Poduzetništvo pogonjeno podacima – pregled literature

Oštarjaš, Drago

Undergraduate thesis / Završni rad

2019

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Organization and Informatics / Sveučilište u Zagrebu, Fakultet organizacije i informatike**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:211:573700

Rights / Prava: Attribution 3.0 Unported/Imenovanje 3.0

Download date / Datum preuzimanja: **2024-03-28**

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
VARAŽDIN

Repository / Repozitorij:

Faculty of Organization and Informatics - Digital Repository

zir.nsk.hr

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U ZAGREBU

FAKULTET ORGANIZACIJE I INFORMATIKE

V A R A Ž D I N

Drago Oštarjaš

PODUZETNIŠTVO POGONJENO PODACIMA-PREGLED LITERATURE

ZAVRŠNI RAD

Varaždin, 2019.

SVEUČILIŠTE U ZAGREBU

FAKULTET ORGANIZACIJE I INFORMATIKE

V A R A Ž D I N

Drago Oštarjaš

Matični broj: 44067/15–R

Studij: *Poslovni sustavi*

PODUZETNIŠTVO POGONJENO PODACIMA-PREGLED LITERATURE

ZAVRŠNI RAD

Mentorica:

Doc. dr. sc. Dijana Oreški

Varaždin, rujan 2019.

Drago Oštarjaš

Izjava o izvornosti

Izjavljujem da je moj završni rad izvorni rezultat mojeg rada te da se u izradi istoga nisam koristio drugim izvorima osim onima koji su u njemu navedeni. Za izradu rada su korištene etički prikladne i prihvatljive metode i tehnike rada.

Autor/Autorica potvrdio/potvrdila prihvaćanjem odredbi u sustavu FOI-radovi

_____

Sažetak

Tema završnog rada je vezana uz poduzetništvo i GEM(Global entrepreneurship monitor) metodologiju, GEM je baza podataka o poduzetničkoj aktivnosti na globalnoj razini. Prvo ćemo objasniti pojam GEM-a i sve vezano uz njega, njegovu povijest i svrhu te ćemo objasniti tko je odgovoran za GEM istraživanja u Hrvatskoj. Zatim ćemo objasniti kako su to GEM podaci primijenjeni i na kojim područjima, objasnit ćemo nekoliko istraživanja koje su koristile GEM podatke te koje organizacije iskorištavaju GEM podatke svakodnevno. Kroz nekoliko dijagrama objasnit ćemo strukturu GEM podataka. Rad završava s analizom dva istraživanja, s kojima ćemo lakše shvatiti svrhu GEM podataka i njihov utjecaj na poduzetništvo.

Ključne riječi: GEM; Poduzetništvo; Poduzetništvo pogonjeno podacima; Poduzetnička namjera; Rudarenje podataka; Anketa o populaciji odraslih; Poduzetnik u nastajanju; Žene poduzetnice;

Sadržaj

1. Uvod 1

2. Opis i primjena GEM podataka 2

2.1. Osnivanje GEM-a 2

2.2. GEM istraživanja u moderno doba 4

2.2.1. Ankete o populaciji odraslih 4

2.2.2. TEA 5

2.3. CEPOR 5

2.4. GEM podaci na mikro razini 7

2.5. Poduzetništvo i gospodarski učinak 8

3. Struktura GEM podataka 10

3.1. „Stvaranje novog posla/nečeg novog“ 13

3.2. Trenutno i buduće korištenje GEM podataka 14

4. Analiza podataka u poduzetništvu 16

4.1. Istraživanje poduzetničkih namjera uz pomoć neuronskih mreža, stabla odlučivanja i metode potpornih vektora 16

4.1.1. Metodologija 17

4.1.2. Rezultati i zaključak istraživanja 19

4.2. Predviđanje poduzetničkih odluka kod žena 23

5. Zaključak 27

Popis literature 28

Popis slika 29

Popis tablica 30

1. Uvod

Tema ovog završnog rada je poduzetništvo pogonjeno podacima. Cilj rada je ispitati u kojoj se mjeri velike količine podataka danas koriste u poduzetništvu, s kojom svrhom i s kakvim učincima. Pri tome se pregled literature i istraživanja oslanjaju na podatke GEM istraživanja.

