koji su se stavljali u fokus istraživanja, kako je detaljnije opisano u trećem poglavlju rada. U literaturi vezanoj uz područje istraživanja analizirana je problematika uvođenja širokopojasnog pristupa Internetu, primijenjenih tehno-ekonomskih postupaka i metoda. Razmotrena su brojna otvorena pitanja i problemi poput onih navedenih u tablici 5.1..

Tablica 5.1. Razmatrana problematika i prijedlozi za njeno rješavanje

<i>Problemi:</i>	<i>Prijedlozi rješenja:</i>
Nepostojanje određenih pravila za primjenu tehno-ekonomskih postupaka vrednovanja uvođenja širokopojasnog pristupa Internetu.	Definiranje smjernica za provedbu tehno-ekonomskih postupaka: - odgovor na pitanje “ <i>KAKO?</i> ” provoditi tehno-ekonomske postupke [23].
Modeliranje tržišta i predviđanje broja korisnika novih telekomunikacijskih usluga.	Analiza postojećih modela i primjena novog modela za predviđanje: - odgovor na pitanje “ <i>POMOĆU ČEGA?</i> ” odnosno koje metode koristiti pri modeliranju tržišta i predviđanju difuzije [27].
Izbor optimalnih strategija za operatore koji pružaju širokopojasni pristup u konkurentskim tržišnim okruženjima	Primjena teorije igara u tehno-ekonomskim modelima: - odgovor na pitanje “ <i>ŠTO?</i> ” od mogućih strategija odabrati u konkurentskom okruženju [144].
Definiranje najboljeg trenutka za ulaganje u širokopojasni pristup.	Uvođenje realnih opcija u modele: - odgovor na pitanje “ <i>KADA?</i> ” ulagati u širokopojasni pristup Internetu [82].
Brojni rizici pri ulaganju u širokopojasni pristup.	Definiranje osnovnih rizika pri ulaganju u širokopojasni pristup: - odgovor na pitanje “ <i>GDJE?</i> ” ulagati u širokopojasni pristup [141].
Različiti sudionici na tržištima širokopojasnog pristupa – ispreplitanje njihovih uloga i odnosa.	Modeliranje industrijskih arhitektura u tehno-ekonomskim modelima: - odgovor na pitanje “ <i>TKO?</i> ” ulaže u širokopojasni pristup Internetu (određivanje uloga različitih sudionika) [19].


Zbog specifičnosti ruralnih područja uvođenje širokopojasnog pristupa u tim je područjima potrebno posebno razmotriti. U ovom radu je predložen novi tehno-ekonomski model zasnovan na teorijskim i metodološkim osnovama koje su rezultat provedenih istraživačkih

projekata navedenih u trećem poglavlju rada vezanih uz tehno-ekonomske postupke. Fokus kreiranog tehno-ekonomskog modela predloženog u ovom radu stavljen je upravo na razmatranje uvođenja širokopojasnog pristupa Internetu u ruralnim područjima, područjima u kojima uvođenje širokopojasnog pristupa nije uvijek isplativo. Za razliku od drugih modela, ovaj model uključuje dodatni okvir pomoću kojeg se definira odgovor na pitanje “*NA KOJI NAČIN?*” ulagati u širokopojasni pristup Internetu u ruralnim područjima.

Uslijed ubrzanog razvoja različitih širokopojasnih rješenja koja omogućuju širokopojasni pristup Internetu u ruralnim područjima, sama tehnička superiornost pojedinih tehnologija ne garantira njihov uspjeh na tržištu, kako je istaknuto i u [145] te [146]. Stoga je predložen tehno-ekonomski model koji uključuje i interese potencijalnih krajnjih korisnika u ruralnim područjima. Dodatni okvir u modelu omogućuje donošenje odluka o uvođenju širokopojasnog pristupa u ruralnim područjima nakon razmatranja odgovarajućih kriterija. Ovi kriteriji opisuju definirane zahtjeve i potrebe korisnika, koji se zatim modeliraju i unose u tehno-ekonomski model, nakon čega se utvrđuje isplativost uvođenja odabranog širokopojasnog pristupnog rješenja.

Dakle, predloženim modelom se povezuju i razmatraju mogućnosti i potrebe korisnika u ruralnim područjima te interesi mrežnih operatora, što bi, prema pretpostavci zasnovanoj na rezultatima istraživanja [19], trebalo rezultirati većom primjenjivošću i dostupnošću širokopojasnog Interneta u ruralnim područjima. Okvir se dodaje na osnovni tehno-ekonomski model, opisan u [19].

Pri provođenju tehno-ekonomskih analiza isplativosti uvođenja širokopojasnih pristupnih rješenja u ruralna područja treba vodi računa i o činjenici da postoje bitne razlike i između različitih ruralnih područja te da ih se ne može sve promatrati na isti način. Uslijed specifičnosti i brojnih međusobnih razlika među ruralnim područjima, nedostaje prikladan model koji bi trebao dati smjernice za optimalan izbor poslovnih modela za implementaciju širokopojasnog pristupa u različitim tipovima ruralnih područja. Predloženi model trebao bi pomoći prilikom smanjivanja rizika vezanog uz izbor te mogućnost implementacije pojedinih širokopojasnih rješenja u različitim tipovima ruralnih područja budući da se specifičnosti pojedinih područja uključuju u modeliranje kroz kriterije definirane unutar okvira.



Slika 5.1. Prijedlog tehno-ekonomskog modela s dodatnim okvirom

5.2. Tehno-ekonomski model koji se temelji na okviru za vrednovanje uvođenja širokopojasnog pristupa Internetu u ruralnim područjima

Predloženi tehno-ekonomski model, prikazan na slici 5.1., namijenjen je za analizu dostupnih podataka i izvođenje simulacija, čiji rezultati omogućuju predviđanje, donošenje odluka o ulaganju, optimizaciju te kontrolu rizika pri ulaganju u širokopojasni pristup u ruralnim područjima. Model pruža uvid u kritične čimbenike koji utječu na rizik pri ulaganju u širokopojasni pristup i procjenjuje vjerojatnost ostvarivanja definiranih ciljeva. Olakšava donošenje strateških odluka kako bi se ostvarili postavljeni ciljevi te kako bi se postigla prednost u odnosu na konkurenciju čak i u neizvjesnim konkurentskim uvjetima. Model je namijenjen za tehničko planiranje i modeliranje širokopojasnih pristupnih mreža, predviđanje troškova i analizu rizika ulaganja, a u obzir uzima i nesigurnost pri određivanju ulaznih parametara modela. Izbor širokopojasnih pristupnih tehnologija koje su uključene u kreirani model se zasniva na rezultatima provedenih usporednih analiza isplativosti različitih pristupnih rješenja, opisanih u petom poglavlju rada. Kako bi bila moguća usporedba isplativosti različitih vrsta pristupnih rješenja, u kreiranim scenarijima su odabrane tehnologije predstavnici za svaku od sljedećih skupina tehnologija: za fiksne žične – ADSL, za fiksne bežične – WiMAX, a za mobilne bežične – LTE.

Ključni dio modela je dodatni okvir koji omogućuje analizu postojećih potreba i zahtjeva krajnjih korisnika, na temelju kojih se zatim vrši daljnje planiranje pristupnih mreža te određivanje najboljih poslovnih modela i strategija za operatore. Predloženi okvir definira analizu dostupnih podataka o krajnjim korisnicima i ispitivanje zahtjeva krajnjih korisnika, kao bitne domene istraživanja nužne za pružanje potrebnih unosa u tehno-ekonomski model. Dakle, za razliku od rezultata analiza podataka o krajnjim korisnicima provedenima npr. u [101], [28] i [102], rezultati dobiveni analizama koje se vrše unutar okvira izravno se dalje uključuju u postupak tehno-ekonomskog modeliranja. Isto tako, za razliku od analiza provedenih u [101], [28] i [102], bitno je napomenuti i da se u provedene analize unutar okvira uključuju i podaci o korisnicima koji su karakteristični za ruralna područja (npr. primarni sektor djelatnosti).

Model se sastoji od skupa funkcija, od kojih svaka koristi niz ulaznih i izlaznih varijabli te jedne funkcije koja poziva ostale. Unutar funkcija koje pripadaju pod dodani okvir provodi se regresijska analiza socio-demografskih i tehno-ekonomskih čimbenika te se određuju iznosi koeficijenta korelacije između pojedinih čimbenika i vrijednosti izlazne varijable, ukupnog broja korisnika širokopojasnog Interneta. Koeficijenti korelacije prikazuju stupanj do kojeg se čimbenici i promatrana izlazna varijabla mijenjaju zajedno. U okviru se čimbenici sortiraju od najutjecajnijih prema najmanje bitnima. Ukoliko pojedini čimbenik i predviđena vrijednost imaju visok koeficijent korelacije, promjene vrijednosti čimbenika su značajno povezane s promjenom broja korisnika. Dok pozitivni koeficijenti ukazuju na to da je povećanje vrijednosti pretpostavki povezano s povećanjem iznosa predviđene vrijednosti, negativni koeficijenti ukazuju na suprotno. Što je veća apsolutna vrijednost koeficijenta korelacije, veća je osjetljivost izračunate vrijednosti. Ostale funkcije u modelu slijedno prate pojedine etape koje se koriste za tehno-ekonomsko modeliranje, objašnjene u trećem poglavlju rada.

U modelu se koristi i analiza osjetljivosti kako bi se utvrdilo u kojoj mjeri odgovarajuće pretpostavke opisane ulaznim parametrima utječu na izračunatu predviđenu vrijednost rezultata. Grafički prikaz osjetljivosti pruža mogućnost brzog i jednostavnog određivanja utjecaja svake od pretpostavki na konačan rezultat. Tako na primjer, u navedenom okviru grafikoni dobiveni uz primjenu Matlab *rstool* funkcije pokazuju osjetljivost izlazne varijable, tj. broja korisnika, na promjenu pojedinih ulaznih varijabli, tj. analiziranih čimbenika. Kroz simulacije se rezultati računaju postupkom ponovnog biranja vrijednosti iz razdioba

vjerojatnosti neizvjesnih varijabli. Scenariji se zasnivaju na procijenjenim rasponima vrijednosti ulaznih parametara. Tradicionalne metode u kojima se vrši istovremena promjena samo po jedne vrijednosti parametra u modelu ne omogućuje istraživanje cijelog skupa mogućih ishoda. Budući da takva analiza uvijek rezultira jednom procjenom, takve procjene ukazuju na ono što je moguće, ali ne ukazuju na to što je vjerojatno. U svrhu generiranja niza vrijednosti za definirane pretpostavke, načinjeni model koristi *Monte Carlo* simulacije. Kroz primjenu *Monte Carlo* simulacija predviđa se cijeli raspon mogućih rezultata za svaki pojedini scenarij. Za svako predviđanje pamte se rezultati te je i nakon stotina ili tisuća napravljenih pokusa moguće dobiti uvid u vrijednosti rezultata, statističke parametre (poput prosječnih predviđenih vrijednosti rezultata) te vjerojatnost pojave svake pojedine vrijednosti rezultata. Također, prikazuje se i učestalost pojave istih rezultata, pa je moguće odrediti vjerojatnosti dobivanja bilo kojeg rezultata odabranog iz izlaznog skupa rezultata.

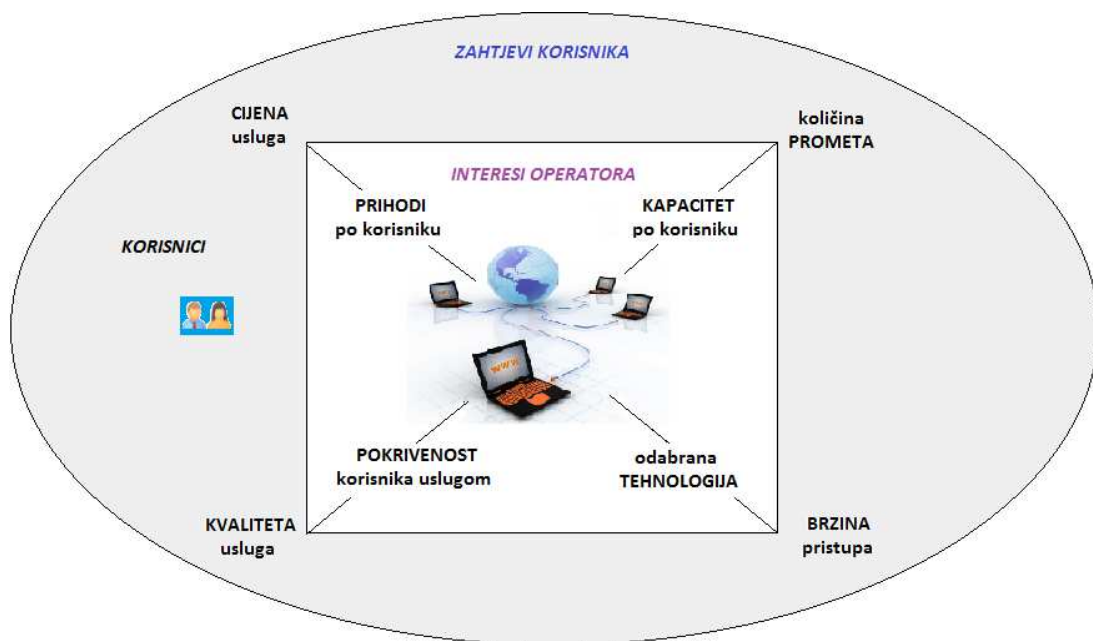
Grafički prikaz učestalosti, odnosno frekvencija pojavljivanja predviđenih vrijednosti rezultata - neto sadašnjih vrijednosti i iznosa subvencija, grupira izlazne vrijednosti rezultata simulacija u određeni broj intervala, kako bi se izlazne podatke što jednostavnije moglo iščitati. Vrijednosti na apscisi prikazuju raspon dobivenih vrijednosti rezultata, dok vrijednosti na ordinati prikazuju učestalost pojavljivanja grupiranih rezultata ovisno o intervalima u kojima se oni nalaze. Interaktivni grafički prikaz učestalosti pojavljivanja predviđenih vrijednosti rezultata omogućuje precizan prikaz vrijednosti rezultata nakon pozicioniranja na dobivenom grafu.

Tablica 5.2. Komponente predloženog modela

Izvor:	Dodatne komponente u predloženom modelu:
[81]	+ uključivanje demografskih i socio-ekonomskih čimbenika pri modeliranju kriterija + određivanje nužnog iznosa subvencija kako bi kreirani model bio isplativ + primjena realnih opcija pri modeliranju
[82]	+ modeliranje konkurencije među operatorima + primjena dodatnog modela za predviđanje broja korisnika - modela crne kutije, odnosno neuronskih mreža (uz tradicionalne modele - Gompertzov i Fisher-Pryov)
[83]	+ primjena teorije igara pri modeliranju
[141]	+ uključivanje čimbenika bitnih operatorima pri donošenju odluka o uvođenju širokopojasnog pristupa u ruralnim područjima u tehno-ekonomski model

Navedena problematika definirana u relevantnom području istraživanja poslužila je kao motiv pri kreiranju nadograđenog modela, što predloženom modelu daje dodatnu težinu. Pri tome su u obzir uzete smjernice koje su definirale nedostatke modela kreiranih u [81], [82], [83] i [141]. Predloženi model sadrži dodatne komponente koje su nadogradnja u odnosu na kreirane modele navedene u tablici 5.2..


Problematika koja se detaljnije razmatra u ovom radu vezana je uz pronalazak ravnoteže između zahtjeva potencijalnih i postojećih krajnjih korisnika širokopojsnih internetskih usluga u ruralnim područjima te interesa mrežnih operatora. Cilj provedene analize vezan je uz poticanje korisnika na daljnju primjenu širokopojsnih tehnologija i usluga (kroz ostvarivanje njihovih zahtjeva) i uz izbor najoptimalnijih poslovnih strategija za operatore (nakon uvažavanja zahtjeva korisnika), što bi trebalo u konačnici rezultirati povećanjem ukupnog broja korisnika uz smanjenje digitalnog jaza.



Slika 5.2. Zahtjevi krajnjih korisnika i interesi operatora

Među zahtjevima korisnika koji se razmatraju pri daljnjoj analizi nalaze se zahtjevi vezani uz cijenu internetskih usluga, kvalitetu usluga, količinu prometa i brzinu pristupa. Sukladno tome, interesi operatora uključuju razmatranje prihoda po korisniku, troškova za pokrivanje korisnika uslugama, troškova za kapacitet po korisniku te troškova za pristupnu brzinu po korisniku, kako je prikazano na slici 5.2..

Pri daljnjoj analizi u radu je pretpostavljeno da su interesi korisnika vezani uz smanjenje cijene internetskih usluga te povećanje kvalitete usluga, povećanje količine prometa i povećanje brzine pristupa, a interesi operatora uz povećanje prihoda po korisniku te smanjenje troškova za pokrivanje korisnika uslugama, za kapacitet i za brzinu pristupa po korisniku, kako je prikazano na slici 5.3..



Slika 5.3. Prikaz odabrane problematike


Pretpostavljeno je da je ravnotežu, odnosno zadovoljenje zahtjeva korisnika te interesa operatora (koji uključuju isplative poslovne modele) moguće postići kroz promjene:

- iznosa cijena usluga,
- područja pokrivanja,
- propusnosti po korisniku te
- brzine pristupa po korisniku.

Potrebno je naglasiti da je pri modeliranju okvira cilj udovoljenje zahtjevima krajnjih korisnika, dok provedene tehno-ekonomske metode modeliranja imaju za cilj utvrditi ekonomsku isplativost složenih tehničkih sustava, što je u interesu operatora. Dakle, razmotren je skup tehničkih metrika (propusnost, brzina, kvaliteta) i ekonomskih metrika (cijena). Nadalje, pri modeliranju su primijenjena multidisciplinarna znanja iz područja telekomunikacija, računarstva, matematike te ekonomije, a kombinirane su različiti inženjerski postupci i metode. Postupak modeliranja je tehnološki orijentiran, dok je glavni fokus stavljen na udovoljenje zahtjevima krajnjih korisnika te na ekonomsku procjenu tehničkih sustava.

Tehnički zahtjevi pri izradi tehno-ekonomskog modela s predloženim okvirom vezani su uz modeliranje poveznice između potrebne mrežne infrastrukture i postavljenih zahtjeva za kapacitetom, brzinom i pokrivanjem područja signalom. Ekonomski zahtjevi vezani su uz poveznicu između ostvarenja isplativih poslovnih modela te postavljenih zahtjeva na cijene usluga.

Svi su navedeni zahtjevi modelirani unutar pojedinih funkcija u tehno-ekonomskom modelu kreiranom u MATLAB[®] okružju [147]. Pojedine funkcije te struktura kreiranog modela detaljnije su opisane u nastavku.



Slika 5.4. Prikaz funkcija u modelu

5.2.1. Struktura predloženog tehno-ekonomskog modela s okvirom

Kreirani tehno-ekonomski model sastoji se od većeg broja funkcija, a to su:

- funkcije koje pripadaju dodanom okviru u tehno-ekonomski model, koje služe za analizu podataka i određivanje koeficijenata, čije se vrijednosti prenose dalje u model,
- ulazna funkcija, koja služi za automatski ili ručni unos ulaznih podataka u model,
- funkcije koje služe za tehno-ekonomsko modeliranje,
- izlazna funkcija, koja poziva sve ostale funkcije te
- funkcija koja izvršava simulacije te vraća rezultate simulacija.

Struktura modela je prikazana na slici 5.4..

Ulazna funkcija

Tehno-ekonomske analize koje se koriste za vrednovanje mogućnosti i opravdanosti uvođenja širokopoljnih pristupnih mreža oslanjaju se na veliki broj različitih ulaznih podataka koje je potrebno uključiti u postupak tehno-ekonomskog modeliranja. Često je, zbog prevelike složenosti, takve modele potrebno pojednostaviti, pa je nužno odrediti najbitnije ulazne čimbenike u model.

U ovom modelu ulazna funkcija, za koju je prikazan algoritam prikuplja prikazani niz podataka, kako je naznačeno u kodu, pri čemu je moguće odabrati slijedni ili predefimirani unos podataka.

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
```

```
ULAZNA FUNKCIJA:
```

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
```

Ako je odabran slijedni unos podataka **onda**

Unos podataka za planiranje scenarija

Unos podataka za kreiranje geo-demografske komponente

Ukupna površina promatranog područja

Ukupan broj stanovnika na promatranom području

Godišnja stopa promjene broja stanovnika

Ukupan broj kućanstava na promatranom području

Godišnja stopa promjene broja kućanstava

Unos podataka za kreiranje tehnološke komponente

Vrsta pristupne tehnologije (fiksna žična (ADSL) / fiksna bežična (WiMAX) / mobilna bežična (LTE))

Unos podataka za kreiranje regulatorne komponente

Ukupan broj telekom operatora na tržištu na promatranom području

Udio operatora na tržištu

Udio ciljanog područja u ukupnom području

Unos podataka za kreiranje komponente dostupnih usluga

Prosječna vrijednost propusnosti po korisniku

Unos podataka za modeliranje scenarija

Unos podataka za modeliranje tržišta

Model predviđanja broja korisnika (Gompertzov / Fisher-Pryev / model crne kutije)

Ako je odabran Gompertzov ili Fisher-Pryev model **onda**

Unos vrijednosti penetracije korisnika u dvije godine za izračun koeficijenata modela i procjenu broja korisnika

Kraj

Ako je odabran model crne kutije **onda**

Inicijalizacija vrijednosti za izračun koeficijenata modela i procjenu broja korisnika na temelju poznatih podataka

Kraj

Unos podataka za modeliranje pristupne mreže

Ako je odabrana fiksna žična (ADSL) pristupna tehnologija **onda**

Unos podataka za određivanje potrebne količine komponenti i za funkcioniranje jedne komponente j

Broj pristupnih linija po korisniku

Broj pristupnih linija po linijskoj kartici

Broj linijskih kartica po jednom DSLAM-u

Broj svjetlovoda po jednom DSLAM-u

Broj svjetlovoda po izvedenom iskopu

Kraj

Ako je odabrana fiksna bežična (WiMAX) ili mobilna bežična (LTE) pristupna tehnologija **onda**

Unos podataka za određivanje potrebne količine komponenti i za funkcioniranje jedne komponente j

Broj korisnika po jednoj sektorskoj anteni

Broj radio sektora po jednoj sektorskoj anteni

Broj sektora po jednoj baznoj stanici

Broj radijskih linkova po jednoj baznoj stanici

Kraj

Unos podataka za planiranje pokrivenosti područja

Polumjer pokrivanja za svaku od komponenata

Unos podataka za planiranje potrebnih kapaciteta

Kapacitet za svaku od komponenata

Brzina po korisniku

Unos podataka za modeliranje prihoda i cijena usluga

Jednokratna naknada za uključenje usluge

Iznos mjesečne naknade za najam korisničke opreme

Iznos mjesečne naknade za internetsku brzinu i neograničen paket internetskog prometa

Unos podataka za modeliranje troškova

Unos podataka za određivanje cijene komponenata

Postotak cijene korisničke opreme koji snosi korisnik

Unos podataka za određivanje operativnih troškova

Trošak instalacije za svaku od komponenata

Godišnji operativni i administrativni troškovi za svaku od komponenata

Trošak održavanja za svaku od komponenata

Period amortiziranja za svaku od komponenata

Unos podataka za određivanje kapitalnih izdataka

Prosječna trenutna cijena za svaku od komponenata

Relativno godišnje smanjenje cijene za svaku od komponenata

Unos podataka za analiziranje održivosti i ocjenjivanje isplativosti modela

Unos podataka za analiziranje financijske održivosti i isplativosti modela

Unos podataka za oporezivanje

Porezna stopa

Period odbitka

Unos podataka za ocjenjivanje ekonomske isplativosti modela

Unos podataka za diskontiranje

Diskontna stopa

Kraj

Ako je odabran predefiniрани unos podataka onda

Unos predefiniраниh vrijednosti

Kraj

%%%%%%%%%

Dok slijedni unos podataka omogućuje unos proizvoljnih vrijednosti, predefiniране vrijednosti primjenjuju se u svrhu testiranja modela kako ne bi bilo nužno iznova unositi podatke pri kreiranju manjih izmjena u modelu. Prikupljeni podaci prosljeđuju se kao ulazi u ostale funkcije koje se primjenjuju pri tehno-ekonomskom modeliranju.

Izlazna funkcija

Izlazna funkcija primjenjuje se kako bi se uspostavio točan poredak pozivanja pojedinih funkcija za planiranje modela, kreiranje modela te ocjenjivanje održivosti i isplativosti modela, koje se koriste pri tehno-ekonomskom modeliranju, a koje prate redoslijed izvođenja postupaka modeliranja opisanog u trećem poglavlju rada.

5.2.2. Opis okvira

Rezultati provedenih istraživanja ukazuju na činjenicu da bi se rizici i neizvjesnosti vezane uz procjene stopa penetracije i buduću potražnju za širokopojasnim pristupom mogle umanjiti ukoliko se provedu detaljna ispitivanja o potražnji i zahtjevima potencijalnih korisnika na kvalitetu širokopojasnih usluga, čime bi se mogli smanjiti i troškovi uvođenja širokopojasnog pristupa po korisniku [141].

Također, definiranje maksimalnih razina cijena priključaka, zasnovanih na provedenom ispitivanju, može se potaknuti operatore na ponudu nižih cijena usluga kako bi se ostvario veći stupanj usvajanja širokopojasnih tehnologija i usluga [141]. To bi rezultiralo uklanjanjem rizika od pojave kombinacije niskih stopa penetracije i niskih razina cijena ponuđenih usluga.

Planiranje mreža temeljeno na potražnji može biti popraćeno dodatnim poticanjem korisnika koji ranije usvajaju tehnološke inovacije, a 'kažnjavanjem' korisnika koji ih kasno usvajaju. Na primjer, moguće je poticanje korisnika na priključivanje u ranim fazama razvoja mreža uz niže (subvencionirane) cijene za priključivanje, dok se korisnici koji se kasnije odluče na usvajanje mogu priključiti po višim cijenama zbog viših troškova operatora.

<u>Zahtjevi korisnika na:</u>	⇒ <u>Operator razmatra:</u>	⇒ <u>Godisnja promjena čimbenika:</u>
cijene usluga	⇒ prihod po korisniku	⇒ cijene usluga (C)
kvalitetu usluga	⇒ pokrivenost korisnika uslugama	⇒ područje pokrivanja (PP)
količine prometa	⇒ kapacitet po korisniku	⇒ propusnost po korisniku (PR)
brzine pristupa	⇒ brzinu pristupa po korisniku	⇒ brzina po korisniku (BR)

Na broj korisnika širokopojasnog pristupa Internetu utječu različiti čimbenici. Pri određivanju najbitnijih čimbenika koji utječu na ukupan broj korisnika potrebno je provesti analizu dostupnih podataka o korisnicima. Pri tome su, kako je navedeno u prethodnim poglavljima rada, najrelevantniji podaci o tehničkim, ekonomskim, demografskim i sociološkim čimbenicima. Stoga se u predloženom okviru ukupan broj korisnika razmatra kao funkcija navedenih čimbenika te njihovih kombinacija.

$$broj_korisnika = f(\text{čimbenici: tehnički, ekonomski, demografski, sociološki, i kombinacije}) \quad (5.1)$$

U predloženom okviru tehno-ekonomskog modela provode se sljedeće analize čimbenika:

- regresijska analiza i određivanje najbitnijih socio-demografskih čimbenika koji opisuju korisnike te utječu na ukupan broj krajnjih korisnika širokopojasnog Interneta;
- regresijska analiza i određivanje najbitnijih kombinacija socio-demografskih i tehno-ekonomskih čimbenika koji opisuju zahtjeve krajnjih korisnika;
- kvantitativna analiza utjecaja promjena iznosa tehno-ekonomskih čimbenika na ukupan broj korisnika.

Ove analize detaljnije su opisane u nastavku. Dobiveni rezultati provedenih analiza izravno se uključuju u postupke tehno-ekonomskog modeliranja, na naknadno objašnjeni način.

5.2.2.1. Regresijska analiza čimbenika koji opisuju korisnike i utječu na broj korisnika

Dakle, u prvom koraku se analizira utjecaj različitih socio-demografskih čimbenika - dobi, obrazovanja, dohotka, gustoće naseljenosti, primarnog sektora djelatnosti karakterističnog za ruralna područja, zaposlenosti te broja korisnika u prethodnom razdoblju, na ukupan broj krajnjih korisnika širokopojasnog Interneta:

$$\begin{aligned}
\text{broj_korisnika} &= f(\text{socio-demografski _čimbenici}) = \\
&= f(\text{dob, obrazovanje, dohodak, gustoća_naseljenosti, primarni_sektor, zaposlenost,} \\
&\quad \text{broj_korisnika_u_prethodnom_razdoblju}) \quad (5.2)
\end{aligned}$$

U cilju određivanja najbitnijih socio-demografskih čimbenika koji opisuju ukupan broj krajnjih korisnika provodi se regresijska analiza čimbenika. Primijenjen je sljedeći model:

$$\begin{aligned}
\ln(\text{broj_korisnika}) &= \alpha + \beta_{N1} \cdot \ln(\text{dob}) + \beta_{N2} \cdot \ln(\text{obrazovanje}) + \beta_{N3} \cdot \ln(\text{dohodak}) + \\
&+ \beta_{N4} \cdot \ln(\text{gustoća_naseljenosti}) + \beta_{N5} \cdot \ln(\text{primarni_sektor}) + \beta_{N6} \cdot \ln(\text{zaposlenost}) + \\
&\quad + \beta_{N7} \cdot \ln(\text{broj_korisnika_u_prethodnom_razdoblju}) \quad (5.3)
\end{aligned}$$

Cilj ove analize je utvrđivanje najbitnijih socio-demografskih čimbenika koji utječu na ukupan broj korisnika širokopojasnog Interneta, pri čemu se čimbenici sortiraju, ovisno o procijenjenim vrijednostima koeficijenata β_N , od najutjecajnijih prema najmanje utjecajnim. U ovom koraku provodi se i testiranje zavisnosti slučajnih varijabli u modelu višestruke regresije, tj. postojanja autokorelacije između čimbenika, pri čemu se autokorelirani čimbenici izostavljaju pri daljnjoj analizi.

5.2.2.2. Regresijska analiza čimbenika koji opisuju zahtjeve krajnjih korisnika

U okvir je uključena pretpostavka kako se proces planiranja mreža treba temeljiti na stvarnoj potražnji za širokopojasnim pristupom. Na taj način, uslijed poznate potražnje, mreža može biti planirana na temelju stvarnih zahtjeva korisnika, što prema [141] smanjuje troškove uvođenja širokopojasnog pristupa Internetu po pretplatniku. Nadalje, kako je istaknuto u [141], ukoliko su u fazi formiranja cijena korisnički zahtjevi na cijenu nepoznati, sustav naplate neće biti konačan kroz cijeli promatrani period. Ukoliko je ranije definirana maksimalna cijena, taj je podatak moguće iskoristiti pri planiranju. Ovo može potaknuti operatore da ponude niže cijene usluga kako bi se ostvario veći stupanj usvajanja širokopojasnog pristupa, što bi trebalo rezultirati uklanjanjem rizika od nastanka kombinacije niskih razina penetracije te niskih razina cijena usluga. Stoga je u okvir uključena i pretpostavka o određivanju maksimalnih razina cijena priključaka, zasnovana na rezultatima ispitivanja potencijalnih korisnika, budući da se zahtjevi tako mogu preciznije definirati. Analogno je moguće odrediti i korisničke zahtjeve vezane uz razinu kvalitete usluga te uz ponuđene pristupne brzine.

Dakle, u drugom koraku se u analizu uključuju korisnički zahtjevi za cijenom usluga, kvalitetom usluga, količinom prometa i pristupnom brzinom. Oni čine razmatrane tehno-ekonomske čimbenike. Ovi podaci dobivaju se anketiranjem odgovarajućeg uzorka potencijalnih krajnjih korisnika, pri čemu je moguće koristiti i povijesne podatke o dostupnim cijenama usluga, paketima usluga i pristupnim brzinama. Provedena analiza dobivenih podataka omogućuje dobivanje poveznice između najbitnijih socio-demografskih čimbenika i tehno-ekonomskih čimbenika (analogno modelu iz [102]). Određuju se iznosi koeficijenata koji opisuju utjecaj pojedinih kombinacija najbitnijih socio-demografskih i navedenih tehno-ekonomskih čimbenika (npr.: dob i brzina pristupa, dohodak i cijena usluga i sl.).

$$\ln(\text{broj_korisnika}) = \alpha + \beta_{K1} \cdot \ln(\text{kombinacija_čimbenika_1}) + \beta_{K2} \cdot \ln(\text{kombinacija_čimbenika_2}) + \dots + \beta_{Kn} \cdot \ln(\text{kombinacija_čimbenika_n}) \quad (5.4)$$

Kao rezultat analize uzimaju se vrijednosti koeficijenata β_K za najbitnije kombinacije koje uključuju četiri navedena tehno-ekonomska čimbenika - cijenu usluga, kvalitetu usluga, količinu prometa i pristupnu brzinu, kako je opisano i u priloženom kodu.