„*GEM(Global Entrepreneurship Monitor) je vodeća svjetska studija o poduzetništvu*.“ GEM provodi ogromno, međunarodno provedeno i koordinirano prikupljanje podataka, čime omogućuje kvalitetne informacije, izvješća i zanimljive priče, što u konačnici uvelike poboljšava razumijevanje poduzetničke pojave. To je također pouzdani resurs za poduzetništvo ključnih međunarodnih organizacija kao što su Ujedinjeni narodi(UN), Svjetski gospodarski forum(WEF), Svjetska banka(WB) i Organizacija za gospodarsku suradnju i razvoj(OECD), koji nude skupove podataka, posebna izvješća i stručna mišljenja. Sve te organizacije koriste GEM-ove podatke, metodologiju i mrežu lokalnih stručnjaka. GEM je započeo 1999. Godine kao zajednički projekt Babson Collegea iz Sjedinjenih Američkih Država i London Business School iz Ujedinjenog Kraljevstva. Glavni cilj projekta je bila želja da se sazna zašto su neke zemlje „poduzetnije“ od drugih [1].

GEM zajednica definira poduzetništvo kao: „Svaki pokušaj stvaranja novih poslova ili novih pothvata, kao što su samozapošljavanje, stvaranje nove poslovne organizacije ili širenje postojećeg poslovanja a ostvaruju ih pojedinac, tim ljudi ili postojeće poduzeće. “

Iako GEM u suštini gleda poduzetništvo kao novu poslovnu aktivnost, taj pojam „nove poslovne aktivnosti“ treba sagledati s više stajališta. Kako ćemo više ulaziti u suštinu teme, tako će se pokazati da definicija GEM-a nije ograničena samo na novo registrirane tvrtke. Također, GEM metodologija se godinama usredotočila na fazu koja kombinira fazu prije osnutka nove tvrtke i fazu neposredno nakon početka rada nove tvrtke te se jednim imenom ta faza naziva „poduzetnička aktivnost u ranoj fazi“ ili TEA (Total Entrepreneurial Activity ili Total Early-Stage Entrepreneurial Activity). GEM kao zajednica također provodi razne upitnike, jedan od njih ispituje kategorije koje razlikuju različite faze poduzetništva, prvo su identificirani pojedinci s poduzetničkim stavovima, odnosno stavovima koji potencijalno vode poduzetničkoj aktivnosti, zatim su identificirani pojedinci koji su uključeni kao vlasnici ili direktori u osnovanim tvrtkama [2]. Također samo istraživanje GEM zajednice provodi se iz tri izvora: gledaju se podaci prikupljeni anketiranjem reprezentativnog uzorka odrasle populacije, zatim podaci prikupljeni anketiranjem i intervjuiranjem stručnjaka iz područja poduzetništva te podaci prikupljeni iz standardiziranih sekundarnih međunarodnih baza podataka [3].

2. Opis i primjena GEM podataka

2.1. Osnivanje GEM-a

Interes za razumijevanjem poduzetništva i razlika u razvoju poduzetništva između zemalja raste tijekom 1990-ih. Jednako kao i danas, Sjedinjene Države su bile vodeći lider u poduzetništvu. U poduzetničkim krugovima javio se snažan interes kako olakšati gospodarski rast određenih zemalja. Jedna od poslovnih škola, London Business School, na čelu s Michaelom Hayom, posebice je stavljala naglasak na poduzetništvo. 1998. Godine pojavila se inicijativa gdje bi se vršila međunacionalna usporedba rasta poduzetništva, a sve je započelo upravo dogovorom Hayea i Billa Bygravea, koji je radio na Babson Collegeu(SAD). Osim njih dvojice, pripomogao im je Paul Reynolds(također s Babson Collegea), koji je im sam započeo prvo istraživanje o poduzetničkoj dinamici u SAD-u, u samo istraživanje je uložena velika količina novca i vremena. Istraživanje se službeno nazivalo PSED(Panel Study of Entrepreneurial Dynamics) ili Panel studija poduzetničke aktivnosti. Najteže je bilo osmisliti postupak koji bi razvijao reprezentativne uzorke onih koji su aktivni u stvaranju poduzeća. PSED je uspješno proveden u Kanadi, Nizozemskoj, Norveškoj i Švedskoj, te su Hay i suradnici došli do zaključka da ako istraživanje provedu u još nekoliko zemalja svijeta, da bi se mogao stvoriti međunarodni uzorak poduzetničke aktivnosti.