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
FUNKCIJE ZA PROVOĐENJE ANALIZE ČIMBENIKA:
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
```

INICIJALIZACIJA

Učitavanje podataka iz datoteke

- Učitavanje ulaznog skupa cimbenika, tzv. prediktora
- Učitavanje izlaznog skupa cimbenika, tzv. odziva
- Učitavanje naziva prediktora
- Učitavanje naziva odziva
- Određivanje veličine uzorka

Regresijska analiza cimbenika

- Pozivanje funkcije `stats0 = regstats(Odziv,Cimbenici)` koja određuje parametre regresije nad učitanim skupom vrijednosti

Prikaz rezultata regresije

- Prikaz beta koeficijenata (`stats0.beta`)
- Prikaz koeficijenta determinacije (`stats0.rsquare`)
- Prikaz *F* statistike (`stats0.fstat`)

Određivanje utjecaja cimbenika na odziv

- Unos zeljene statisticke razine znacajnosti

Analiziranje utjecaja cimbenika na odziv uz primjenu *rstool* funkcije za multidimenzionalnu prilagodbu i interaktivnu vizualizaciju odziva kao funkcije više prediktorskih varijabli
 Prikaz beta koeficijenata koji opisuju utjecaj svakog pojedinog cimbenika na odziv uz primjenu sljedećeg izraza: $\beta = rstool(Cimbenici, Odziv==0, 'linear', 0.01, naziviCimbenika, nazivOdziva)$

Određivanje najbitnijih cimbenika

- Ispis koeficijenata koji služe za određivanje najbitnijih cimbenika
- Određivanje apsolutnih vrijednosti koeficijenata zbog lakše usporedbe iznosa
- Sortiranje koeficijenata prema vrijednostima zbog određivanja najbitnijih cimbenika
- Ispis najbitnijih cimbenika i vrijednosti njihovih koeficijenata:
- Odabir broja najbitnijih cimbenika koji se želi uključiti u daljnju analizu
- Ispis samo odabranih koeficijenata
- Dodjeljivanje kategorija (rednih brojeva) odabranim cimbenicima

Klasifikacija ovisno o odabranim cimbenicima

- Ispis naziva svih cimbenika
- Normiranje vrijednosti koeficijenata
- Sortiranje vrijednosti normiranih koeficijenata u intervalu od -1 do 1
- Ispis najbitnijih cimbenika i vrijednosti njihovih koeficijenata

KRAJ

%%%%%%%%%

5.2.2.3. Kvantitativna analiza utjecaja promjena iznosa tehno-ekonomskih čimbenika na ukupan broj korisnika

Utjecaj tehno-ekonomskih čimbenika - cijene usluga, kvalitete usluga (koja se analizira kroz pokrivenost korisnika tj. područja uslugom), prometa (odnosno propusnosti) te brzine, na ukupan broj korisnika provodi se kroz analizu dostupnih podataka:

$$\begin{aligned} broj_korisnika &= f(\text{tehno-ekonomski_čimbenici}) = \\ &= f(\text{cijena, kvaliteta, promet, brzina}) \end{aligned} \quad (5.5)$$

Utjecaj pojedinih čimbenika na ukupan broj korisnika opisuje vrijednost koeficijenta *beta*:

$$\begin{aligned} broj_korisnika &= \alpha + \beta c \cdot \text{cijena} + \beta_{pp} \cdot \text{područje_pokrivanja} + \\ &+ \beta_{pr} \cdot \text{propusnost} + \beta_{br} \cdot \text{brzina} + \beta_0 \end{aligned} \quad (5.6)$$

Cilj ove analize je utvrđivanje najboljih strategija za operatore ovisno o prethodno određenim iznosima koeficijenata β te Δ , što je detaljnije opisan u nastavku.

Formula za određivanje utjecaja tehno-ekonomskih čimbenika na ukupan broj korisnika, odnosno za određivanje koeficijenata β koji najbolje opisuju model je:

$$BK = \beta_c \cdot C + \beta_{pp} \cdot PP + \beta_{pr} \cdot PR + \beta_{br} \cdot BR + \beta_0 \quad (5.7)$$

Pri čemu se koriste sljedeće oznake:

BK = broj korisnika

BR = brzina

C = cijena usluga

β = koeficijent uz pojedini čimbenik

PP = područje pokrivanja

Δ = promjena

PR = propusnost

$\Delta \in [-1,1] \rightarrow$ normirane vrijednosti

Nakon što su određeni koeficijenti β u modelu te je poznat njihov iznos, može se za nove vrijednosti tehno-ekonomskih čimbenika procijeniti nova vrijednost broja korisnika:

$$BK1 = \beta_c \cdot C2 + \beta_{pp} \cdot PP2 + \beta_{pr} \cdot PR2 + \beta_{br} \cdot BR2 + \beta_0 \quad (5.8)$$

Formula za određivanje utjecaja promjene vrijednosti tehno-ekonomskih čimbenika na promjenu ukupnog broja korisnika može se zapisati u sljedećem obliku:

$$\begin{aligned} \Delta BK &= BK1 - BK = \\ &= (\beta_c \cdot C2 + \beta_{pp} \cdot PP2 + \beta_{pr} \cdot PR2 + \beta_{br} \cdot BR2 + \beta_0) - (\beta_c \cdot C + \beta_{pp} \cdot PP + \beta_{pr} \cdot PR + \beta_{br} \cdot BR + \beta_0) = \\ &= \beta_c \cdot (C2 - C) + \beta_{pp} \cdot (PP2 - PP) + \beta_{pr} \cdot (PR2 - PR) + \beta_{br} \cdot (BR2 - BR) \end{aligned} \quad (5.9)$$

odnosno:

$$\Delta BK = \beta_c \cdot \Delta C + \beta_{pp} \cdot \Delta PP + \beta_{pr} \cdot \Delta PR + \beta_{br} \cdot \Delta BR \quad (5.10)$$

Ukoliko se razmotre moguće promjene tehno-ekonomskih čimbenika koje mogu nastupiti u nekom budućem razdoblju, mogu se definirati kombinacije promjena iznosa čimbenika prikazane u tablici 5.3..

Tablica 5.3. Utjecaj promjene tehno-ekonomskih čimbenika na ukupni broj korisnika

	BROJ KORISNIKA:	Cijena	Kvaliteta	Promet	Brzina	Ostalo
	$\Delta BK :$	$\Delta C:$	$\Delta PP:$	$\Delta PR:$	$\Delta BR:$	$\Delta O:$
1.	$\beta_1 \cdot \Delta 1$	$\Delta 1$	0	0	0	0
2.	$\beta_2 \cdot \Delta 2$	0	$\Delta 2$	0	0	0
3.	$\beta_3 \cdot \Delta 3$	0	0	$\Delta 3$	0	0
4.	$\beta_4 \cdot \Delta 4$	0	0	0	$\Delta 4$	0
5.	$\beta_1 \cdot \Delta 1 + \beta_2 \cdot \Delta 2$	$\Delta 1$	$\Delta 2$	0	0	0
6.	$\beta_1 \cdot \Delta 1 + \beta_3 \cdot \Delta 3$	$\Delta 1$	0	$\Delta 3$	0	0
7.	$\beta_1 \cdot \Delta 1 + \beta_4 \cdot \Delta 4$	$\Delta 1$	0	0	$\Delta 4$	0
8.	$\beta_2 \cdot \Delta 2 + \beta_3 \cdot \Delta 3$	0	$\Delta 2$	$\Delta 3$	0	0
9.	$\beta_2 \cdot \Delta 2 + \beta_4 \cdot \Delta 4$	0	$\Delta 2$	0	$\Delta 4$	0
10.	$\beta_3 \cdot \Delta 3 + \beta_4 \cdot \Delta 4$	0	0	$\Delta 3$	$\Delta 4$	0
11.	$\beta_1 \cdot \Delta 1 + \beta_2 \cdot \Delta 2 + \beta_3 \cdot \Delta 3$	$\Delta 1$	$\Delta 2$	$\Delta 3$	0	0
12.	$\beta_1 \cdot \Delta 1 + \beta_2 \cdot \Delta 2 + \beta_4 \cdot \Delta 4$	$\Delta 1$	$\Delta 2$	0	$\Delta 4$	0
13.	$\beta_1 \cdot \Delta 1 + \beta_3 \cdot \Delta 3 + \beta_4 \cdot \Delta 4$	$\Delta 1$	0	$\Delta 3$	$\Delta 4$	0
14.	$\beta_2 \cdot \Delta 2 + \beta_3 \cdot \Delta 3 + \beta_4 \cdot \Delta 4$	0	$\Delta 2$	$\Delta 3$	$\Delta 4$	0
15.	$\beta_1 \cdot \Delta 1 + \beta_2 \cdot \Delta 2 + \beta_3 \cdot \Delta 3 + \beta_4 \cdot \Delta 4$	$\Delta 1$	$\Delta 2$	$\Delta 3$	$\Delta 4$	0

Budući da su za daljnju analizu bitni samo navedeni čimbenici, zanemaruje se utjecaj promjena ostalih čimbenika ($\Delta O = 0$) na broj korisnika.

5.2.2.4. Modeliranje prihoda

Kako je navedeno u poglavlju 3.3.2.4., prihodi operatora modeliraju se ovisno o postojećem broju korisnika te o cijenama usluga:

$$prihodi = f(\text{broj_korisnika}, \text{cijene_usluga}) \quad (5.11)$$

Formula za određivanje prihoda određena je na sljedeći način:

$$prihodi = \text{broj_korisnika} \cdot \text{cijena_usluga} \quad (5.12)$$

odnosno, kraće:

$$P = BK \cdot C \quad (5.13)$$

Formula za određivanje utjecaja promjene vrijednosti ovih dvaju čimbenika na promjenu ukupnih prihoda može se zapisati u sljedećem obliku:

$$\Delta P = P_2 - P = \Delta BK \cdot \Delta C \quad (5.14)$$

Ovisno o kombinacijama promjena prikazanima u tablici 5.3., moguće je definirati iznose promjena prihoda u svakom od pojedinih slučajeva, kako je prikazano u tablici 5.4..

Tablica 5.4. Modeliranje prihoda operatora

	$\Delta P:$
1.	$\beta_1 \cdot (\Delta 1)^2$
2.	0
3.	0
4.	0
5.	$(\beta_1 \cdot \Delta 1 + \beta_2 \cdot \Delta 2) \cdot \Delta 1$
6.	$(\beta_1 \cdot \Delta 1 + \beta_3 \cdot \Delta 3) \cdot \Delta 1$
7.	$(\beta_1 \cdot \Delta 1 + \beta_4 \cdot \Delta 4) \cdot \Delta 1$
8.	0
9.	0
10.	0
11.	$(\beta_1 \cdot \Delta 1 + \beta_2 \cdot \Delta 2 + \beta_3 \cdot \Delta 3) \cdot \Delta 1$
12.	$(\beta_1 \cdot \Delta 1 + \beta_2 \cdot \Delta 2 + \beta_4 \cdot \Delta 4) \cdot \Delta 1$
13.	$(\beta_1 \cdot \Delta 1 + \beta_3 \cdot \Delta 3 + \beta_4 \cdot \Delta 4) \cdot \Delta 1$
14.	0
15.	$(\beta_1 \cdot \Delta 1 + \beta_2 \cdot \Delta 2 + \beta_3 \cdot \Delta 3 + \beta_4 \cdot \Delta 4) \cdot \Delta 1$

5.2.2.5. Modeliranje troškova

Kako je navedeno u poglavlju 3.3.2.5., troškovi operatora vezani su uz planiranu pokrivenosti područja (tj. korisnika) uslugama, dostupni kapacitet po korisniku te brzinu po korisniku:

$$\text{troškovi} = f(\text{pokrivenost}, \text{kapacitet}, \text{brzina}) \quad (5.15)$$

ili skraćeno:

$$T = BK \cdot (PP + PR + BR) \quad (5.16)$$

Nadalje, svaka od ovih varijabli može se dodatno modelirati prema sljedećem:

$$\text{troškovi_područje_pokrivanja} = f(\text{broj_korisnika}, \text{područje_pokrivanja}, \text{cijena_korisničke_opreme}) \quad (5.17)$$

$$\text{troškovi_propusnost} = f(\text{broj_korisnika}, \text{propusnost_po_korisniku}, \text{cijena_za_mrežnu_infrastrukturu}) \quad (5.18)$$

$$\text{troškovi_brzina} = f(\text{broj_korisnika}, \text{brzina_po_korisniku}) \quad (5.19)$$

Formula za određivanje utjecaja promjene vrijednosti ovih čimbenika na promjenu ukupnih troškova može se zapisati u sljedećem obliku:

$$\Delta T = \Delta BK \cdot (\Delta PP + \Delta PR + \Delta BR) \quad (5.20)$$

Ovisno o kombinacijama promjena prikazanim u tablici 5.3., moguće je definirati iznose promjena troškova u pojedinim slučajevima, kako je prikazano u tablici 5.5..

Tablica 5.5. Modeliranje troškova operatora

	$\Delta T:$
1.	0
2.	$\beta_2 \cdot (\Delta_2)^2$
3.	$\beta_3 \cdot (\Delta_3)^2$
4.	$\beta_4 \cdot (\Delta_4)^2$
5.	$(\beta_1 \cdot \Delta_1 + \beta_2 \cdot \Delta_2) \cdot \Delta_2$
6.	$(\beta_1 \cdot \Delta_1 + \beta_3 \cdot \Delta_3) \cdot \Delta_3$
7.	$(\beta_1 \cdot \Delta_1 + \beta_4 \cdot \Delta_4) \cdot \Delta_4$
8.	$(\beta_2 \cdot \Delta_2 + \beta_3 \cdot \Delta_3) \cdot (\Delta_2 + \Delta_3)$
9.	$(\beta_2 \cdot \Delta_2 + \beta_4 \cdot \Delta_4) \cdot (\Delta_2 + \Delta_4)$
10.	$(\beta_3 \cdot \Delta_3 + \beta_4 \cdot \Delta_4) \cdot (\Delta_3 + \Delta_4)$
11.	$(\beta_1 \cdot \Delta_1 + \beta_2 \cdot \Delta_2 + \beta_3 \cdot \Delta_3) \cdot (\Delta_2 + \Delta_3)$
12.	$(\beta_1 \cdot \Delta_1 + \beta_2 \cdot \Delta_2 + \beta_4 \cdot \Delta_4) \cdot (\Delta_2 + \Delta_4)$
13.	$(\beta_1 \cdot \Delta_1 + \beta_3 \cdot \Delta_3 + \beta_4 \cdot \Delta_4) \cdot (\Delta_3 + \Delta_4)$
14.	$(\beta_2 \cdot \Delta_2 + \beta_3 \cdot \Delta_3 + \beta_4 \cdot \Delta_4) \cdot (\Delta_2 + \Delta_3 + \Delta_4)$
15.	$(\beta_1 \cdot \Delta_1 + \beta_2 \cdot \Delta_2 + \beta_3 \cdot \Delta_3 + \beta_4 \cdot \Delta_4) \cdot (\Delta_2 + \Delta_3 + \Delta_4)$

5.2.2.6. Primjena dobivenih rezultata analiza provedenih unutar okvira

Nakon kreiranja modela koji definira utjecaj promjena tehno-ekonomskih čimbenika na ukupni broj korisnika, kao i modela za definiranje prihoda i troškova, definirana je i sljedeća funkcija pomoću koje se nadograđuje osnovni tehno-ekonomski model.

%%
 FUNKCIJA ZA ODREĐIVANJE PARAMETARA KOJI OPISUJU PROMJENE TEHNO-EKONOMSKIH ČIMBENIKA:
 %%%

Definiranje godišnjih promjena tehno-ekonomskih čimbenika

Inicijalizacija parametara *delta* (*de_1*, *de_2*, *de_3* i *de_4*) koji opisuju redom godišnje promjene cijene usluga (ΔC), područja pokrivanja (ΔPP), propusnosti po korisniku (ΔPR) i brzine po korisniku (ΔBR) (određivanje minimalne vrijednosti, koraka za podjelu intervala te maksimalne vrijednosti)

de_1=*de_min*(1):*de_int*(1):*de_maks*(1);
de_2=*de_min*(2):*de_int*(2):*de_maks*(2);

$de_3=de_min(3):de_int(3):de_maks(3);$
 $de_4=de_min(4):de_int(4):de_maks(4);$

Deklaracija koeficijenata $beta$ (be_1 , be_2 , be_3 i be_4), odnosno učitavanje njihovih vrijednosti iz rezultata koje vraća funkcija za provođenje analize čimbenika, prema sljedećem:

$be_1=KOEFIJIENTI(1,1);$
 $be_2=KOEFIJIENTI(1,2);$
 $be_3=KOEFIJIENTI(1,3);$
 $be_4=KOEFIJIENTI(1,4);$

Određivanje ukupnog broja kombinacija različitih strategija q prema sljedećem:

Za svaki i od 1 do 4 (odnosno od be_1 do be_4)
Sve dok $de_1=de_min(1):de_int(1):de_maks(1),$
Sve dok $de_2=de_min(2):de_int(2):de_maks(2),$
Sve dok $de_3=de_min(3):de_int(3):de_maks(3),$
Sve dok $de_4=de_min(4):de_int(4):de_maks(4),$
Uvećaj broj kombinacija za jedan ($kombinacija=kombinacija+1$)
Kraj
Kraj
Kraj
Kraj
Kraj

Određivanje ukupnog broja kombinacija množenjem broja kombinacija s brojem strategija po kombinaciji $q=15*kombinacija$; (ukupno ima 15 različitih strategija po svakoj kombinaciji)

Kombiniranje

Postavljanje vrijednosti kombinacija u nulu te rednog broja strategije u nulu

Za svaki i od 1 do 4 (odnosno od be_1 do be_4)
Sve dok $de_1=de_min(1):de_int(1):de_maks(1),$
Sve dok $de_2=de_min(2):de_int(2):de_maks(2),$
Sve dok $de_3=de_min(3):de_int(3):de_maks(3),$
Sve dok $de_4=de_min(4):de_int(4):de_maks(4),$
Postavi vrijednosti koeficijenata $beta(1) = be_1; delta(1) = de_1; beta(2) = be_2;$
 $delta(2) = de_2; beta(3) = be_3; delta(3) = de_3; beta(4) = be_4; delta(4) = de_4;$

Određivanje troškova operatora uz primjenu sljedećih formula:

$deltaT(1) = 0;$
 $deltaT(2) = beta(2)*delta(2)*delta(2);$
 $deltaT(3) = beta(3)*delta(3)*delta(3);$
 $deltaT(4) = beta(4)*delta(4)*delta(4);$
 $deltaT(5) = (beta(1)*delta(1)+beta(2)*delta(2))*delta(2);$
 $deltaT(6) = (beta(1)*delta(1)+beta(3)*delta(3))*delta(3);$
 $deltaT(7) = (beta(1)*delta(1)+beta(4)*delta(4))*delta(4);$
 $deltaT(8) = (beta(2)*delta(2)+beta(3)*delta(3))*delta(2)*delta(3);$

$\text{deltaT}(9) = (\text{beta}(2)*\text{delta}(2)+\text{beta}(4)*\text{delta}(4))*\text{delta}(2)*\text{delta}(4);$
 $\text{deltaT}(10) = (\text{beta}(3)*\text{delta}(3)+\text{beta}(4)*\text{delta}(4))*\text{delta}(3)*\text{delta}(4);$
 $\text{deltaT}(11) = (\text{beta}(1)*\text{delta}(1)+\text{beta}(2)*\text{delta}(2)+\text{beta}(3)*\text{delta}(3))*\text{delta}(2)*\text{delta}(3);$
 $\text{deltaT}(12) = (\text{beta}(1)*\text{delta}(1)+\text{beta}(2)*\text{delta}(2)+\text{beta}(4)*\text{delta}(4))*\text{delta}(2)*\text{delta}(4);$
 $\text{deltaT}(13) = (\text{beta}(1)*\text{delta}(1)+\text{beta}(3)*\text{delta}(3)+\text{beta}(4)*\text{delta}(4))*\text{delta}(3)*\text{delta}(4);$
 $\text{deltaT}(14) = (\text{beta}(2)*\text{delta}(2)+$
 $+ \text{beta}(3)*\text{delta}(3)+\text{beta}(4)*\text{delta}(4))*\text{delta}(2)*\text{delta}(3)*\text{delta}(4);$
 $\text{deltaT}(15) = (\text{beta}(1)*\text{delta}(1)+\text{beta}(2)*\text{delta}(2)+\text{beta}(3)*\text{delta}(3)+$
 $+ \text{beta}(4)*\text{delta}(4))*\text{delta}(2)*\text{delta}(3)*\text{delta}(4);$

Određivanje prihoda operatora uz primjenu sljedećih formula:

$\text{deltaP}(1) = \text{beta}(1)*\text{delta}(1)*\text{delta}(1);$
 $\text{deltaP}(2) = 0;$
 $\text{deltaP}(3) = 0;$
 $\text{deltaP}(4) = 0;$
 $\text{deltaP}(5) = (\text{beta}(1)*\text{delta}(1)+\text{beta}(2)*\text{delta}(2))*\text{delta}(1);$
 $\text{deltaP}(6) = (\text{beta}(1)*\text{delta}(1)+\text{beta}(3)*\text{delta}(3))*\text{delta}(1);$
 $\text{deltaP}(7) = (\text{beta}(1)*\text{delta}(1)+\text{beta}(4)*\text{delta}(4))*\text{delta}(1);$
 $\text{deltaP}(8) = 0;$
 $\text{deltaP}(9) = 0;$
 $\text{deltaP}(10) = 0;$
 $\text{deltaP}(11) = (\text{beta}(1)*\text{delta}(1)+\text{beta}(2)*\text{delta}(2)+\text{beta}(3)*\text{delta}(3))*\text{delta}(1);$
 $\text{deltaP}(12) = (\text{beta}(1)*\text{delta}(1)+\text{beta}(2)*\text{delta}(2)+\text{beta}(4)*\text{delta}(4))*\text{delta}(1);$
 $\text{deltaP}(13) = (\text{beta}(1)*\text{delta}(1)+\text{beta}(3)*\text{delta}(3)+\text{beta}(4)*\text{delta}(4))*\text{delta}(1);$
 $\text{deltaP}(14) = 0;$
 $\text{deltaP}(15) = (\text{beta}(1)*\text{delta}(1)+\text{beta}(2)*\text{delta}(2)+\text{beta}(3)*\text{delta}(3)+$
 $+ \text{beta}(4)*\text{delta}(4))*\text{delta}(1);$

%%

... Kod koji definira STRATEGIJE operatora ...

(Ovaj dio koda ovisi o broju konkurentskih operatora na tržištu, a primjer koda za odabrani scenarij prikazan je u poglavlju s vrednovanjem tehnno-ekonomskog modela.)

%%

Kraj
Kraj
Kraj
Kraj
Kraj

Ispis vektora PROMJENE koji sadrži određene vrijednosti parametara *delta*

Određivanje klasifikacijskog stabla koje prikazuje strategije operatora ovisno o određenim vrijednostima *delta*
t = classregtree(kombinacije_beta_i_delta,najbolje_strategije,'names',{'b1' 'b2' 'b3' 'b4' 'd1' 'd2' 'd3' 'd4'})

Iscrtavanje stabla pomoću naredbe *view(t)*

Kraj

%%%

Dio koda koji opisuje pojedino konkurentsko okruženje, odnosno razmatra određeni broj operatora na tržištu, prikazan je u poglavlju rada koje opisuje odabrani scenarij u kojem se vrednuje predloženi model s okvirom.

Rezultati ove funkcije, koja čini osnovu predloženog okvira, su normirane vrijednosti parametara *delta*, sadržane u vektoru *PROMJENE*, prema sljedećem:

$$PROMJENE = [\Delta C, \Delta PP, \Delta PR, \Delta BR] \quad (5.21)$$

Vrijednosti parametara su normirane u intervalu od -1 do 1, kako bi ih se moglo izravno uključiti u tehno-ekonomski model. Parametri *delta* procijenjeni su na temelju iznosa koeficijenata *beta* (vezanih uz zahtjeve korisnika) koje ova funkcija uzima kao ulazne vrijednosti.

Dobivene normirane vrijednosti *delta* sadržane u vektoru *PROMJENE* uključuju se dalje u postupak tehno-ekonomskog modeliranja te **izravno utječu na postupke planiranja i kreiranja tehno-ekonomskog modela, kako je prikazano i na slici 5.5..**

Njihova vrijednost, kako je naznačeno na prikazima, izravno utječe i na sljedeće postupke:

- a) **planiranje regulatorne komponente scenarija** (kroz definiranje **ciljanog područja pokrivanja** mrežom)
- b) **planiranje komponente dostupnih usluga promatranog scenarija** (kroz definiranje **propusnosti** po korisniku)
- c) **modeliranje pristupne mreže** (kroz definiranje **brzine** po korisniku)
- d) **modeliranje cijena usluga** (kroz određivanje iznosa **naknada** po korisniku).

a)

```

% 1) PLANIRANJE SCENARIJA
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

% c) Regulatorna komponenta
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

function [broj_operatora, udio_operatora_na_trzistu, ciljano_podrucje_pokriivanja]...
= scenarijreg(povrsina_podrucja, period_promatranja, odstupanje, PROMJENE, ...
br_operatora, udio_op_na_trzistu, ciljani_udio, kombin)
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

.
.
.

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

% Godisnja promjena udjela ciljanog podrucja u ukupnom podrucju (PP)
(koefcijent između -1 i 1):

promjena_ciljanog_udjela = PROMJENE(kombin,1)(1,2);

ciljano_podrucje_pokriivanja =
povrsina_podrucja*ciljani_udio*(1+promjena_ciljanog_udjela).^ (0:(period_promatranja-1));
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

```

b)

```

% 1) PLANIRANJE SCENARIJA
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

% d) Komponenta dostupnih usluga
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

function [propusnost_po_korisniku]...
= scenarijuslug(odstupanje, period_promatranja, PROMJENE, prop_po_korisniku, kombin)
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

.
.
.

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

% PREDVIĐVANJE PROSJEČNE PROPUSNOSTI:

% Godisnja stopa promjene zahtjeva za propusnošću po korisniku (PR)
(koefcijent između -1 i 1):

promjena_propusnosti = PROMJENE(kombin,1)(1,3);

propusnost_po_korisniku =
prop_po_korisniku*(1+promjena_propusnosti).^ (0:(period_promatranja-1));
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

```

c)

```

% 2) MODELIRANJE SCENARIJA
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

% 2. MODELIRANJE PRISTUPNE MREŽE
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

function [nazivi_komponentata, broj_komponentata, ovisnost_komponentata, opis_komponentata, ...
zahtjevi_kapacitet, zahtjevi_pokriivenost, ukupni_zahtjevi_pokriivenost, ...
= pristupnarez (period_promatranja, ciljano_podrucje_pokriivanja, PROMJENE, ...
propusnost_po_korisniku, procijenjeni_broj_korisnika, ...
brzina_po_korisniku, naz_komponentata, ovisn_komponentata, opis_komp, kombin)
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

.
.
.

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

% PLANIRANJE POTREBNIH KAPACITETA:

% Analiza utjecaja promjene korisničkih zahtjeva za brzinom (BR) na ukupnu isplativost:

promjena_brzine = PROMJENE(kombin,1)(1,4);

brzina_po_korisniku =
brzina_po_korisniku*(1+promjena_brzine).^ (0:(period_promatranja-1));

.
.
.

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

```

d)

```

% 2) MODELIRANJE SCENARIJA
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

% 3. MODELIRANJE CIJENA USLUGA
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

function [jednokratna_naknada_za_uključenje_usluge, ...
mjesečna_naknada_za_najam_korisničke_opreme, godišnja_naknada_za_najam_korisničke_opreme, ...
mjesečna_naknada_za_brzinu_i_promet, godišnja_naknada_za_brzinu_i_promet, ...
godišnja_promjena_naknade_za_najam_opreme_brzinu_i_promet]...
= cijeneusluga(odstupanje, PROMJENE, jednokr_naknada_za_uključenje_usluge, ...
mj_naknada_za_najam_korisničke_opreme, mj_naknada_za_brzinu_i_promet, kombin)
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

.
.
.

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

% Iznos godišnje stope promjene naknade (C) za najam opreme, internet brzinu i paket prometa
(koefcijent između -1 i 1):

godišnja_promjena_naknade_za_najam_opreme_brzinu_i_promet = PROMJENE(kombin,1)(1,1);
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

```

Slika 5.5. Prikaz utjecaja određenih parametara na postupak tehnno-ekonomskog modeliranja


5.2.3. Značajke predloženog modela s okvirom

Značajke predloženog tehno-ekonomskog modela s okvirom navedene su u tablici 5.6..

Tablica 5.6. Značajke predloženog tehno-ekonomskog modela s okvirom

Prednosti predloženog tehno-ekonomskog modela	
⇒ prikaz postojećeg stanja:	<ul style="list-style-type: none"> - procjena utjecaja pojedinih čimbenika na broj korisnika širokopolasnog Interneta na promatranom području u pojedinom trenutku - primjena svih najbitnijih metoda za vrednovanje kreiranog modela uz mogućnost predviđanja ukupnog raspona izlaznih vrijednosti za odabrane vrijednosti ulaznih parametara i procjenu vjerojatnosti pojave odabranih izlaznih vrijednosti iz dobivenog skupa
⇒ prilagodljivost:	- moguće osvježavanje novim podacima i dodatno proširivanje
⇒ tehnološka 'neutralnost':	- moguća usporedba različitih tehnoloških pristupnih rješenja (fiksnih žičnih / fiksnih bežičnih / mobilnih bežičnih)

Cilj primjene predloženog modela vezan je uz povećanje broja korisnika u ruralnim područjima - smanjenje postojećeg digitalnog jaza i poticanje korisnika na primjenu širokopolasnih tehnologija i usluga kroz ispunjavanje zahtjeva korisnika u tim područjima.



Slika 5.6. Cilj predloženog modela

5.3. Vrednovanje primjenjivosti predloženog tehno-ekonomskog modela kroz procjenu održivosti poslovnih modela uvođenja širokopojasnih pristupnih mreža u ruralnim područjima

Donošenje poslovnih odluka i analiza mogućih tehnoloških arhitektura za pružanje širokopojasnog pristupa Internetu zahtijeva holistički pristup, pri čemu je potrebno razmotriti brojne tehnološke, poslovne i regulatorne aspekte mogućih poslovnih prilika, odnosno kreirati kvalitetne i detaljne poslovne modele.

Kako je već istaknuto, povećanje broja širokopojasnih priključaka u ruralnim područjima moguće je poticati kroz definiranje optimiziranih poslovnih modela koji će stimulirati uvođenje cjenovno prihvatljivih širokopojasnih rješenja na regionalnim i lokalnim razinama, a takvi poslovni modeli pretpostavljaju uključivanje države te regionalnih i lokalnih uprava i zajednica u razvoju, izgradnji i subvencioniranju širokopojasne infrastrukture u ruralnim područjima [111].

Predloženi tehno-ekonomski model moguće je primijeniti pri razmatranju održivosti odabranih poslovnih modela te pri izboru optimalnog poslovnog modela u pojedinim ruralnim područjima. Za ruralna područja u kojima ekonomska isplativost nije značajna ili se pokaže kao negativna kreirani tehno-ekonomski model može se primijeniti za procjenu iznosa subvencija (iznosa kojeg bi trebalo izdvojiti kako bi projekt bio održiv) nužnih kako bi se zadovoljili zahtjevi operatora (isplativa ulaganja), ali i početni zahtjevi korisnika.

S obzirom na okvirom definirane zahtjeve (kriterije), nužno je vrednovanje primjenjivosti novog tehno-ekonomskog modela kroz procjenu održivosti određenih poslovnih modela uvođenja širokopojasnih pristupnih mreža u ruralnim područjima. Pri procjenama se primjenjuju sljedeće metode - scenariji, analize osjetljivosti, *Monte Carlo* simulacije, realne opcije i teorija igara. Rezultati donose procjenu održivosti odabranih poslovnih modela i definiraju uvjete pod kojima bi neodrživi modeli mogli postati održivi u ruralnim područjima te omogućuju definiranje prijedloga najprikladnijih poslovnih modela za razmatrana ruralna područja.

5.3.1. Opis odabranih poslovnih modela za vrednovanje primjenjivosti predloženog tehno-ekonomskog modela s okvirom

U svrhu vrednovanja primjenjivosti predloženog modela odabrani su poslovni modeli koji razmatraju izbor najboljih strategija za operatore koji se nalaze u konkurentskom okruženju. Budući da u ruralnim područjima često (ne postoji ili) postoji mali broj konkurentskih operatera, za analizu je odabran scenarij u kojem na promatranom području međusobno konkuriraju dva operatera (npr. privatni (monopolist) i javni (lokalna zajednica)). Nakon unosa ulaznih parametara u model i izvršavanja simulacija, na temelju rezultata provedenih simulacija moguće je pronaći najbolje strategije za oba operatera.

Ovisno o navedenim kombinacijama promjena iznosa čimbenika, ukoliko se u konkurentskom okruženju u kojem se nalaze dva operatera želi odabrati najbolja strategija za svakog od njih, moguće je promotriti sljedeće slučajeve:

- oba operatera se odlučuju na ulaganje u širokopoljnu mrežu,
- samo jedan od operatera ulaže ili
- niti jedan operator ne ulaže.

Ovisno o vrijednostima promjena tehno-ekonomskih čimbenika (odnosno iznosima koeficijenata *delta*) te o iznosima koeficijenata koji opisuju promjene broja korisnika (odnosno koeficijenata *beta*), mijenja se najbolja strategija za pojedinog operatera.

U svrhu utvrđivanja najboljih strategija za operatore, u modelu se primjenjuje teorija igara. Tablice 5.7. i 5.8. definiraju moguće kombinacije strategija za dva operatera, pri čemu oznaka 'UK' odgovara iznosu neto sadašnje vrijednosti (engl. *payoff*) koju je moguće ostvariti u pojedinom slučaju, a koja se određuje prema sljedećem: $UK = PRIHODI - TROSKOVI$. Oznaka 'D' odgovara odluci o ulaganju, a oznaka 'N' o ne ulaganju.

Tablica 5.7. Kombinacije strategija za dva operatera

Strategije		OPERATOR 2			
		N		D	
OPERATOR 1	N	UK _(1,1)	UK _(2,1)	UK _(1,3)	UK _(2,3)
	D	UK _(1,2)	UK _(2,2)	UK _(1,4)	UK _(2,4)

Tablica 5.8. Prikaz mogućih kombinacija strategija za dva operatora

	Troškovi				Prihodi			
	samo jedan da	oba da	samo jedan ne	oba ne	samo jedan da	oba da	samo jedan ne	oba ne
	ΔT	$1/2 \cdot \Delta T$	0	0	ΔP	$1/2 \cdot \Delta P$	$-\Delta P$	$-1/2 \cdot \Delta P$
1.	0	0	0	0	$B1 \cdot (\Delta 1)^2$	$1/2 \cdot B1 \cdot (\Delta 1)^2$	$-B1 \cdot (\Delta 1)^2$	$-1/2 \cdot B1 \cdot (\Delta 1)^2$
2.	$B2 \cdot (\Delta 2)^2$	$1/2 \cdot B2 \cdot (\Delta 2)^2$	0	0	0	0	0	0
3.	$B3 \cdot (\Delta 3)^2$	$1/2 \cdot B3 \cdot (\Delta 3)^2$	0	0	0	0	0	0
4.	$B4 \cdot (\Delta 4)^2$	$1/2 \cdot B4 \cdot (\Delta 4)^2$	0	0	0	0	0	0
5.	$(B1 \cdot \Delta 1 + B2 \cdot \Delta 2) \cdot \Delta 2$	$1/2 \cdot (B1 \cdot \Delta 1 + B2 \cdot \Delta 2) \cdot \Delta 2$	0	0	$(B1 \cdot \Delta 1 + B2 \cdot \Delta 2) \cdot \Delta 1$	$1/2 \cdot (B1 \cdot \Delta 1 + B2 \cdot \Delta 2) \cdot \Delta 1$	$-(B1 \cdot \Delta 1 + B2 \cdot \Delta 2) \cdot \Delta 1$	$-1/2 \cdot (B1 \cdot \Delta 1 + B2 \cdot \Delta 2) \cdot \Delta 1$
6.	$(B1 \cdot \Delta 1 + B3 \cdot \Delta 3) \cdot \Delta 3$	$1/2 \cdot (B1 \cdot \Delta 1 + B3 \cdot \Delta 3) \cdot \Delta 3$	0	0	$(B1 \cdot \Delta 1 + B3 \cdot \Delta 3) \cdot \Delta 1$	$1/2 \cdot (B1 \cdot \Delta 1 + B3 \cdot \Delta 3) \cdot \Delta 1$	$-(B1 \cdot \Delta 1 + B3 \cdot \Delta 3) \cdot \Delta 1$	$-1/2 \cdot (B1 \cdot \Delta 1 + B3 \cdot \Delta 3) \cdot \Delta 1$
7.	$(B1 \cdot \Delta 1 + B4 \cdot \Delta 4) \cdot \Delta 4$	$1/2 \cdot (B1 \cdot \Delta 1 + B4 \cdot \Delta 4) \cdot \Delta 4$	0	0	$(B1 \cdot \Delta 1 + B4 \cdot \Delta 4) \cdot \Delta 1$	$1/2 \cdot (B1 \cdot \Delta 1 + B4 \cdot \Delta 4) \cdot \Delta 1$	$-(B1 \cdot \Delta 1 + B4 \cdot \Delta 4) \cdot \Delta 1$	$-1/2 \cdot (B1 \cdot \Delta 1 + B4 \cdot \Delta 4) \cdot \Delta 1$
8.	$(B2 \cdot \Delta 2 + B3 \cdot \Delta 3) \cdot (\Delta 2 + \Delta 3)$	$1/2 \cdot (B2 \cdot \Delta 2 + B3 \cdot \Delta 3) \cdot (\Delta 2 + \Delta 3)$	0	0	0	0	0	0
9.	$(B2 \cdot \Delta 2 + B4 \cdot \Delta 4) \cdot (\Delta 2 + \Delta 4)$	$1/2 \cdot (B1 \cdot \Delta 1 + B2 \cdot \Delta 2 + B3 \cdot \Delta 3) \cdot (\Delta 1 + \Delta 2 + \Delta 3)$	0	0	0	0	0	0
10.	$(B3 \cdot \Delta 3 + B4 \cdot \Delta 4) \cdot (\Delta 3 + \Delta 4)$	$1/2 \cdot (B3 \cdot \Delta 3 + B4 \cdot \Delta 4) \cdot (\Delta 3 + \Delta 4)$	0	0	0	0	0	0
11.	$(B1 \cdot \Delta 1 + B2 \cdot \Delta 2 + B3 \cdot \Delta 3) \cdot (\Delta 2 + \Delta 3)$	$1/2 \cdot (B1 \cdot \Delta 1 + B2 \cdot \Delta 2 + B3 \cdot \Delta 3) \cdot (\Delta 2 + \Delta 3)$	0	0	$(B1 \cdot \Delta 1 + B2 \cdot \Delta 2 + B3 \cdot \Delta 3) \cdot \Delta 1$	$1/2 \cdot (B1 \cdot \Delta 1 + B2 \cdot \Delta 2 + B3 \cdot \Delta 3) \cdot \Delta 1$	$-(B1 \cdot \Delta 1 + B2 \cdot \Delta 2 + B3 \cdot \Delta 3) \cdot \Delta 1$	$-1/2 \cdot (B1 \cdot \Delta 1 + B2 \cdot \Delta 2 + B3 \cdot \Delta 3) \cdot \Delta 1$
12.	$(B1 \cdot \Delta 1 + B2 \cdot \Delta 2 + B4 \cdot \Delta 4) \cdot (\Delta 2 + \Delta 4)$	$1/2 \cdot (B1 \cdot \Delta 1 + B2 \cdot \Delta 2 + B4 \cdot \Delta 4) \cdot (\Delta 2 + \Delta 4)$	0	0	$(B1 \cdot \Delta 1 + B2 \cdot \Delta 2 + B4 \cdot \Delta 4) \cdot \Delta 1$	$1/2 \cdot (B1 \cdot \Delta 1 + B2 \cdot \Delta 2 + B4 \cdot \Delta 4) \cdot \Delta 1$	$-(B1 \cdot \Delta 1 + B2 \cdot \Delta 2 + B4 \cdot \Delta 4) \cdot \Delta 1$	$-1/2 \cdot (B1 \cdot \Delta 1 + B2 \cdot \Delta 2 + B4 \cdot \Delta 4) \cdot \Delta 1$
13.	$(B1 \cdot \Delta 1 + B3 \cdot \Delta 3 + B4 \cdot \Delta 4) \cdot (\Delta 3 + \Delta 4)$	$1/2 \cdot (B1 \cdot \Delta 1 + B3 \cdot \Delta 3 + B4 \cdot \Delta 4) \cdot (\Delta 3 + \Delta 4)$	0	0	$(B1 \cdot \Delta 1 + B3 \cdot \Delta 3 + B4 \cdot \Delta 4) \cdot \Delta 1$	$1/2 \cdot (B1 \cdot \Delta 1 + B3 \cdot \Delta 3 + B4 \cdot \Delta 4) \cdot \Delta 1$	$-(B1 \cdot \Delta 1 + B3 \cdot \Delta 3 + B4 \cdot \Delta 4) \cdot \Delta 1$	$-1/2 \cdot (B1 \cdot \Delta 1 + B3 \cdot \Delta 3 + B4 \cdot \Delta 4) \cdot \Delta 1$
14.	$(B2 \cdot \Delta 2 + B3 \cdot \Delta 3 + B4 \cdot \Delta 4) \cdot (\Delta 2 + \Delta 3 + \Delta 4)$	$1/2 \cdot (B2 \cdot \Delta 2 + B3 \cdot \Delta 3 + B4 \cdot \Delta 4) \cdot (\Delta 2 + \Delta 3 + \Delta 4)$	0	0	0	0	0	0
15.	$(B1 \cdot \Delta 1 + B2 \cdot \Delta 2 + B3 \cdot \Delta 3 + B4 \cdot \Delta 4) \cdot (\Delta 2 + \Delta 3 + \Delta 4)$	$1/2 \cdot (B1 \cdot \Delta 1 + B2 \cdot \Delta 2 + B3 \cdot \Delta 3 + B4 \cdot \Delta 4) \cdot (\Delta 2 + \Delta 3 + \Delta 4)$	0	0	$(B1 \cdot \Delta 1 + B2 \cdot \Delta 2 + B3 \cdot \Delta 3 + B4 \cdot \Delta 4) \cdot \Delta 1$	$1/2 \cdot (B1 \cdot \Delta 1 + B2 \cdot \Delta 2 + B3 \cdot \Delta 3 + B4 \cdot \Delta 4) \cdot \Delta 1$	$-(B1 \cdot \Delta 1 + B2 \cdot \Delta 2 + B3 \cdot \Delta 3 + B4 \cdot \Delta 4) \cdot \Delta 1$	$-1/2 \cdot (B1 \cdot \Delta 1 + B2 \cdot \Delta 2 + B3 \cdot \Delta 3 + B4 \cdot \Delta 4) \cdot \Delta 1$

Prikazan je kod koji opisuje odabrano konkurentsko okruženje, odnosno razmatra definirani broj operatora na tržištu te traži najbolje strategije za dva konkurentna operatora. Navedeni dio koda ubacuje se na mjesto koje je naznačeno u petlji unutar funkcije za određivanje parametara koji opisuju promjene tehnno-ekonomskih cimbenika u prethodnom poglavlju.

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
STRATEGIJE:
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