Osim početnih istraživanja, odlučeno je da će se provesti prvi upitnik na principu „da/ne“. Upitnik se započeo provoditi u Ujedinjenom Kraljevstvu i SAD-u , te su nadodane Kanada, Finska, Njemačka što ukupno čini 5 zemalja, više nego dovoljno za prvi službeni upitnik. „*Svaki nacionalni tim je sponzorirao reprezentativni uzorak od 1000 odraslih osoba te su u dva mjeseca prikupljeni podaci i rezultati dovoljni za povjerenje u istražene međunacionalne usporedbe*.“ Sljedećim istraživanjem 1999. Godine povećao se broj timova tj. uključenih zemalja i minimalni ispitni uzorak je povećan na 2000 osoba. Godinama se broj timova povećavao i 2014. Godine je više od 100 zemalja bilo uključeno u GEM zajednicu [4].

2004. godine osnovana je GERA(Global Entrepreneurship Research Association) odnosno „Globalno udruženje za istraživanje poduzetništva“, definirana je kao udruga koja nadzire GEM projekt u Velikoj Britaniji. GERA je nadzirana od strane članova koje biraju zemlje GEM zajednice i članovi Babson Collegea i London Business Schoola. Što se tiče sponzorstva, Babson College je ostao glavni sponzor za cijeli projekt, a London Business School je isključen nakon 2007. Godine, iako ju još uvijek smatraju domaćinom GERA-e i ima pravo upravljanja sredstvima koje daju države, odnosno nacionalni timovi. Zaposlenici unutar organizacije su istraživači s punim radnim vremenom i stručnjaci za baze podataka, a po potrebi, pokreću se razne koordinacijske inicijative s raznim stručnjacima od strane GEM organizacije [4].

Godišnji sastanci GEM udruženja se obično održavaju u siječnju te tako predstavljaju prijelaznu točku u GEM ciklusima. Članovi nacionalnih timova se sastaju kako bi raspravljali kako je proveden prethodni ciklus, uspoređuje se kvaliteta podataka i uzoraka te se postavljaju pitanja kako poboljšati sama istraživanja. Prije svakog okupljanja postoje pripreme te se istražuju teme odnosno izmjene kod upitnika, anketa i drugih metoda istraživanja. Također, određuje se i „Posebna tema“ koja definira cijelo okupljanje i koja je unaprijed predstavljena nacionalnim timovima kako bi se znali pripremiti na nju. Pitanja o posebnim temama istražuju se i usavršavaju tijekom rujna i listopada, te se onda odlučuje hoće li se pitanja u konačnici naći u upitnicima, kada dođe vrijeme za godišnji sastanak u siječnju [2].

2.2. GEM istraživanja u moderno doba

GEM skupovi podataka javno su dostupni tri godine nakon završetka istraživanja, oni pružaju jedinstveni izvor za procjenu čimbenika koji utječu na stvaranje poduzeća i njegovu ulogu u gospodarskom rastu. Sustavno ocjenjivanje nacionalnih stručnjaka u zemljama sudionicama GEM istraživanja osigurava lakše proučavanje nacionalnih uvjeta poduzetništva, nadopunjujući različite utvrđene mjere nacionalnih ekonomskih i političkih obilježja. Postoje tri različite značajke koje karakteriziraju GEM inicijativu: jedinstvena organizacijska struktura, globalna izvješća koja sumiraju godišnje procjene poduzetničke aktivnosti i skupovi podataka koji su sastavljeni i dostupni za javnu upotrebu [4].

2.2.1. Ankete o populaciji odraslih

Kao što smo spomenuli još od samih početaka GEM istraživanja, jedna od osnovnih metoda istraživanja su *ankete*; jedna takva anketa, „Anketa o populaciji odraslih“, provodila se da bi se postigle usklađene mjere percepcije mogućnosti, mjere kojima bi se lakše proveo osnutak novih tvrtki i kako bi se lakše upravljalo novim poslovnim pothvatima.