```

Definiraj osnovnu matricu s formulama postavljanjem formula u stupce matrice (prema tablici koja prikazuje moguće kombinacije strategija za dva operatora)

Za svaki m od 1 do 15

```

Postavi osnovna_matrica(m,1)=deltaT(m);
Postavi osnovna_matrica(m,2)=0.5*deltaT(m);
Postavi osnovna_matrica(m,3)=0;
Postavi osnovna_matrica(m,4)=0;
Postavi osnovna_matrica(m,5)=deltaP(m);
Postavi osnovna_matrica(m,6)=0.5*deltaP(m);
Postavi osnovna_matrica(m,7)=-deltaP(m);
Postavi osnovna_matrica(m,8)=-0.5*deltaP(m);

```

Kraj

Za svaki rbr od 1 do 15

```

Postavi redni_broj_strategije=rbr+((kombinacija-1)*15);

```

```

Postavi rbr_str=redni_broj_strategije;

```

Usporedi koristi (prema tablici koja opisuje kombinacije strategija za dva operatora)

Definiraj matricu $UK = \{0\ 0, 0\ 0; 0\ 0, 0\ 0\}$ prema tablici sa kombinacijama strategija za dva operatora

```

Postavi UK(1,1)={osnovna_matrica(rbr,8)-osnovna_matrica(rbr,4)};
Postavi UK(1,2)={osnovna_matrica(rbr,8)-osnovna_matrica(rbr,4)};
Postavi UK(1,3)={osnovna_matrica(rbr,7)-osnovna_matrica(rbr,3)};
Postavi UK(1,4)={osnovna_matrica(rbr,5)-osnovna_matrica(rbr,1)};
Postavi UK(2,1)={osnovna_matrica(rbr,5)-osnovna_matrica(rbr,1)};
Postavi UK(2,2)={osnovna_matrica(rbr,7)-osnovna_matrica(rbr,3)};
Postavi UK(2,3)={osnovna_matrica(rbr,6)-osnovna_matrica(rbr,2)};
Postavi UK(2,4)={osnovna_matrica(rbr,6)-osnovna_matrica(rbr,2)};

```

Primjeni teoriju igara za izbor najoptimalnijih strategija

```

Postavi U=zeros(4,2);
Postavi U(1,1)=UK{1,1}; U(1,2)=UK{1,2}; U(2,1)=UK{1,3}; U(2,2)=UK{1,4};
U(3,1)=UK{2,1}; U(3,2)=UK{2,2}; U(4,1)=UK{2,3}; U(4,2)=UK{2,4};

```

Definiraj igru s dva operatora pri čemu svaki ima dvije strategije (N=ne ulagati/D=ulagati): $M=[2 \ 2]$;

Pozovi funkciju za izračun matrice A koja sadrži kombinacije strategija operatora u ravnoteži i koristi uz primjenu funkcije $np\ g^*$ koja razmatra Nash-ovu ravnotežu: $[A, payoff] = np\ g(M, U)$;

Postavi $A11=A(1,1)$;

Postavi $A12=A(1,2)$;

Postavi $A21=A(2,1)$;

Postavi $A22=A(2,2)$;

Izbor opcija za pojedinog operatora ('NE'=ne ulagati / 'DA'=ulagati / 'K'=kombinacija strategija) usporedbom strategija i koristi

... kod iz PRILOGA...

Izbor najbolje strategije za operatore:

svaki_payoff(kombinacija,:)=payoff;

Odredi sumu koristi: *suma_payoff(kombinacija,1)=*

svaki_payoff(kombinacija,1)+svaki_payoff(kombinacija,2);

Za svaki h od 1 do 4,

PROMJENE(kombinacija,h)=delta(h);

Kraj

najbolje(kombinacija,:) = {suma_payoff(kombinacija,1), PROMJENE(kombinacija,:)};

Sortiranje redaka s koeficijentima u matrici PROMJENE prema njihovom utjecaju na vrijednosti *payoff-a*:

Najbolje_strategije(rbr_str,1)=STRATEGIJA();

Kraj

%%%%%%%%%

Kreirani kod temelji se na opisanom scenariju u kojem se na određenom području nalaze dva operatora. Rezultati dobiveni simuliranjem navedenog scenarija opisani su u idućem poglavlju rada te omogućuju vrednovanje primjenjivosti kreiranog modela.

* Funkcija koja se koristi za određivanje Nash-ove ravnoteže, *np g*, preuzeta je sa linka <http://www.mathworks.com/>

5.3.2. Analiza dobivenih rezultata

U kreiranom testnom scenariju za vrednovanje modela se odabrani parametar *delta* mijenja u koracima od 0.5 u intervalu od -1 do 1. Odabrani broj ponavljanja, tj. koraka potrebnih za procjenu realnih opcija uz primjenu *Monte Carlo* simulacija u testnom scenariju iznosi 1000, dok je odabrani broj koraka simulacije potrebnih za procjenu utjecaja nesigurnosti ulaznih vrijednosti na vrijednost rezultata 100. Simulirano je ukupno 37 500 različitih strategija prikazanih pomoću klasifikacijskog stabla te ukupno 2 500 različitih kombinacija. Za ulazne podatke koriste se predefinirane vrijednosti. Dobiveni rezultati prikazani su grafički pomoću stabla odlučivanja i histograma, te opisno, pomoću klasifikacijskih pravila.

Kreirano klasifikacijsko stablo odlučivanja sastoji se od čvorova, grana i listova. Čvorovi prikazuju atribute, grane njihove vrijednosti, a listovi klase, odnosno vrijednosti završnog klasifikacijskog atributa na temelju kojeg se vrši donošenje odluka o izboru prikladne strategije. Točke grananja prikazuju testiranje određenog atributa koji se uspoređuje s određenom konstantom, a listovi set klasifikacija. Svaki novi primjer koji još nije klasificiran potiskuje se prema dnu stabla sve dok ne dođe do nekog lista koji mu može pridati klasu.

Objekt sastavljen od atributa i vrijednosti predstavlja jednu od putanja po stablu, od korijenskog atributa do klase odluke. Kako bi se stvorila odluka, kreće se od korijena stabla kojeg čini atribut s najmanjom izračunatom entropijom. Zatim se granama koje predstavljaju vrijednosti tog atributa stiže do sljedećeg atributa s najmanjom entropijom među preostalim atributima. Postupak se iterativno ponavlja sve dok ne preostanu čvorovi čije grane sadrže isključivo listove iste kategorije ili klase.

Kreirano stablo, dobiveno kao rezultat simulacije, prikazano je na idućoj stranici. Ono omogućuje donošenje odluka o izboru optimalnih kombinacija strategija za dva operatora. Tako na primjer, u slučaju da se oba operatora odluče na ulaganje u širokopojasnu pristupnu mrežu u razmatranom ruralnom području, što je na slici 5.7. naznačeno oznakama 'DD', budući da postoji više načina za ostvarenje optimalnih modela, operatori tada mogu odabrati kombinacije promjena pojedinih parametara *delta* (označenih oznakama *d1* do *d4*, kako je opisano u kodu) koje im najviše odgovaraju u pojedinom trenutku.

Dakle, ukoliko se oba operatora odluče na ulaganje u širokopojasnu pristupnu infrastrukturu ('DD') u razmatranom ruralnom području, pri čemu postoji više načina za ostvarenje optimalnih modela, operatori mogu odabrati kombinacije promjena pojedinih parametara *delta* (promjena cijene usluga - *d1*, područja pokrivanja - *d2*, propusnosti po korisniku - *d3* i brzine po korisniku - *d4*) koje im najviše odgovaraju.


Ukoliko su pretpostavljene sljedeće promjene parametara:

$$d2 \geq 0.75, d3 < 0.75 \text{ i } d4 \geq 0.25,$$

odnosno, ukoliko oba operatora planiraju minimalno povećanje područja pokrivanja od 75%, maksimalno povećanje propusnosti po korisniku od 75%, te minimalno povećanje brzine po korisniku od 25%, odabire se put po stablu prikazan na slici 5.8.. Tada vrijednosti parametra *d1* treba biti:

$$d1 \geq 0.75,$$

odnosno, cijenu usluga po korisniku oba operatora trebaju povećati minimalno za 75% kako bi ulaganja u širokopojasnu pristupnu infrastrukturu bila isplativa za oba operatora. Moguće su i brojne druge kombinacije vrijednosti navedenih parametara.



Slika 5.8. Izbor optimalnih strategija za operatore u konkurentskom okruženju

Budući da se u kreiranom testnom scenariju za vrednovanje modela odabrani parametri *delta* mijenjaju u koracima od 0.5 u intervalu od -1 do 1, pri čemu vrijednost 1 predstavlja sto postotno povećanje vrijednosti, a -1 sto postotno smanjenje vrijednosti parametra, promjene vrijednosti parametara na grafu prikazane su s određenim rasponima, odnosno promjene njihovih vrijednosti izražene su pomoću vrijednosti: -0.75, -0.25, 0.25 i 0.75.

Stablo odlučivanja moguće je transformirati u klasifikacijska pravila budući da svaki list u stablu predstavlja jedno pravilo, kako je prikazano na slici 5.9.. Klasifikacijska pravila omogućuju jednostavno dodavanje novog pravila postojećem skupu.

```

Decision tree for classification:


1 if d4<0.25 then node 2 else node 3
2 if d1<0.25 then node 4 else node 5
3 if d1<0.25 then node 6 else node 7
4 if d1<0.25 then node 8 else node 9
5 class = DD
6 if d1<0.75 then node 10 else node 11
7 if d1<0.25 then node 12 else node 13
8 if d1<0.75 then node 14 else node 15
9 if d2<0.25 then node 16 else node 17
10 if d2<0.75 then node 18 else node 19
11 if d2<0.75 then node 20 else node 21
12 class = KK
13 if d3<0.25 then node 22 else node 23
14 class = DD
15 if d2<0.75 then node 24 else node 25
16 if d3<0.25 then node 26 else node 27
17 if d2<0.25 then node 28 else node 29
18 if d3<0.75 then node 30 else node 31
19 if d4<0.25 then node 32 else node 33
20 if d2<0.25 then node 34 else node 35
21 if d3<0.75 then node 36 else node 37
22 if d1<0.75 then node 38 else node 39
23 if d1<0.75 then node 40 else node 41
24 class = DD
25 if d4<0.75 then node 42 else node 43
26 if d3<0.25 then node 44 else node 45
27 class = DD
.
.
.
165 class = DD
166 if d4<0.75 then node 170 else node 171
167 class = DD
168 class = DD
169 class = KK
170 class = DD
171 class = KK

```

Slika 5.9. Prikaz dobivenog ispisa klasifikacijskih pravila

Klasifikacijska pravila predstavljaju alternativu stablu odluke. Preduvjet-pravila predstavljaju niz testova. Preduvjeti su povezani logičkim "I" operatorom. Zaključak prikazuje klasu ili klase koje odgovaraju primjerima koji su zadovoljili određeno pravilo.

Dobiveni histogrami prikazani na slici 5.10. grafički prikazuju učestalosti, odnosno frekvencije pojavljivanja predviđenih vrijednosti te grupiraju izlazne vrijednosti simulacije u određeni broj intervala kako bi se dobivene rezultate moglo što jednostavnije iščitati.



Slika 5.10. Histogrami s rezultatima

Donje osi prikazuju raspone dobivenih vrijednosti rezultata. Najveće vrijednosti na skali frekvencija s desne strane grafova su frekvencije grupe intervala koji sadrže najveći broj predviđenih vrijednosti. Prikazani rezultati simulacija uključuju raspon vrijednosti procijenjenih neto sadašnjih vrijednosti te nužnih iznosa subvencija, odnosno poticaja.

Rezultati simulacija su prikazani i brojačno, prema prikazu na slici 5.11., pri čemu su određene vrijednosti koeficijenta *beta* sadržane u vektoru *KOEFICIJENTI*, maksimalni mogući iznos realne opcije, prosječni iznos subvencija (kako bi razmatrani poslovni model bio isplativ), kao i utvrđeni najbolji predloženi iznosi parametara *delta* (koji opisuju promjene cijene, područja pokrivanja, propusnosti i brzine) te redni broj predložene optimalne kombinacije, kako je prikazano ispod. Analogno je moguće vrednovati isplativost i drugih proizvoljnih poslovnih modela.

```
KOEFICIJENTI = [ 1.0000 0.7663 0.2085 -0.0101]
maks_realna_opcija = 1.2104e+007
prosjecni_iznos_subvencije = 7.8872e+005
predlozene_PROMJENE = [1.0000 -0.5000 0 0]
redni_broj_predlozene_kombinacije = 858
```

Slika 5.11. Numerički rezultati

Dakle, u kreiranom tehno-ekonomskom modelu dobiveni rezultati simulacija prikazuju se grafički pomoću stabla odlučivanja, opisno pomoću klasifikacijskih pravila te pomoću histograma. Kreirano stablo omogućuje donošenje odluka o izboru optimalnih kombinacija strategija za operatore. Pri tome je preciznost dobivenog proračuna moguće je povećati smanjenjem koraka. Isto tako, i intervale promjena vrijednosti parametara moguće je proizvoljno ograničiti.

Nadalje, u kreiranom modelu metode za planiranje scenarija, *Monte Carlo* simulacije, realne opcije i teorija igara primjenjuju se pri ograničavanju nesigurnosti vezanih uz procjene isplativosti analiziranih projekata. Odabrani broj ponavljanja, tj. koraka potrebnih za procjenu realnih opcija uz primjenu *Monte Carlo* simulacija i odabrani broj koraka simulacije potrebnih za procjenu utjecaja nesigurnosti ulaznih vrijednosti na vrijednost rezultata utječu na ukupan broj simuliranih strategija i kombinacija. Povećanjem broja tih koraka postiže se povećanje preciznosti dobivenih rezultata.

Nakon provedenih simulacija, dobivaju se rasponi mogućih neto sadašnjih vrijednosti prikazani pomoću histograma. Na temelju dobivenog raspona vrijednosti moguće je preciznije utvrditi vjerojatnost pojave pojedinih vrijednosti. U slučaju kada rezultati provedenih analiza pokažu da su pojedini projekti bez subvencija jednostavno neisplativi, kreirani tehno-ekonomski model omogućuje određivanje nužnih iznosa subvencija.

6. ZAKLJUČAK

Razvoj širokopojasnog pristupa Internetu i dostupnost širokopojasnih usluga pokreće ekonomski rast, povećava stopu zaposlenosti i konkurentnosti, a dostupnost širokopojasnog pristupa povećava kvalitetu života krajnjih korisnika. Kako je navedeno u uvodnom dijelu rada, najbitniji razlozi primjene širokopojasnog pristupa Internetu vezani su uz njegove brojne prednosti u odnosu na uskopojasni pristup, poput većih dostupnih brzina prijenosa podataka, manjih kašnjenja pri prijenosu podataka te mogućnosti pristupa internetskim uslugama visoke kvalitete i uslugama koje zahtijevaju prijenos velikih količina podataka u realnom vremenu.

Kako je istaknuto u drugom poglavlju rada, unatoč brojnim koristima koje proizlaze iz primjene širokopojasnih pristupnih tehnologija i usluga te važnosti njegove primjene, danas postoji mnoštvo područja u Europi i Svijetu u kojima širokopojasni pristup Internetu nije dostupan, pa se povećavaju razlike između stanovnika koji imaju te onih koji nemaju mogućnost pristupa informacijsko-komunikacijskim tehnologijama i uslugama. Nedovoljna dostupnost širokopojasnog pristupa Internetu karakteristična je za slabije naseljena, ruralna područja. Stoga su u radu ukratko navedeni postojeći problemi vezani uz uvođenje širokopojasnog pristupa Internetu u ruralnim područjima te je istaknut problem nejednake dostupnosti širokopojasnog pristupa Internetu između ruralnih i urbanih područja, tzv. digitalni jaz.

Kako bi se utvrdilo postojanje digitalnog jaza između pojedinih ruralnih i urbanih područja, u drugom poglavlju rada je u odabranom studijskom primjeru načinjena procjena broja širokopojasnih priključaka u ruralnim i urbanim područjima uz primjenu logističke funkcije te je provedena analiza dobivenih rezultata koja je potvrdila postojanje jaza. Stoga su navedene općenite smjernice i metode za smanjivanje digitalnog jaza na kojima se temelje daljnja istraživanja u disertaciji te su izdvojena širokopojasna pristupna rješenja prikladna za ruralna područja.

Treće poglavlje rada obuhvaća daljnje razlaganje problematike uvođenja širokopojasnog pristupa Internetu. Budući da sama tehnička superiornost pojedinih tehnologija ne garantira njihov uspjeh na telekomunikacijskim tržištima te uslijed ubrzanog razvoja naprednih telekomunikacijskih sustava i usluga, potražnja za tehnološko-ekonomskim modelima je sve veća jer takvi modeli daju odgovore na mnoga važna pitanja. Zbog lakše usporedbe različitih rješenja primijenjenih u

brojnim provedenim studijama i analizama koje razmatraju tehničke i ekonomske aspekte uvođenja širokopojsnih pristupnih mreža, u trećem poglavlju rada je načinjena kategorizacija i prikaz najrelevantnijih tehno-ekonomskih metoda i modela iz literature. Pri tome su razmotrene i opisane postojeće tehno-ekonomske metode za vrednovanje uvođenja širokopojsnog pristupa Internetu - planiranje tehno-ekonomskog modela, kreiranje modela (koje uključuje postupke za modeliranje tržišta, pristupnih mreža, cijena usluga, prihoda i troškova), analiziranje održivosti i ocjenjivanje isplativosti modela te vrednovanje modela (koje uključuje primjenu analiza osjetljivosti, *Monte Carlo* simulacija, teorije igara i realnih opcija).

U četvrtom poglavlju rada prikazana je metodologija za rješavanje problematike uvođenja širokopojsnog pristupa Internetu u ruralnim područjima, uz određivanje čimbenika koji su bitni za uvođenje širokopojsnog pristupa Internetu u tim područjima. U ovoj cjelini rada razmotrena su dva aspekta – aspekt mrežnih operatora te onaj potencijalnih krajnjih korisnika. Ovi pristupi uključuju provedbu kvantitativnih analiza (regresijske analize ključnih socio-demografskih čimbenika bitnih za uvođenje širokopojsnog pristupa u ruralnim područjima i analize ključnih tehno-ekonomskih čimbenika koji utječu na operatorovu odluku o uvođenju širokopojsnog pristupa Internetu u ruralnim područjima) te provedbu kvalitativnih analiza (analize podataka o potencijalnim krajnjim korisnicima novih širokopojsnih usluga u ruralnim područjima i analize ključnih čimbenika pri investiranju u širokopojsni pristup u ruralnim područjima iz perspektive mrežnih operatora). Rezultati provedenih analiza primijenjeni su pri daljnjem vrednovanju tehničkih mogućnosti i ekonomskih aspekata uvođenja širokopojsnog pristupa Internetu u ruralnim područjima.

Odgovore na sljedeća pitanja vezana uz širokopojsni pristup - "*Tko?*", "*Gdje?*" i "*Kada?*" ulaže u širokopojsnu pristupnu infrastrukturu, razmotrena kroz brojna provedena istraživanja referencirana u popisu literature, nužni je dopuniti i odgovorom na pitanje "*Na koji način?*" razvijati širokopojsne pristupne mreže u ruralnim područjima, područjima koja se često smatraju neatraktivnima za ulaganja, te kako ostvariti uz to vezane brojne koristi (za korisnike, ali i operatore). Naime, budući da se stanovnici koji naseljavaju ruralna područja često razlikuju prema svojim potrebama, mogućnostima te stilu i načinu života od stanovnika urbanih područja, prilikom razmatranja tehno-ekonomskih aspekata implementacije širokopojsnog pristupa u ruralnim područjima potrebno je pažnju posvetiti upravo specifičnim potrebama i zahtjevima ruralnog stanovništva vezanima uz primjenu širokopojsnih tehnologija i usluga. U petom poglavlju rada stoga se istražuju načini na koje se tehno-ekonomske metode modeliranja mogu

koristiti pri povezivanju analiziranih tehnički i ekonomski orijentiranih zahtjeva korisnika (zahtjeva za kvalitetom usluga, količinom prometa, pristupnom brzinom, cijenom usluga) te zahtjeva operatora za isplativošću odabranih tehnoloških rješenja u ruralnim područjima. Zato je definiran novi okvir za analizu i modeliranje eksplicitno definiranih korisničkih zahtjeva koji služi kao nadogradnja tehno-ekonomskog modela i omogućuje detaljniju analizu specifičnosti različitih ruralnih područja temeljenu na dostupnim podacima.

Opisan je predloženi nadograđeni tehno-ekonomski model koji se temelji na kriterijima i okviru za vrednovanje uvođenja širokopojasnog pristupa u ruralnim područjima. Predloženim nadograđenim modelom se povezuju potrebe korisnika u ruralnim područjima za širokopojasnim tehnologijama i uslugama (zahtjevi na cijenu i kvalitetu širokopojasnih usluga, količinu prometa i brzinu pristupa) s interesima mrežnih operatora (koji obuhvaćaju isplative poslovne modele). Primjena predloženog modela trebala bi rezultirati dostupnošću širokopojasnog pristupa Internetu u ruralnim područjima prilagođenom zahtjevima korisnika te smanjenjem postojećeg digitalnog jaza između ruralnih i urbanih područja.

Nadalje, u cilju vrednovanja korisnosti predloženog modela u petom poglavlju rada odabrani su poslovni modeli u ruralnim područjima koji razmatraju izbor najboljih strategija za operatore u konkurentskom okruženju te je načinjena analiza dobivenih rezultata. Kreirani model koristi metode tehno-ekonomskog modeliranja pri analizi i usporedbi izvedivosti različitih alternativnih širokopojasnih pristupnih rješenja - fiksnih žičnih, fiksnih bežičnih i mobilnih bežičnih rješenja. Metode za planiranje scenarija, *Monte Carlo* simulacije, realne opcije i teorija igara primjenjuju se pri ograničavanju nesigurnosti vezanih uz procjene isplativosti analiziranih projekata. Nakon provedenih simulacija, kao rezultati, dobivaju se rasponi mogućih izlaznih vrijednosti prikazani pomoću histograma. Na temelju dobivenog raspona vrijednosti moguće je preciznije utvrditi vjerojatnost pojave točno određenih vrijednosti.

U slučaju kada rezultati provedenih analiza ukažu na činjenicu da neisplativost pojedinih projekata ulaganja u širokopojasnu infrastrukturu nije samo rezultat neodgovarajućih poslovnih modela, već da su pojedini projekti bez subvencija jednostavno neostvarivi, kreirani tehno-ekonomski model omogućuje određivanje nužnih iznosa subvencija kako bi planirani investicijski projekti u ruralnim područjima bili isplativi.

Nužno je navesti i postojeća ograničenja kreiranog tehno-ekonomskog modela. Naime, tehno-ekonomski modeli su, kao i svi znanstveni modeli, pojednostavljenja složenije stvarnosti. Potencijalni opseg tehno-ekonomskih modela je vrlo širok, te se proteže od predefiniranih tehničkih zahtjeva do različitih poslovnih strategija. Budući da je definiranje odgovarajućeg opsega i razine detalja u modelu bitno za postizanje pouzdanih i relevantnih rezultata analiza, prilikom izbora opsega modela bilo je potrebno pažljivo razmotriti sve činjenice. Sukladno tome, glavno ograničenje predstavljala je činjenica da tehno-ekonomski modeli proizlaze iz odluka donesenih tijekom procesa definiranja problema te procesa modeliranja.

Postojanje više alternativnih scenarija i stupnjeva slobode u svakom od područja modeliranja moglo je rezultirati kreiranjem pretjerano složenog modela. Stoga je posebna pozornost posvećena ustupcima između opsega i složenosti modela - model je detaljan i točan u fokusu područja, dok je za manje važna područja nepotrebna složenost izostavljena.

Primijenjene tehno-ekonomske metode za modeliranje odabranih tehničkih arhitektura, mogu se dalje razvijati i proširivati. Poboljšanja predloženog modela se mogu izvršiti u svakom od koraka u procesu tehno-ekonomskog modeliranja. Jedan od postupaka koje je moguće dodatno modelirati odnosi se na definiranje klasa usluga. Budući da je kreirani model u pojedinim područjima pojednostavljen, pretpostavljeno je kako je svim korisnicima ponuđena ista klasa usluga (tj. usluge uz iste brzine pristupa, raspoložive količine prometa te cijene). Model je moguće proširiti kako bi sadržavao veći broj različitih dostupnih klasa usluga, između kojih bi korisnici mogli odabrati onu koja im najviše odgovara. Međutim, i ovaj pojednostavljeni model omogućuje analizu utjecaja unosa rezultata iz kreiranog okvira u tehno-ekonomski model te uvid u dobivene rezultate simulacija.

Nadalje, prilikom kreiranja modela u obzir je uzeta činjenica da je dostupni skup ulaznih podataka često ograničen. Stoga su prilikom modeliranja kriterija unutar predloženog okvira primijenjeni rezultati parametarske regresijske analize nad dostupnim podacima. Primijenjeni su podaci o vrijednostima parametara za koje je pretpostavljeno kako značajno utječu na broj širokopojasnih priključaka. Dakle, procijenjene su vrijednosti parametara u predefiniranom obliku. Nakon toga su izostavljeni nerelevantni parametri. Za razliku od parametarske, u neparametarskoj analizi je, uz procjenu vrijednosti parametara, cilj procijeniti i oblik samog modela budući da se početni model sažima nakon izostavljanja nerelevantnih parametara. Dakle, za slučaj kada su dostupni podaci o velikom broju parametara, model bi bilo moguće dograditi

kako bi omogućio primjenu rezultata neparametarske regresijske analize u kojoj se značajni parametri određuju u naknadnim koracima analize, dok se ostali parametri izostavljaju bez gubitaka informacije.

Isto tako, budući da se procjene u modelu temelje na prikupljenim ulaznim podacima te da se točnost proračuna uvelike zasniva na točnosti primijenjenih ulaznih podataka, nužno je pri modeliranju koristiti što ažurnije podatke iz relevantnih izvora. Učinkovitost primjene kreiranog modela temelji se na pretpostavci o mogućnosti pristupa ažuriranim i točnim objavljenim podacima, kako je predloženo i novim europskim preporukama koje definiraju nužne preuvjete za provedbu strožih empirijskih analiza.

Kreirani model je modularan i lako bi mogao biti primijenjen na različite scenarije. Time je ostavljen prostor za daljnja istraživanja koja mogu obuhvaćati analizu različitih tehnologija na sličan način kao što su u ovoj disertaciji analizirane odabrane širokopoljasne pristupne tehnologije.

Popis slika

Slika 2.1.	Mrežna arhitektura	17
Slika 2.2.	Sudionici i uloge na telekomunikacijskim tržištima	18
Slika 2.3.	Procesi usvajanja, razvoja i implementacije širokopojasnog pristupa	19
Slika 2.4.	Usporedba žičnih i bežičnih pristupnih rješenja	29
Slika 2.5.	Kvantitativne i kvalitativne mjere ruralnosti	30
Slika 2.6.	Digitalni jaz između ruralnih i urbanih županija	39
Slika 2.7.	Procjena broja širokopojasnih priključaka po glavi stanovnika u ruralnim i urbanim županijama	41
Slika 3.1.	Tehno-ekonomski postupci	49
Slika 3.2.	Tehno-ekonomski modeli	50
Slika 3.3.	Različiti sudionici na telekomunikacijskim tržištima	53
Slika 3.4.	Faze razvoja tehnologija i usluga na telekomunikacijskom tržištu	54
Slika 3.5.	Rogersov i Bassov model difuzije	56
Slika 3.6.	Fisher-Pryov i Gompertzov model prihvaćanja novih tehnologija i usluga	57
Slika 3.7.	Primjena dostupnih podataka pri dimenzioniranju pristupnih mreža	58
Slika 3.8.	Strukture žičnih vodova postavljenih duž ulice te dijagonalno	59
Slika 3.9.	Strukture pokrivanja područja bežičnim signalom	59
Slika 3.10.	Planiranje lokacija baznih stanica pri pokrivanju područja bežičnim signalom	60
Slika 3.11.	Cijene usluga širokopojasnog pristupa Internetu u razdoblju od 2003. do 2010. godine	61
Slika 3.12.	Porast broja pretplatnika mobilnih usluga i broja korisnika Interneta	62
Slika 3.13.	Okvir za modeliranje prihoda	63

Slika 3.14.	Okvir za modeliranje troškova	65
Slika 3.15.	Prikaz novčanog tijeka	66
Slika 3.16.	Okvir za modeliranje financijske isplativosti	67
Slika 3.17.	Okvir za modeliranje financijske održivosti	67
Slika 3.18.	Okvir za modeliranje neto sadašnjih vrijednosti	69
Slika 3.19.	Odnos između neto sadašnje vrijednosti, diskontne stope i interne stope rentabilnosti	70
Slika 3.20.	Moguće raspodjele vjerojatnosti neizvjesnih varijabli	71
Slika 3.21.	Analiza osjetljivosti neto sadašnje vrijednosti na promjene ulaznih faktora	72
Slika 3.22.	Izbor optimalnih strategija dvaju sudionika na telekomunikacijskom tržištu	75
Slika 3.23.	Utjecaj realnih opcija na iznose neto sadašnjih vrijednosti	75
Slika 3.24.	Okvirom definirane realne opcije	76
Slika 3.25.	Model dopunjen okvirom koji definira industrijske arhitekture	82
Slika 3.26.	Hijerarhija ruralnih scenarija	89
Slika 3.27.	ADSL, WiMAX, PLC i mobilne 3G (UMTS) / 4G (LTE) pristupne mreže	91
Slika 3.28.	Usporedba isplativosti fiksnih žičnih i fiksnih bežičnih širokopolasnih pristupnih rješenja	92
Slika 3.29.	Usporedba isplativosti fiksnih žičnih i bežičnih pristupnih rješenja	93
Slika 3.30.	Usporedba isplativosti mobilnih pristupnih rješenja	94
Slika 3.31.	Usporedba isplativosti fiksnih i mobilnih bežičnih pristupnih rješenja	94
Slika 4.1.	Regresijska veza između čimbenika	102
Slika 4.2.	Kriteriji za Durbin-Watsonov test autokorelacije	111
Slika 4.3.	Prikaz relevantnih čimbenika za usvajanje i uvođenje širokopolasnih rješenja	116

Slika 4.4.	Prikaz udjela Internet korisnika prema dobi, zaposlenosti i stupnju obrazovanja te korisnika širokopojasnog pristupa Internetu	119
Slika 4.5.	Prikaz broja priključaka širokopojasnog Interneta te dostupnih javnih e-usluga	121
Slika 4.6.	Dijagrami raspršenja čestica pri korelacijama između stope usvajanja širokopojasnog pristupa Internetu te nezavisnih varijabli - broja stanovnika, gustoće naseljenosti stanovništva i bruto domaćeg proizvoda po glavi stanovnika	126
Slika 4.7.	Utjecaj socio-demografskih i ekonomskih čimbenika na primjenu širokopojasnog Interneta u ruralnim te urbanim županijama	131
Slika 5.1.	Prijedlog tehno-ekonomskog modela s dodatnim okvirom	142
Slika 5.2.	Zahtjevi krajnjih korisnika i interesi operatora	145
Slika 5.3.	Prikaz odabrane problematike	146
Slika 5.4.	Prikaz funkcija u modelu	147
Slika 5.5.	Prikaz utjecaja određenih parametara na postupak tehno-ekonomskog modeliranja	163
Slika 5.6.	Cilj predloženog modela	164
Slika 5.7.	Klasifikacijsko stablo odlučivanja	171
Slika 5.8.	Izbor optimalnih strategija za operatore u konkurentskom okruženju	172
Slika 5.9.	Prikaz dobivenog ispisa klasifikacijskih pravila	173
Slika 5.10.	Histogrami s rezultatima	174
Slika 5.11.	Numerički rezultati	175

Popis tablica

Tablica 2.1.	Razlozi poticanja širokopojasnog pristupa Internetu	20
Tablica 2.2.	Očekivane koristi od širokopojasnog pristupa Internetu	21
Tablica 2.3.	Vrste širokopojasnih tehnologija	22
Tablica 2.4.	Usporedba širokopojasnih pristupnih tehnologija	27
Tablica 2.5.	Prikaz širokopojasnih pristupnih rješenja	28
Tablica 2.6.	Kvantitativne i kvalitativne mjere ruralnosti područja	31
Tablica 2.7.	Kategorizacija hrvatskih županija	33
Tablica 2.8.	Model izdvajanja urbanih naselja	34
Tablica 2.9.	Rezultati procjene broja širokopojasnih priključaka logističkom funkcijom	40
Tablica 3.1.	Pregled istraživačkih projekata vezanih uz tehno-ekonomske aspekte razvoja i implementacije širokopojasnih tehnologija i usluga	48
Tablica 3.2.	Usporedni pregled provedenih tehno-ekonomskih analiza	78
Tablica 3.3.	Pregled primjene metoda realnih opcija i teorije igara	80
Tablica 3.4.	Definiranje promatranog područja i izbor scenarija	85
Tablica 3.5.	Definiranje razmatranog tržišnog segmenta	85
Tablica 3.6.	Planiranje pristupne mreže	86
Tablica 3.7.	Procjena isplativosti različitih pristupnih rješenja	88
Tablica 3.8.	Tipovi ruralnih naselja	90
Tablica 3.9.	Usporedba provedenih analiza uvođenja širokopojasnog pristupa	96
Tablica 4.1.	Korisnici Interneta prema radnom statusu	118
Tablica 4.2.	Korisnici Interneta prema dobi	118
Tablica 4.3.	Opremljenost kućanstva informacijskim i komunikacijskim tehnologijama	119

Tablica 4.4.	Razine informatiziranosti javnih usluga	120
Tablica 4.5.	Kvaliteta dostupnih javnih usluga	121
Tablica 4.6.	Statistički pokazatelji nelinearnog modela	129
Tablica 4.7.	Statistički pokazatelji dopunjenog nelinearnog modela	130
Tablica 5.1.	Razmatrana problematika i prijedlozi za njeno rješavanje	140
Tablica 5.2.	Komponente predloženog modela	144
Tablica 5.3.	Utjecaj promjene tehno-ekonomskih čimbenika na ukupni broj korisnika	157
Tablica 5.4.	Modeliranje prihoda operatora	158
Tablica 5.5.	Modeliranje troškova operatora	159
Tablica 5.6.	Značajke predloženog tehno-ekonomskog modela s okvirom	164
Tablica 5.7.	Kombinacije strategija za dva operatora	166
Tablica 5.8.	Prikaz mogućih kombinacija strategija za dva operatora	167

Literatura

- [1] **"Europe 2020: A Digital Agenda For Europe"**, Com(2010) 245, Communication from the Commission to the European Parliament, the Council, the European Economic and Social Committee and the Committee of the Regions, European Commission, Brussels, 2010.
- [2] **"Comparison of Access Technologies"**, EC/IST FP6 Project No 026920, White Paper, Open PLC European Research Alliance, 2009.
- [3] Lannoo, B., **"Study of Access Communications Networks for Heterogeneous Environments"**, doktorska disertacija, Universiteit Gent, Faculteit Ingenieurswetenschappen, Belgija, 2008.
- [4] **"Alternatives for Extending Broadband Coverage to Underserved EU Regions, in the Context Of The Digital Divide Forum"**, Economic study, Buckley, 2004.
- [5] **"Proposal for a Regulation of the European Parliament and of the Council on measures to reduce the cost of deploying high-speed electronic communications networks"**, European Commission, 2013/0080 (COD), Brussels, 2013.
- [6] Bažant, A., Car, Ž., Gledec, G., Jevtić, D., Ježić, G., Kunštić, M., Lovrek, I., Matijašević, M., Mikac, B., Skočir, Z., **"Telekomunikacije - tehnologija i tržište"**, Lovrek I., Gledec G. (ur.), Element, Zagreb, 2007.
- [7] Kelly, T., Rossotto, C. M., **"Broadband Strategies Handbook"**, The World Bank, Washington, 2012.
- [8] Žutinić, Đ., Bokan, N., **"Poljoprivreda i selo u sociološkim istraživanjima"**, Sveučilište u Zagrebu, Agronomski fakultet, Zagreb, 2008.
- [9] Žagar, D., Križanović, V., Grgić, K., **"Analyses of Main Factors in Implementation of Broadband Internet in Croatian Rural Areas"**, Proceedings of the 26th International Conference Science in Practice (SIP 2008), Osijek, Hrvatska, 2008.