Provođenje anketa i drugih GEM istraživanja je imalo određena ograničenja, kod svake države odnosno kod nacionalnih timovi se pazilo na troškove. Svaki od tih timova bio je suočen s prikupljanjem financijske potpore, a ako uzmemo u obzir da su se širenjem inicijative priključile i „manje“ zemlje, odnosno zemlje s ograničenim resursima, onda je shvatljivo da nije bilo jednostavno dobiti podršku za prikupljanje podataka. Također, ono što je predstavljalo određeni problem, bilo je intervjuiranje svih segmenata društva, neko od tih segmenata su ograničeni u području obrazovanja ili je problem predstavljao jezik zbog provođenja intervjua. Sve to je utjecalo na donošenje odluke da će se koristiti kratki intervjui s izravnim pitanjima i jednostavnim alternativama kod odgovora, tipa „da/ne“ što je bilo najjednostavnije za shvatiti na bilo kojem jeziku.

Sljedeći cilj je bio provođenje intervjua za dvije skupine ispitanika, od koji su prvi oni koji predstavljaju opću populaciju odraslih koji daju percepciju mogućnosti i sposobnost za osnivanjem novih tvrtki, odnosno oni koji daju osjećaj kakva je opća poduzetnička klima. S druge strane imamo one koji su aktivni u stvaranju novih tvrtki ili koji upravljaju postojećim poduzećima tj. ulaganjima. Postojala je pretpostavka da je 2.000 uzoraka po nacionalnom timu dovoljno kako bi se dobili relativno precizni rezultati o poduzetnicima u nastajanju [4].

Osim anketa o populaciji odraslih, još se provode dva istraživanja iz kojih se crpe podaci, to su ; *Ključni informativni intervju* i *Sekundarni nacionalni ekonomski podaci.* Kod prvog imamo detaljne i strukturirane upitnike otvorenog tipa. Također, svake godine svaka

zemlja sudionica mora identificirati poduzetničke stručnjake koji su intervjuirani licem u lice te ispunjavaju upitnik o devet okvirnih uvjeta koje GEM smatra bitnima za poduzetništvo.
Drugo istraživanje se provodilo korištenjem podataka iz institucija kao što su OECD(Organizacija za ekonomski suradnju i razvoj) i Svjetska banka. Sami podaci su usklađeni za uspoređivanje između zemalja [6].

2.2.2. TEA

TEA(Total Early-Stage Entrepreneurial Activity) je stopa prevalencije pojedinca u radno sposobnom stanovništvu koji su aktivno uključeni u osnivanje poduzeća, bilo u fazi pokretanja nove tvrtke, tzv. „poduzetnici u nastajanju“, ili u fazi koja se proteže 42 mjeseca nakon osnutka tvrtke, tzv. „vlasnik-upravitelj novih tvrtki“. Također, stvaranje poslovanja može se smatrati procesom u dvije faze; početnom ili predprofitnom fazom nakon čega slijedi razdoblje početne dobiti. S druge strane ako gledamo da se uzorak za istraživanja sastojao od minimalno 2000 ispitanika, postojale su određene pogreške u rezultatima, same pogreške su se mogel smanjiti ako je više aktivnosti uključeno u mjeru aktivnosti, što ne zahtijeva povećanje u veličini uzorka. Sve to je dovelo do stvaranja indeksa ukupne poduzetničke aktivnosti (TEA) ili rane faze poduzetničke aktivnosti. Onima koji su se kvalificirali kao „poduzetnik u nastajanju“ ili kao „vlasnik-upravitelj nove tvrtke“ dodijeljena je vrijednost 1, a svima ostalima je dodijeljena vrijednost 0 [4].