- [10] **"Strategija ruralnog razvoja RH, 2008.-2013."**, Ministarstvo poljoprivrede, ribarstva i ruralnog razvoja, Zagreb, 2007.
- [11] Lukić, A., **"Tipologija ruralnih područja Hrvatske – geografski aspekt"**, doktorska disertacija, Geografski odsjek PMF-a, Zagreb, 2009.
- [12] **"Model diferencijacije urbanih, ruralnih i prijelaznih naselja u Republici Hrvatskoj"**, Državni zavod za statistiku, Zagreb, 2011.
- [13] **"Program razvoja Interneta i širokopojasnog pristupa Internetu na područjima od posebne državne skrbi, brdsko-planinskim područjima i otocima"**, HAKOM, 2010.
- [14] **"Strategija razvoja širokopojasnog pristupa u Republici Hrvatskoj u razdoblju od 2011. do 2015. godine"**, MMPI, 2010.
- [15] Gulin, D., Tušek, B., Žager, L., **"Poslovno planiranje, kontrola i analiza"**, RiF, Zagreb, 2004.
- [16] Cingula, M., Hunjak, T., Ređep, M., **"Poslovno planiranje"**, RRiF-plus, Zagreb, 2004.
- [17] Sigurdsson, H. M., **"Techno-Economics of Residential Broadband Deployment"**, Technical University of Denmark, Center for Information and Communication Technologies, Danska, 2007.
- [18] Porter, A. L., **"Technology futures analysis: Toward integration of the field and new methods"**, Technological Forecasting and Social Change, 2004.
- [19] Smura, T., **"Techno-economic modelling of wireless network and industry architectures"**, doktorska disertacija, Aalto University, School of Electrical Engineering, Department of Communications and Networking, Espoo, Finska, 2012.
- [20] Majnarić, T., **"Poslovno modeliranje telekomunikacijskih usluga u mrežama nove generacije"**, Lator, Zagreb, 2009.
- [21] Verbrugge, S., Casier, K., Van Ooteghem, J., Lannoo, B., **"Practical Steps in Techno-economic Evaluation of Network Deployment Planning"**, IBCN White Paper, Belgija, 2009.

- [22] Harno, J., **"Techno-economic valuation of mobile communications scenarios"**, doktorska disertacija, Aalto University, Faculty of Electronics, Telecommunications and Automation, Finska, 2010.
- [23] **"Techno-economics of integrated communication systems and services"**, ECOSYS, Deliverable 3, izvješće s ECOSYS projekta, 2004.
- [24] Hofer, C. W., Schendel, D. E., **"Strategy formulation: Analytical concepts"**, St. Paul, West Publishing, 1978.
- [25] Karhu, P., **"Emerging Mobile Service Innovation Markets: The Case of the Finnish Mobile TV Service Market"**, doktorska disertacija, University of St. Gallen, Graduate School of Business Administration, Economics, Law and Social Sciences Finska, 2007.
- [26] Meade, N., Islam, T., **"Modelling and forecasting the diffusion of innovation – A 25-year review"**, International Journal of Forecasting, Vol. 22, 2006., str. 519–545.
- [27] Sokele, M., **"Analytical method for forecasting of telecommunications service life-cycle quantitative factors"**, Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva, Zagreb, 2009.
- [28] Andres, L., Cuberes, D., Diouf, M., Serebrisky, T., **"The diffusion of the Internet: A cross-country analysis"**, Telecommunications Policy, Vol. 34, 2010., str. 323–340.
- [29] Kivi, A., **"Diffusion of Mobile Internet Services"**, doktorska disertacija, Aalto University, School of Electrical Engineering, Department of Communications and Networking, Finska, 2011.
- [30] Marinakis, Y. D., **"Forecasting technology diffusion with the Richards model"**, Technological Forecasting and Social Change, Vol. 79, 2012., str. 172–179.
- [31] Seol, H., Park, G., Lee, H., Yoon, B., **"Demand forecasting for new media services with consideration of competitive relationships using the competitive Bass model and the theory of the niche"**, Technological Forecasting and Social Change, Vol. 79, 2012., str. 1217–1228.
- [32] Casier, K., **"Techno-economic aspects of FTTH network deployment"**, doktorska disertacija, Universiteit Gent, Faculteit Ingenieurswetenschappen, Belgija, 2010.

- [33] Swift, D. K., Dagli, C. H., "**A study on the network traffic of Connexion by Boeing: Modeling with artificial neural networks**", Engineering Applications of Artificial Intelligence, Vol. 21, Iss. 8, 2008., str. 1113–1129.
- [34] Ruz, G. A., Varas, S., Villena, M., "**Policy making for broadband adoption and usage in Chile through machine learning**", Expert Systems with Applications, Vol. 40, Iss. 17, 2013., str. 6728–6734.
- [35] Modlic, B., "**Radijske tehnologije za širokopojasni nepokretni pristup i mjerenja**", studija, Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva, Zagreb, 2008.
- [36] Elnegaard, N. K., Stordahl, K., Lydersen, J., Eskedal, T. G., "**Mobile Broadband Evolution and the Possibilities**", Teletronikk, 2009.
- [37] Li, X., "**Radio Access Network Dimensioning for 3G UMTS**", doktorska disertacija, University of Bremen, Communication Networks Group, Njemačka, 2009.
- [38] http://education.nationalgeographic.com/education/topics/gis/?ar_a=1
- [39] Sevilla, D., "**Design of a new IT Infrastructure for the Region of Nordjylland - Access Network**", magistarski rad, Aalborg University, Department of Electronic Systems, Danska, 2008.
- [40] Rappaport, T. S., "**Wireless Communications: Principles and Practice (2nd Edition)**", Prentice Hall, 2002.
- [41] Nawrocki, M. J., Dohler, M., Aghvami, H., "**Modern Approaches to Radio Network Modeling and Planning**", in: "Understanding UMTS Radio Network Modeling, Planning and Automated Optimization", John Wiley & Sons Ltd, Engleska, 2006.
- [42] Prasad, R., Velez, F. J., "**WiMAX Networks - Techno-Economic Vision and Challenges**", Springer, 2010.
- [43] Olexa, R., "**Implementing 802.11, 802.16, and 802.20 Wireless Networks Planning, Troubleshooting and Operations**", Elsevier, 2005.
- [44] Zhan, Y., Chen, H., "**Mobile WiMAX: Toward Broadband Wireless Metropolitan Area Networks**", Auerbach Publications, 2008.

- [45] Shahajahan, M., Hes-Shafi, A., "**Analysis of Propagation Models for WiMAX at 3.5 GHz**", magistrski rad, Blekinge Institute of Technology, Department of Electrical Engineering, Švedska, 2009.
- [46] Smura, T., "**Techno-Economic Analysis of IEEE 802.16a-based Fixed Wireless Access Networks**", magistrski rad, Helsinki University of Technology, Department of Electrical and Communications Engineering, Finska, 2004.
- [47] "**Report on Evaluation of the Test, Conclusion and Recommendation on the PLC Network Design and Integration**", D16 Report, OPERA, 2009.
- [48] "**Triple-play pricing study**", izvješće, Analysys Mason, 2010.
- [49] Riihimäki, V., "**Real option valuation of broadband access networks - Statistical analysis of WiMAX and ADSL investments**", magistrski rad, Helsinki University of Technology, Finska, 2006.
- [50] "**Global ICT developments**", ICT Indicators database (2001-2013), ITU Statistics, ITU World Telecommunication, 2013., dostupno na: <http://www.itu.int/ict/statistics>
- [51] Gavrilut, L. M., "**A Techno-economic Analysis of Wireless Mesh Networks**", magistrski rad, Information Networking Institute and Athens Information Technology, Grčka, 2009.
- [52] Olsen, B., Stordahl, K., "**Models for Forecasting Cost Evolution of Components and Technologies**", *Teletronikk*, 2004., str. 138-144.
- [53] Schaeffer, M., Svoboda, Z., "**Vodič uz Priručnik za izradu projektne dokumentacije**", The Urban Institute, Zagreb, 2005.
- [54] Markendahl, J., "**Mobile Network Operators and Cooperation - A Tele-Economic Study of Infrastructure Sharing and Mobile Payment Services**", doktorska disertacija, Kungliga Tekniska Högskolan, Štokholm, Švedska, 2011.
- [55] Johansson, K., "**Cost Effective Deployment Strategies for Heterogeneous Wireless Networks**", KTH, Information and Communication Technology, Švedska, 2007.

- [56] Harno, J., "**Impact of 3G and beyond technology development and pricing on mobile data service provisioning, usage and diffusion**", *Telematics and Informatics*, Vol. 27, 2010., str. 269–282.
- [57] Ghazisaidi, N., Maier, M., "**Techno-economic analysis of EPON and WiMAX for future Fiber-Wireless (FiWi) networks**", *Computer Networks*, Vol. 54, 2010., str. 2640–2650.
- [58] Bohlin, E., "**Business Models and Financial Impacts of Future Mobile Broadband Networks**", *Telematics and Informatics*, Vol. 24, Iss. 3, 2007., str. 217–237.
- [59] Tongia, R., "**Can broadband over powerline carrier (PLC) compete? A techno-economic analysis**", *Telecommunications Policy*, Vol. 28, 2004., str. 559–578.
- [60] Altmana, E., Boulognea, T., El-Azouzia, R., Jiménez, T., Wynterc, L., "**A survey on networking games in telecommunications**", *Computers and Operations Research*, Vol. 33, 2006., str. 286–311.
- [61] Verheijen, M. F., "**From experimentation to citywide rollout: Real options for a municipal WiMAX network in the Netherlands**", magistarski rad, Eindhoven University of Technology, Technology Management, Nizozemska, 2007.
- [62] Caballero, M., Pardillo, A. V., Salis, J. M. R., Villaverde, S. R., Martínez, J. P., "**Technical and Economic Viability of WiMAX-PLC Network Roll-Out to Supply Broadband Access in Rural and Exurban Areas**", *Proceedings of the 18th European Regional Conference - International Telecommunications Society*, 2007.
- [63] Casier, K., Lannoo, B., Ooteghem, J. V., Verbrugge, S., Colle, D., Pickavet, M., Demeester, P., "**Case study for a wired versus wireless city network in Ghent**", *Proceedings of the BroadBand Europe 2007 Conference*, 2007.
- [64] Allen, S. M., Hurley, S., Ryan, D. M., Taplin, R. K., Melby, E., Braten, L. E., Elnegaard, N. K., Thomas, N. J., "**Business case assessments of a wireless broadband network deployment**", *Proceedings of the BroadBand Europe 2005 Conference*, 2005.

- [65] Smura, T., Hämmäinen, H., Rokkas, T., Katsianis, D., "**Techno-economic analysis of fixed WiMAX networks**", Mobile WiMAX - Toward Broadband Wireless Metropolitan Area Networks, Auerbach Publications, New York, 2008., str. 383-405.
- [66] Smura, T., "**Competitive potential of WiMAX in the broadband access market: A techno-economic analysis**", Proceedings of the 16th ITS European Regional Conference, Portugal, 2005.
- [67] Lannoo, B., Verbrugge, S., Ooteghem, J. V., Bruyne, J. D., Joseph, W., Colle, D., Pickavet, M., Martens, L., Demeester, P., "**Economic feasibility Study of a Mobile WiMAX Rollout in Belgium: Sensitivity Analysis and Real Options Thinking**", Broadband Europe 2007 Conference, 2007.
- [68] Harno, J., "**3G business prospects - Analysis of Western European UMTS markets**", Proceedings of the 1st International Symposium on Wireless Communication Systems, 2004., str. 250-254.
- [69] Rendon, J., Kuhlmann, F., Alanis, J. P., "**A Business Case for the Deployment of a 4G Wireless Heterogeneous Network in Spain**", Annual Review Of Communications, Vol. 61, 2007., str. 27-42.
- [70] Iatropoulos, A. D., Economides, A. A., Angelou, G. N., "**Broadband Investments Analysis Using Real Options Methodology - A case study for Egnatia Odos S.A.**", Communications and Strategies, No. 55, 2004., str. 45–76.
- [71] Angelou, G. N., Economides, A. A., "**A multi-criteria game theory and real-options model for irreversible ICT investment decisions**", Telecommunications Policy, Vol. 33, 2009., str. 686–705.
- [72] Tanguturi, V. P., Harmantzis, F. C., "**Migration to 3G wireless broadband internet and real options: The case of an operator in India**", Telecommunications Policy, Vol. 30, 2006., str. 400–419.
- [73] Sadowski, B. M., Verheijen, M., Nucciarelli, A., "**From Experimentation to Citywide Rollout: Real Options for a Municipal WiMax Network in the Netherlands**", Communications and Strategies, No. 70, 2008., str. 101–123.

- [74] Eskelinen, H., Frank, L., Hirvonen, T., "**Does strategy matter? A comparison of broadband rollout policies in Finland and Sweden**", Telecommunications Policy, Vol. 32, 2008., str. 412–421.
- [75] Matsubayashi, N., "**Price and quality competition: The effect of differentiation and vertical integration**", European Journal of Operational Research, Vol. 180, 2007., str. 907–921.
- [76] Katsianis, D., Gyürke, A., Konkoly, R., Varoutas, D., Sphicopoulo, T., "**A game theory modeling approach for 3G operators**", Netnomics, Vol. 8, 2007., str. 71–90.
- [77] Maillé, P., Tuffin, B., "Price war in heterogeneous wireless networks", Computer Networks, Vol. 54, 2010.
- [78] Tahon, M., Lannoo, B., Ooteghem, J. V., Casier, K., Verbrugge, S., Colle, D., Pickavet, M., Demeester, P., "**Municipal support of wireless access network rollout: A game theoretic approach**", Telecommunications Policy, Vol. 35, Iss. 9–10., 2011., str. 883–894.
- [79] Lannoo, B., Tahon, M., Ooteghem, J. V., Pareit, D., Casier, K., Verbrugge, S., Moerman, I., Pickavet, M., Demeester, P., "**Game-theoretic evaluation of competing wireless access networks for offering mobile Internet**", Second Annual Conference on Competition and Regulation in Network Industries, Brussels, Belgium, 2009.
- [80] Trestian, R., Ormond, O., Muntean, G. - M., "**Reputation-based network selection mechanism using game theory**", Physical Communication, Vol. 4, 2011., str. 156–171.
- [81] Huang, K. C., "**Can citywide municipal WiFi be a feasible solution for local broadband access in the US? An empirical evaluation of a techno-economic model**", doktorska disertacija, University of Pittsburgh, Graduate Faculty, Department of Information Science and Telecommunications, 2008.
- [82] Riihimäki, V., "**Managing Uncertainties in Broadband Investments - Case Studies of Real Options for Rural Area Access Networks**", doktorska disertacija, Aalto University, School of Science and Technology, Faculty of Electronics, Telecommunications and Automation, Department of Communications and Networking, Espoo, Finska, 2010.

- [83] Riff, A., "**Game-theoretic Analysis of Deployment Schemes for Mobile Network Offloading**", magistarski rad, Aalto University, School of Electrical Engineering, Espoo, Finska, 2011.
- [84] Olsen, B. T., "**OPTIMUM – A techno-economic tool**", *Teletronikk*, Vol. 95, No. 2/3, 1999., str. 239-250.
- [85] Žagar, D., Križanović, V., "**Analyses and Comparisons of Technologies for Rural Broadband Implementation**", Proceedings of the 17th International Conference on Software Telecommunications and Computer Networks (SoftCOM 2009), Hvar, Hrvatska, 2009.
- [86] Križanović, V., Grgić, K., Žagar, D., "**Analyses and Comparisons of Fixed Access Technologies for Rural Broadband Implementation**", Proceedings of the 32nd International Conference on Information Technology Interfaces (ITI 2010), Cavtat-Dubrovnik, Hrvatska, 2010.
- [87] Križanović, V., Žagar, D., Grgić, K., "**Techno-Economic Analyses of Wireline and Wireless Broadband Access Networks Deployment in Croatian Rural Areas**", Proceedings of the 11th International Conference on Telecommunications (ConTEL 2011), Graz, Austrija, 2011., str. 265-272.
- [88] Križanović, V., Žagar, D., Martinović, G., "**Mobile Broadband Access Networks Planning and Evaluation Using Techno-economic Criteria**", Proceedings of the 34th International Conference on Information Technology Interfaces (ITI 2012), Cavtat-Dubrovnik, Hrvatska, 2012., str. 281-286.
- [89] Žagar, D., Križanović, V., Grgić, K., "**Business Case Assessments of Fixed and Mobile Broadband Access Networks Deployments**", Proceedings of the 20th International Conference on Software, Telecommunications and Computer Networks (SoftCOM 2012), Split, Hrvatska, 2012.
- [90] Križanović, V., Žagar, D., Grgić, K., "**Econometric Analysis of Demographic and Socio-Economic Factors Influencing Broadband Adoption in Croatian Rural Counties**", Proceedings of the 12th International Conference on Telecommunications (ConTEL 2013), Zagreb, Hrvatska, 2013., str. 283-288.

- [91] WiTech TEA tools, dostupno na: <http://www.witech.it/>
- [92] Grubescic, T., **"The Geodemographic Correlates of Broadband Access and Availability in the United States: A Longitudinal Analysis"**, Telematics and Informatics, Vol. 21, Iss. 4, 2004., str. 335-358.
- [93] Grubescic, T., **"The Spatial Distribution of Broadband Providers in the United States: 1999 – 2004"**, Telecommunications Policy, Vol. 32, Iss. 3-4, 2008., str. 212-233.
- [94] Udovičić, M., Baždarić, K., Bilić-Zulle, L., Petrovečki, M., **"Što treba znati kada izračunavamo koeficijent korelacije?"**, Biochemia Medica, Vol. 17, No. 1, 2007.
- [95] Marusteri, M., Bacarea, V., **"Kako odabrati pravi test za procjenu statističke značajnosti razlike između skupina?"**, Biochemia Medica, Vol. 20, No. 1, 2010.
- [96] Tsatsou, P., **"Why Internet Use? A Quantitative Examination of the Role of Everyday Life and Internet Policy and Regulation"**, Technology in Society, Volume 33, Issues 1–2, 2011.
- [97] **"Strateški okvir za razvoj RH, 2006.-2013."**, Središnji državni ured za razvojnu strategiju i koordin. fondova EU, 2006.
- [98] Skogseid, I., **"Information Infrastructure and Rural Innovation Systems - A study of the dynamics of local adaptation of ICT"**, doktorska disertacija, University of Oslo, Faculty of Mathematics and Natural Science, Norveška, 2007.
- [99] Kolko, J., **"Broadband and Local Growth"**, Journal of Urban Economics, Vol. 71, Iss. 1, 2012., str. 100–113.
- [100] Holt, L., Jamison, M., **"Broadband and Contributions to Economic Growth: Lessons from the US Experience"**, Telecommunications Policy, 2009.
- [101] Lee, S., **"A cross-country analysis of ubiquitous broadband deployment: Examination of adoption factors"**, doktorska disertacija, University of Florida, SAD, 2008.
- [102] Savage, S. J., Waldman, D., **"Broadband Internet Access, Awareness and Use: Analysis of United States Household Data"**, Telecommunications Policy, Vol. 29, 2005., str. 615–633.