2.3. CEPOR

„CEPOR ili Centar za politiku razvoja malih i srednjih poduzeća i poduzetništva je prvi think-tank u Hrvatskoj koji se bavi problematikom malih i srednjih poduzeća i poduzetništva [5]*.“*

> *„Think-tank je moderan tip neprofitne organizacije, koja se bavi istraživanjem i edukacijom o određenoj javnoj politici ili problemu, a s ciljem utjecaja na javnu raspravu i proces donošenja odluka* [5]*.“*

CEPOR je neprofitna organizacija osnovana 2011. godine, nastala je temeljem dogovora između Republike Hrvatske i Instituta Otvoreno društvo-Hrvatska. Osnivače čine 10 institucija koje su lideri u svojim područjima djelovanja, bilo to djelovanje u akademskoj

zajednici ili gospodarstvu. Osnivače čine: Ekonomski institut Zagreb, Ekonomski fakultet u Osijeku, Sveučilište J.J. Strossmayera u Osijeku, Institut za međunarodne odnose, Zagreb(Akademska zajednica) , Hrvatska gospodarska komora, Hrvatska obrtnička komora (Udruženja gospodarstvenika), Razvojne institucije kao što su Centar za poduzetništvo iz Osijeka i drugi. Jedan od glavnih ciljeva CEPOR-a je doprinos oblikovanju poduzetničke kulture, te stimulativnog institucionalnog okvira za poduzetničko djelovanje, kako bi se ostvario snažan ekonomski rast [5].

GEM istraživanje za Hrvatsku od 2002. godine provodi CEPOR, već smo spomenuli da je GEM najveće svjetsko istraživanje poduzetničke aktivnosti. GEM istraživanje za Hrvatsku nezaobilazni je izvor informacija svim političkim liderima i brojnim međunarodnim institucijama kod oblikovanja poduzetničke okoline. „*GEM Hrvatska*“ istraživački tim čine: dr.sc. Slavica Singer(voditeljica tima), dr.sc. Nataša Šarlija, dr.sc. Sanja Pfeifer i dr.sc. Sunčica Oberman Peterka. GEM istraživanje za Hrvatsku provodi se uz podršku *Hrvatske udruge banaka i Ministarstva gospodarstva, poduzetništva i obrta* [5].

2011. započeo je projekt izrade redovnih godišnjih izvješća, izvješća prikazuju osnovne značajke sektora malih i srednjih poduzeća u Republici Hrvatskoj, prezentira se institucionalni i zakonodavni okvir te se pokazuje koliko je raspoloživa podrška(financijska i edukacijska) sektoru malih i srednjih poduzeća. CEPOR vidi izvješća kao izvor informiranja nadležnih institucija i šire javnosti o problemima u poduzetništvu u Hrvatskoj te kao osnovni cilj želi kreirati kvalitetnu informacijsku osnovu za donošenje odluka s kojima je omogućeno jačanje poduzetničke kulture i jačanje sektora malih i srednjih poduzeća, tako da se poveća broj zaposlenih, odnosno da se stvori veći doprinos navedenih sektora k jačanju BDP-a [5].

Razvoj ženskog poduzetništva u Republici Hrvatskoj se odvijao/odvija u dvije faze, od 2010.-2013. te od 2014.-2020. U prvoj fazi strategije razvoja 2010.godine CEPOR je izradio analizu najboljih praksi razvoja ženskog poduzetništva u zemljama EU. U drugoj fazi, od travnja 2014. godine, započeta je nova strategija, izrađena na temelju strategije 2010.-2013. Glavni cilj strategije je bila želja za smanjenjem nezaposlenosti žena, te povećanje uključenosti žena u raznim regionalnim gospodarskim aktivnostima i drugim područjima društvenog života [5].

.

2.4. GEM podaci na mikro razini

Nakon detaljnog opisa GEM zajednice i s njom povezanih pojmova potrebno je objasniti i same GEM podatke. U sljedeća dva potpoglavlja objasniti ćemo primjenu GEM podataka te ćemo opisati nekoliko istraživanja koja su dosad koristila GEM podatke u svojim analizama, počevši od GEM podataka na mikro razini.

Poduzetništvo na mikro razini slijedi ideju poduzetništva u nastajanju. Poduzetništvo u nastajanju se definira na temelju dva velika istraživačka projekta; već ranije spomenuti GEM projekt i PSED(Panel Study of Entrepreneurial Dynamics). Projekti imaju sličnosti i različitosti te ih povezuje metodologija istraživanja koja se razvijala tijekom većeg broja godina. Osnovna ideja iza nastalih poduzetničkih istraživanja je identificirati statistički reprezentativni uzorak, a u GEM projektu je to ostvareno pomoću već spomenute *Ankete o populaciji odraslih*, gdje se slučajnim uzorkom odraslih postavljaju ova pitanja;

- Pokušavate li sami ili s drugima započeti novi posao, uključujući bilo kakvo samozapošljavanje ili prodaju robe ili usluge drugima?
- Pokušavate li sami ili s drugima pokrenuti novi posao ili novi pothvat za svog poslodavca?

Svi koji su na jedno od ova dva pitanja odgovorili s „da“ smatraju se poduzetnicima u nastajanju, ako su aktivno pripomogli u pokretanju novog posla ili poduzeća i ako očekuju posjedovanje barem dijela poduzeća. Ono što razlikuje GEM od PSED-a je „dodatna skupina ljudi“ koju smatraju poduzetnički aktivnom; ta skupina se identificira prema pitanju;

- Dali ste sami ili s drugima vlasnik tvrtke u kojoj pomažete upravljati, zapošljavati radnike ili prodavati bilo koju robu ili usluge drugima?

Ako netko odgovori „da“ na ovo pitanje i ako nije primio plaću duže od 42 mjeseca, oni se smatraju poduzetnički aktivnima. Ako uzmemo u obzir sve značajke istraživanja i njihove rezultate, GEM može definirati poduzetnički aktivne kao *„odrasle osobe u procesu osnivanja poduzeća koji će posjedovati ili trenutačno posjedovati i upravljati mladim poduzećem“* [6].

2.5. Poduzetništvo i gospodarski učinak

„Tipovi i faze poduzetništva mogu utjecati na ekonomiju zemlje na različite načine u različitim dijelovima svijeta [7]*.“*

Osim ovog citata potrebno je uočiti međuodnos poduzetništva i gospodarstva, poduzetništvo može utjecati na gospodarski rast i dugoročni gospodarski razvoj, dok gospodarstvo može utjecati na razine poduzetničke aktivnosti. U ovom potpoglavlju bavit ćemo se tim odnosom i vidjet ćemo da je potrebna pažljiva analiza za razdvajanje tih odnosa. Poduzetnici sudjeluju u stvaranju radnih mjesta, sudjeluju u rastu produktivnosti i inovacijama, također indirektno utječu na regionalni rast putem prelijevanja znanja, to njihovo sudjelovanje definiramo kao *„ekonomska vrijednost poduzetništva“.* Poduzetnici povećavaju dinamiku moderne ekonomije te ovdje ne mislimo na postojeća i velika poduzeća nego novonastale tvrtke, postojeće osiguravaju stabilnost te su bolje za proizvodnju i primjenu inovacija. Moderna istraživanja ukazuju na važnost stvaranja i ulaganja u znanje kao uvjeta za ambiciozne poduzetnike i kao osnova za gospodarski rast u razvijenijim državama svijeta. Zemlje u razvoju moraju doseći određeni prag razvoja kako bi poduzetništvo uopće moglo imati pozitivan učinak na gospodarstvo.

Sama istraživanja odnosa poduzetništva i ekonomije bila su gotovo nemoguća s obzirom na kvalitetu akademskog sadržaja do globalne ekonomske krize 2008. godine. Nakon te krize i krize eura, kvantiteta i kvaliteta radova i sadržaja se povećala te su radovi pokrivali različita gospodarstva i davali značajan doprinos empirijskoj literaturi. U konačnici, budući radovi temeljeni na GEM metodologiji trebali bi dosljedno povezivati dinamiku poduzetništva s gospodarskim rastom, kako iz teorijske perspektive, tako i iz empirijske [7].