- [103] Chaudhuri, A., Flamm, K., **"Analysis of the Determinants of Broadband Access"**, Telecommunications Policy, Vol. 31, 2007., str. 312-326.
- [104] Goldfarb, A., Prince, J., **"Internet Adoption and Usage Patterns are Different: Implications for the Digital Divide"**, Information Economics and Policy, Vol. 20, Iss. 1, 2008., str. 2-15.
- [105] **"Exploring The Digital Nation: Home Broadband Internet Adoption In The United States"**, National Telecommunications and Information Administration, 2010., dostupno na:
http://www.ntia.doc.gov/files/ntia/publications/esa_ntia_us_broadband_adoption_report_11082010_1.pdf.
- [106] Chen, Y., Savage, S., **"The effects of competition on the price for cable modem Internet access"**, NET Institute Working Paper, 2007.
- [107] Picot, A., Wernick, C., **"The role of government in broadband access"**, Telecommunications Policy, Vol. 31, 2007., str. 660-674.
- [108] Cambini, C., Jiang, C. Y., **"Broadband investment and regulation: A literature review"**, Telecommunications Policy, Vol. 33, 2009., str. 559-574.
- [109] Bauer, J. M., **"Regulation, public policy, and investment in communications infrastructure"**, Telecommunications Policy, Vol. 34, 2010., str. 65-79.
- [110] LaRose, R., Stover, S., Gregg, J. L., Straubhaar, J., **"The impact of rural broadband development: Lessons from a natural field experiment"**, Government Information Quarterly, Vol. 28, 2011., str. 91–100.
- [111] **"Strateški plan RH za razdoblje 2012.-2014. godine"**, Mnistarstva mora, prometa i infrastrukture, Zagreb, 2011.
- [112] Gillett, S. E., Lehr, W. H., Osorio, C., **"Local government broadband initiatives"**, Telecommunications Policy, Vol. 28, 2004., str. 537-558.
- [113] Hollifield, C. A., Donnermeyer, J. F., **"Creating demand: Influencing information technology diffusion in rural communities"**, Government Information Quarterly, Vol. 20, Iss. 2, 2003., str. 135–150.

- [114] Troulos, C., Maglaris, V., **"Factors determining municipal broadband strategies across Europe"**, Telecommunications Policy, Vol. 35, 2011., str. 842-856.
- [115] Middleton, C. A., Bryne, A., **"An exploration of user-generated wireless broadband infrastructures in digital cities"**, Telematics and Informatics, Vol. 28, 2011., str. 163-175.
- [116] Ooteghem, J. V., Lannoo, B., Casier, K., Verbrugge, S., Pickavet, M., Moerman, I., Demeester, P., **"Municipalities as a driver for wireless broadband access"**, Wireless Personal Communications, Vol. 49, No. 3, 2009., str. 391-414.
- [117] Lehr, W., Sirbu, M., Gillett, S., **"Wireless is changing the policy calculus for municipal broadband"**, Government Information Quarterly, Vol. 23, 2006., str. 435-453.
- [118] Tapia, A., Maitland, C., Stone, M., **"Making IT work for municipalities: Building municipal wireless networks"**, Government Information Quarterly, Vol. 23, 2006., str. 359-380.
- [119] Sirbu, M., Lehr, W., Gillett, S., **"Evolving wireless access technologies for municipal broadband"**, Government Information Quarterly, Vol. 23, 2006., str. 480-502.
- [120] Kyriakidou, V., Katsianis, D., Orfanos, I., Chipouras, A., Varoutas, D., **"Business modeling and financial analysis for Metropolitan Area Networks: Evidence from Greece"**, Telematics and Informatics, Vol. 28, 2011., str. 112-124.
- [121] Tapia, A. H., Kvasny, L., Ortiz, J. A., **"A Critical Discourse Analysis of three US municipal wireless network initiatives for enhancing social inclusion"**, Telematics and Informatics, Vol. 28, 2011., str. 215-226.
- [122] Nucciarelli, A., Sadowski, B. M., Achard, P. O., **"Emerging models of public-private interplay for European broadband access: Evidence from the Netherlands and Italy"**, Telecommunications Policy, Vol. 34, 2010., str. 513-527.
- [123] Bouras, C., Gkamas, A., Papagiannopoulos, J., Theophilopoulos, G., Tsiatsos, T., **"Broadband municipal optical networks in Greece: A suitable business model"**, Telematics and Informatics, Vol. 26, 2009., str. 391-409.

- [124] Sadowski, B. M., Nucciarelli, A., Rooij, M., **"Providing incentives for private investment in municipal broadband networks Evidence from the Netherlands"**, Telecommunications Policy, Vol. 33, 2009., str. 582-595.
- [125] Hudson, H. E., **"Municipal wireless broadband: Lessons from San Francisco and Silicon Valley"**, Telematics and Informatics, Vol. 27, 2009., str. 1-9.
- [126] Whitacre, B., **"The Diffusion of Internet Technologies to Rural Communities: A Portrait of Broadband Supply and Demand"**, American Behavioral Scientist, Vol. 53, Iss. 9, 2010., str. 1283–1303.
- [127] **"Primjena informacijskih i komunikacijskih tehnologija (IKT) u kućanstvima i kod pojedinaca"**, priopćenja Državnog zavoda za statistiku Republike Hrvatske, Zagreb, 2007.-2013., dostupno na: <http://www.dzs.hr>
- [128] Michailidis, A., Partalidou, M., Nastis, S., Papadaki-Klavdianou, A., Charatsari, C., **"Who goes online? Evidence of Internet use patterns from rural Greece"**, Telecommunications Policy, Vol. 35, 2011., str. 333–343.
- [129] Prieger, J. E., Hu, W-M., **"The Broadband Digital Divide and the Nexus of Race, Competition, and Quality"**, Information Economics and Policy, Vol. 20, Iss. 2, 2008., str. 150-167.
- [130] Drouard, J., **"Computer Literacy, Online Experience or SocioEconomic Characteristics - What are the Main Determinants of Broadband Internet Adoption and Internet Usage"**, Communications & Strategies, Vol. 80, 2010., str. 83-103.
- [131] **Bangemann report**, European Council, Brussels, 1994., dostupno na: <http://europa.eu.int/ISPO/infosoc/backg/bangeman.html>
- [132] **"Plan provedbe Programa e-Hrvatska"**, studije i izvješća o dostupnosti javnih usluga na Internetu, Središnji državni ured za e-Hrvatsku, Republika Hrvatska, 2004.-2009., dostupno na: <http://www.uprava.hr/default.aspx?id=13639>
- [133] Kyriakidou, V., Michalakelis, C., Spicopoulos, T., **"Driving Factors During the Different Stages of Broadband Diffusion: A Non-Parametric Approach"**, Technological Forecasting and Social Change, 2012.

- [134] **"International Comparison Requirements Pursuant to the Broadband Data Improvement Act"**, Second International Broadband Data Report, Federal Communications Commission, svibanj 2011., dostupno na: <https://prodnet.www.neca.org/publicationsdocs/wwpdf/da11732.pdf>
- [135] **"Statistički ljetopis Republike Hrvatske"**, publikacije Državnog zavoda za statistiku Republike Hrvatske, Zagreb, 2002.-2011., dostupno na: <http://www.dzs.hr>
- [136] Preston, P., Cawley, A., Metykova, M., **"Broadband and rural areas in the EU: From technology to applications and use"**, Telecommunications Policy, Vol. 31, 2007., str. 389-400.
- [137] Stover, S., **"Rural Internet Connectivity"**, Telecommunications Policy, Vol. 5, 2001., str. 331–347.
- [138] **"Telecommunications: Broadband Deployment Is Extensive throughout the United States, but It Is Difficult to Assess the Extent of Deployment Gaps in Rural Areas"**, GAO-06-426, Government Accountability Office - US (GAO), 2006.
- [139] Srinuan, P., Srinuan, C., Bohlin, E., **"Fixed and Mobile Broadband Substitution in Sweden"**, Telecommunications Policy, Vol. 36, Iss. 3, 2012.
- [140] Lee, S., Marcu, M., Lee, S., **"An empirical analysis of fixed and mobile broadband diffusion"**, Information Economics and Policy, 2011., str. 227-233.
- [141] Laaksonen, P., **"Critical Factors of High-Speed Broadband Investments in Rural Areas from Perspective of Operators"**, magistarski rad, Aalto University, School of Electrical Engineering, Espoo, Finska, 2011.
- [142] Burton, M. L., Hicks, M. J., **"The Residential and Commercial Benefits of Rural Broadband: Evidence from Central Appalachia"**, Center for Business and Economic Research, Marshall University, 2005.
- [143] Thompson, H. G. Jr., Garbacz, C., **"Economic Impacts of Mobile versus Fixed Broadband"**, Telecommunications Policy, Vol. 35, Iss. 11, 2011.

- [144] Katsianis, D., "**Telecommunications Networks Planning and Evaluation with Techno-Economic Criteria**", članak, sažetak doktorske disertacije, University of Athens, 2009.
- [145] Verdegem, P., Marez, L. D. "**Rethinking determinants of ICT acceptance: Towards an integrated and comprehensive overview**", Technovation, Vol. 31, 2011., str. 411–423.
- [146] Peronard, J.-P., Just, F., "**User motivation for broadband: A rural Danish study**", Telecommunications Policy, Vol. 35, 2011., str. 691–701.
- [147] **MATLAB®**, MathWorks, dostupan na: <http://www.mathworks.com/products/matlab/>

PRILOG

Kod za izbor optimalnih strategija operatora :

Ako $A11 * U(1,1) = A21 * U(3,1)$

Ako $U(1,1) > U(3,1)$

$op1 = 'NE';$

Ako $A11 * U(1,2) > A12 * U(2,2)$

$op2 = 'NE';$

Kraj

Ako $A11 * U(1,2) < A12 * U(2,2)$

$op2 = 'DA';$

Kraj

Ako $A11 * U(1,2) = A12 * U(2,2)$

Ako $U(1,2) > U(2,2)$

$op2 = 'NE';$

Kraj

Ako $U(1,2) < U(2,2)$

$op2 = 'DA';$

Kraj

Ako $U(1,2) = U(2,2)$

$op1 = 'K';$

$op2 = 'K';$

Kraj

Kraj

Kraj

Ako $U(1,1) < U(3,1)$

$op1 = 'DA';$

Ako $A21 * U(3,2) > A22 * U(4,2)$

$op2 = 'NE';$

Kraj

Ako $A21 * U(3,2) < A22 * U(4,2)$

$op2 = 'DA';$

Kraj

Ako $A21 * U(3,2) = A22 * U(4,2)$

Ako $U(3,2) > U(4,2)$

$op2 = 'NE';$

Kraj

Ako $U(3,2) < U(4,2)$

$op2 = 'DA';$

Kraj

Ako $U(3,2) = U(4,2)$

op1='K';

op2='K';

Kraj

Kraj

Kraj

Ako $U(1,1) == U(3,1)$

op1='K';

op2='K';

Kraj

Kraj

Ako $A11 * U(1,1) > A21 * U(3,1)$

op1='NE';

Ako $A11 * U(1,2) > A12 * U(2,2)$

op2='NE';

Kraj

Ako $A11 * U(1,2) < A12 * U(2,2)$

op2='DA';

Kraj

Ako $A11 * U(1,2) == A12 * U(2,2)$

Ako $U(1,2) > U(2,2)$

op2='NE';

Kraj

Ako $U(1,2) < U(2,2)$

op2='DA';

Kraj

Ako $U(1,2) == U(2,2)$

op1='K';

op2='K';

Kraj

Kraj

Kraj

Ako $A11 * U(1,1) < A21 * U(3,1)$

op1='DA';

Ako $A21 * U(3,2) > A22 * U(4,2)$

op2='NE';

Kraj

Ako $A21 * U(3,2) < A22 * U(4,2)$

op2='DA';

Kraj

Ako $A21 * U(3,2) == A22 * U(4,2)$

Ako $U(3,2) > U(4,2)$

op2='NE';

Kraj

Ako $U(3,2) < U(4,2)$

$op2 = 'DA'$;

Kraj

Ako $U(3,2) = U(4,2)$

$op1 = 'K'$;

$op2 = 'K'$;

Kraj

Kraj

Kraj

Ako $A11 * U(1,1) + A12 * U(2,1) = A21 * U(3,1) + A22 * U(4,1)$

$op1 = 'K'$;

$op2 = 'K'$;

Kraj

Ako $strcmp(op1, op2) = 1$

Ako $strcmp(op1, 'NE') = 1$

$STRATEGIJA = \{ 'NN' \}$;

$OP1\{rbr_str\} = \{ payoff(1,1), 'N' \}$;

$OP2\{rbr_str\} = \{ payoff(1,2), 'N' \}$;

U suprotnom $strcmp(op1, 'DA') = 1$

$STRATEGIJA = \{ 'DD' \}$;

$OP1\{rbr_str\} = \{ payoff(1,1), 'D' \}$;

$OP2\{rbr_str\} = \{ payoff(1,2), 'D' \}$;

U suprotnom $strcmp(op1, 'K') = 1$

$STRATEGIJA = \{ 'KK' \}$;

$OP1\{rbr_str\} = \{ payoff(1,1), 'kombinacija' \}$;

$OP2\{rbr_str\} = \{ payoff(1,2), 'kombinacija' \}$;

Kraj

U suprotnom $strcmp(op1, op2) = 0$

Ako $strcmp(op1, 'NE') = 1$

$STRATEGIJA = \{ 'ND' \}$;

$OP1\{rbr_str\} = \{ payoff(1,1), 'N' \}$;

$OP2\{rbr_str\} = \{ payoff(1,2), 'D' \}$;

U suprotnom $strcmp(op1, 'DA') = 1$

$STRATEGIJA = \{ 'DN' \}$;

$OP1\{rbr_str\} = \{ payoff(1,1), 'D' \}$;

$OP2\{rbr_str\} = \{ payoff(1,2), 'N' \}$;

Kraj

Kraj

Sažetak

Unatoč brojnim koristima koje proizlaze iz primjene širokopojasnih pristupnih tehnologija i usluga, danas postoji mnoštvo ruralnih područja u Svijetu u kojima širokopojasni pristup Internetu nije dostupan. Ova se disertacija bavi problematikom vezanom uz uvođenje širokopojasnog pristupa Internetu u ruralnim područjima. U disertaciji je provedena analiza stanja te su utvrđene razlike u stopama usvajanja i primjeni širokopojasnih tehnologija i usluga u odabranim ruralnim i urbanim područjima. Nadalje, prikazana je metodologija za rješavanje problematike nedovoljne dostupnosti širokopojasnog pristupa Internetu u ruralnim područjima, odnosno problematike tzv. digitalnog jaza - određivanje najrelevantnijih čimbenika za uvođenje širokopojasnog pristupa Internetu uz primjenu regresijske analize i uključivanje tih čimbenika u postupak tehno-ekonomskog modeliranja. Isto tako, u radu su razmotreni i načini na koje se tehno-ekonomske metode modeliranja mogu koristiti pri povezivanju analiziranih tehno-ekonomski orijentiranih zahtjeva korisnika (za kvalitetom usluga, količinom prometa, pristupnom brzinom, cijenom usluga) te zahtjeva operatora za isplativim tehničkim rješenjima za ruralna područja. Zato je definiran novi okvir za analizu i modeliranje eksplicitno definiranih zahtjeva. Predloženi okvir služi kao nadogradnja tehno-ekonomskih modela i omogućuje detaljniju analizu specifičnosti različitih ruralnih područja temeljenu na dostupnim podacima. Na posljetku, prikazana je korisnost predloženog modela pri izboru najboljih strategija za operatore u konkurentskom okruženju.

Ključne riječi:

širokopojasni pristup Internetu, uvođenje širokopojasnog pristupa, širokopojasni pristup u ruralnim područjima, tehno-ekonomski model

Abstract

Despite the numerous benefits arising from the application of broadband access technologies and services, in the majority of rural areas in the world broadband Internet access is not yet available. Therefore, the thesis deals with the issues related to the introduction of broadband Internet access in rural areas. In the thesis, the differences in the adoption rates of broadband technology and services in rural and urban areas for several studied cases are examined. The given results indicated a lower level of broadband adoption in rural compared to urban areas, i.e. the presence of the digital divide. Therefore, the selected methodology for addressing the digital divide problem is introduced – the determination of the most relevant factors for broadband adoption using regression analysis, and the inclusion of these factors in the techno-economic modeling process. Furthermore, the techno-economic modeling methods used for connecting analyzed techno-economically oriented user requirements (for the quality of broadband services, the broadband traffic amount, the broadband access speed, and the broadband service price) with the operators' requirements on the cost effective business models in rural areas are considered. Therefore, a new framework for analyzing and modeling the explicitly defined users and operators' requirements is proposed. The proposed framework serves as an upgrade for the existing techno-economic models and allows a detailed analysis of the specificities of different rural areas, based on the available data. Finally, the efficiency of the proposed model application in choosing the best business strategies for operators in a competitive environment is shown.

Keywords:

broadband Internet access, broadband implementation, rural broadband access, techno-economic model

Životopis

Višnja Križanović rođena je 30. ožujka 1983. u Novom Sadu. Nakon završetka osnovnoškolskog i gimnazijskog obrazovanja općeg smijera u Orahovici, 2002. godine upisala je dodiplomski studij na Elektrotehničkom fakultetu u Osijeku. Tijekom dodiplomskog studija bila je stipendist MZOŠ, a 2004. godine dobila je priznanje Elektrotehničkog fakulteta za primjeren uspjeh u studiranju. Diplomski rad s naslovom „Širokopolasni pristup Internetu u ruralnim područjima u Republici Hrvatskoj“ pod mentorstvom prof. dr. sc. Drage Žagara uspješno je obranila 2007. godine te je stekla zvanje diplomirane inženjerke elektrotehnike. Iste godine, na Elektrotehničkom fakultetu u Osijeku upisala je poslijediplomski doktorski studij elektrotehnike smjera Komunikacije i informatika. Od studenog 2007. godine zaposlena je kao asistentica na Elektrotehničkom fakultetu u Osijeku na Zavodu za komunikacije. Od tada aktivno sudjeluje u izvođenju nastave - auditornih i laboratorijskih vježbi iz više kolegija na preddiplomskom, diplomskom i stručnom studiju: Komunikacijske mreže, Računalne i komunikacijske mreže, Mreže računala, Komunikacijski protokoli, Kodovi i kodiranje, Ekspertni industrijski sustavi. Kao suradnica sudjeluje u nekolicini znanstvenih i stručnih projekata: „Širokopolasni pristup i internetske usluge u ruralnim područjima“ (projekt MZOŠ), „Pogled u budućnost“ (projekt HAKOM - FER Zagreb - Ekonomski fakultet Zagreb - FESB Split - ETF Osijek - Ericsson Nikola Tesla - Nokia Siemens Networks) te „Istraživanje tehničke dijagnostike složenih elektroenergetskih objekata“ (projekt Končar Inženjering za energetiku i transport - HEP Prijenos Osijek – ETF Osijek). Autorica je i koautorica većeg broja znanstvenih radova. Kao sumentorica vodi veći broj studenata kroz izradu diplomskih i završnih radova. Članica je strukovne udruge IEEE (Communications Society) od 2008. godine.

Brief biography

Visnja Krizanovic received her M.Sc. (2007) degree in Electrical Engineering from the Faculty of Electrical Engineering, J. J. Strossmayer University in Osijek, Croatia. She is working as a teaching assistant at the Department of Communications, Faculty of Electrical Engineering in Osijek since 2007. As a project researcher she has been engaged in two projects considering broadband Internet access implementation in rural areas – the research project “Broadband Internet access and broadband services in rural areas” supported by the Ministry of Science, Education and Sports of the Republic of Croatia (2007 - 2013), and the multidisciplinary research project “Looking to the future” led by the Croatian Post and Electronic Communications Agency and several Croatian Universities (2010 - 2013). She is the author and a co-author of several published research papers. She is a member of IEEE since 2008.