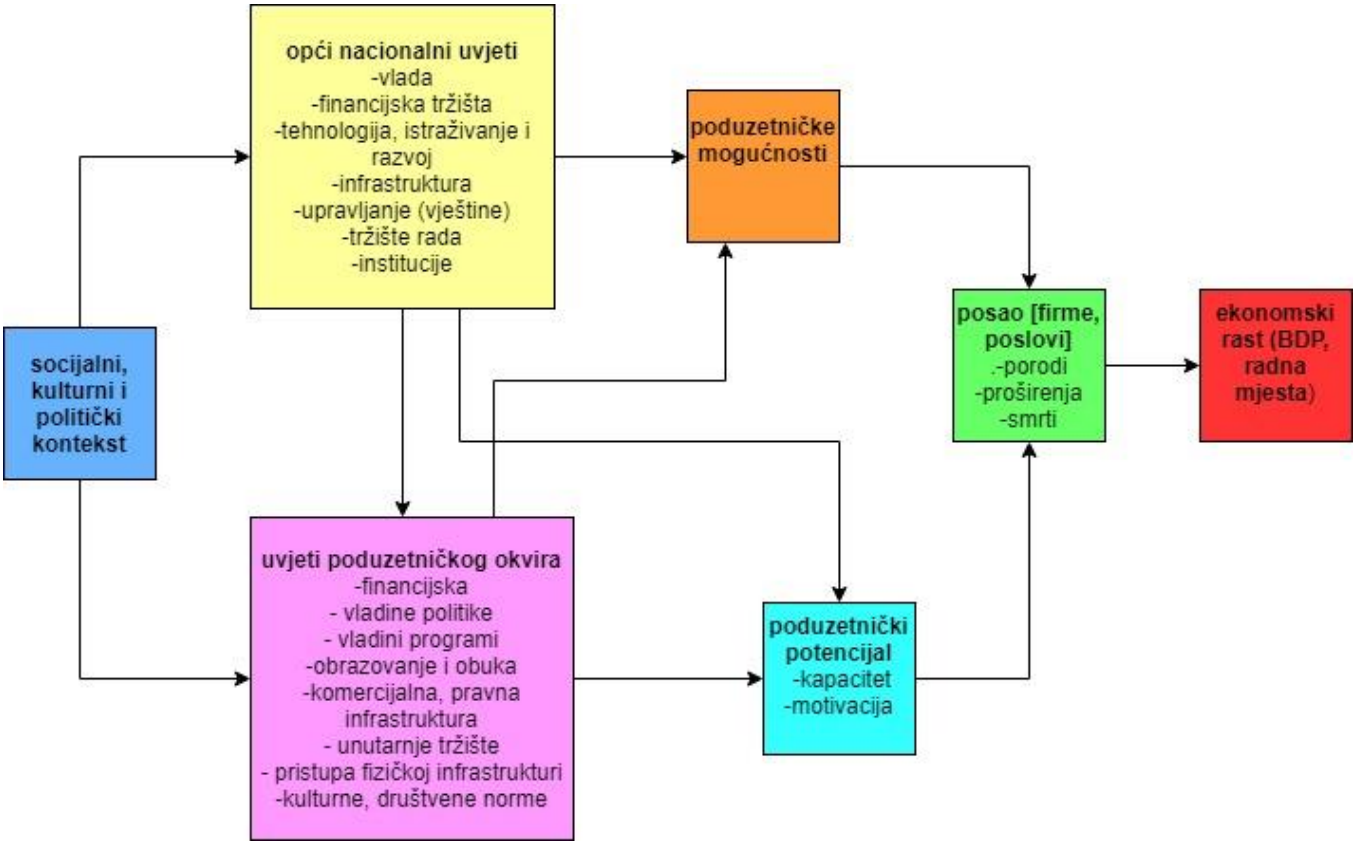
Kako je rasla kvaliteta akademskog sadržaja tako se pojavljuju i druga istraživanja osim GEM-a. Pojavljuje se novi skup podataka o istraživanju poduzetništva, Grupe Svjetske banke(WBGES ili World Bank Group Entrepreneurship Survey). GEM podaci služe za mjerenje poduzetničke aktivnosti u ranoj fazi a WBGES za formalnu registraciju poslovanja. Rjeđe GEM podaci pokazuju znatno niže razine poduzetničke aktivnosti u ranoj fazi u razvijenim zemljama, odnosno češća je situacija osnivanja formalnog poslovanja u razvijenoj zemlji nego osnivanje samostalnog poduzeća. Više se koriste za opisivanje stanja zemalja u razvoju nego za razvijenije zemlje. Istraživanja su pokazala da zemlje u razvoju imaju nisku stopu namjere i visoku stopu neformalnosti poduzetništva, dok razvijenije zemlje kao što su Sjedinjene Američke Države i Njemačka pokazuju upravo suprotno. Tvrtke u razvijenim zemljama imaju veću jednostavnost i poticaje, sve s ciljem većeg pristupa formalnom financiranju kao i u porezne i druge svrhe koje se ne odnose na poslovne aktivnosti.

WBGES je za istraživanje 2008. prikupljao podatke izravno iz registra tvrtki u više od 100 zemalja širom svijeta, te WBGES predstavlja važnost poduzetništva u dinamici moderne ekonomije. Istraživanje iz 2010. godine je pokazalo da informatizacija i automatizacija kod procesa registracije tvrtke smanjuje regulatorske prepreke za pokretanje poslovanja te uz niže troškove čini osnovne razloge izlaska iz krize poduzetničke aktivnosti [8].

3. Struktura GEM podataka

Za bolje razumijevanje GEM podataka odnosno njihove strukture koristit ćemo nekoliko akademskih istraživanja. Stručnjaci se najčešće bave ovim istraživačkim pitanjima: Kako se trenutno koriste GEM podaci u akademskom istraživanju u smislu razine analize, varijable, metode, shema mjerenja i analitičkih postupaka? Koje su najbolje prakse i problematična područja primjene? Kako se u budućim studijima može koristiti GEM baza podataka do svog punog potencijala? I mnoga druga pitanja kojima se bave dvije glavne skupine istraživača, oni koji rade s postojećim GEM podacima i ljudi koji su odgovorni za prikupljanje novih GEM podataka, tj. već spomenuti nacionalni GEM timovi i koordinacijski timovi [10].

Za početno razumijevanje strukture GEM podataka prikazat ćemo dijagram i tablicu koja prikazuje uzročni mehanizam koji predstavlja utjecaj poduzetništva na ekonomski rast.



Slika 1. Idejni model GEM-a i aktivnosti prikupljanja podataka [9]

Dijagram prikazuje kako poduzetnička ideja polazi od samog proučavanja tržišta i istraživanja kolike su financijske mogućnosti potencijalnog poduzetnika. Nakon te prve dvije barijere proučava se što je sve moguće uz prikupljeni informacije te se preispituje potencijal

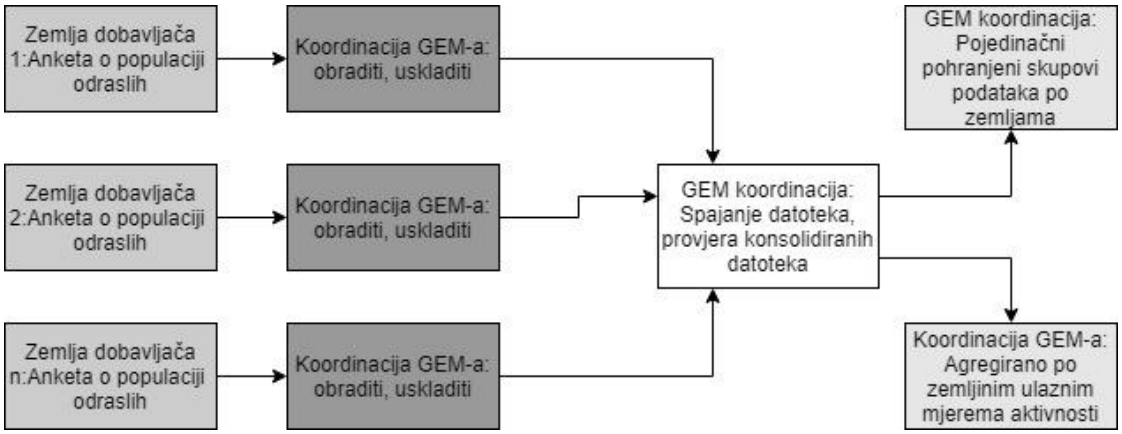
poduzetnika i određene životne situacije koje mogu biti prepreka u rastu nove tvrtke, shodno tome, rezultat postupka je ekonomski rast tj. rast BDP-a i radnih mjesta.

Tablica 1. Idejni model GEM-a i aktivnosti prikupljanja podataka [9]

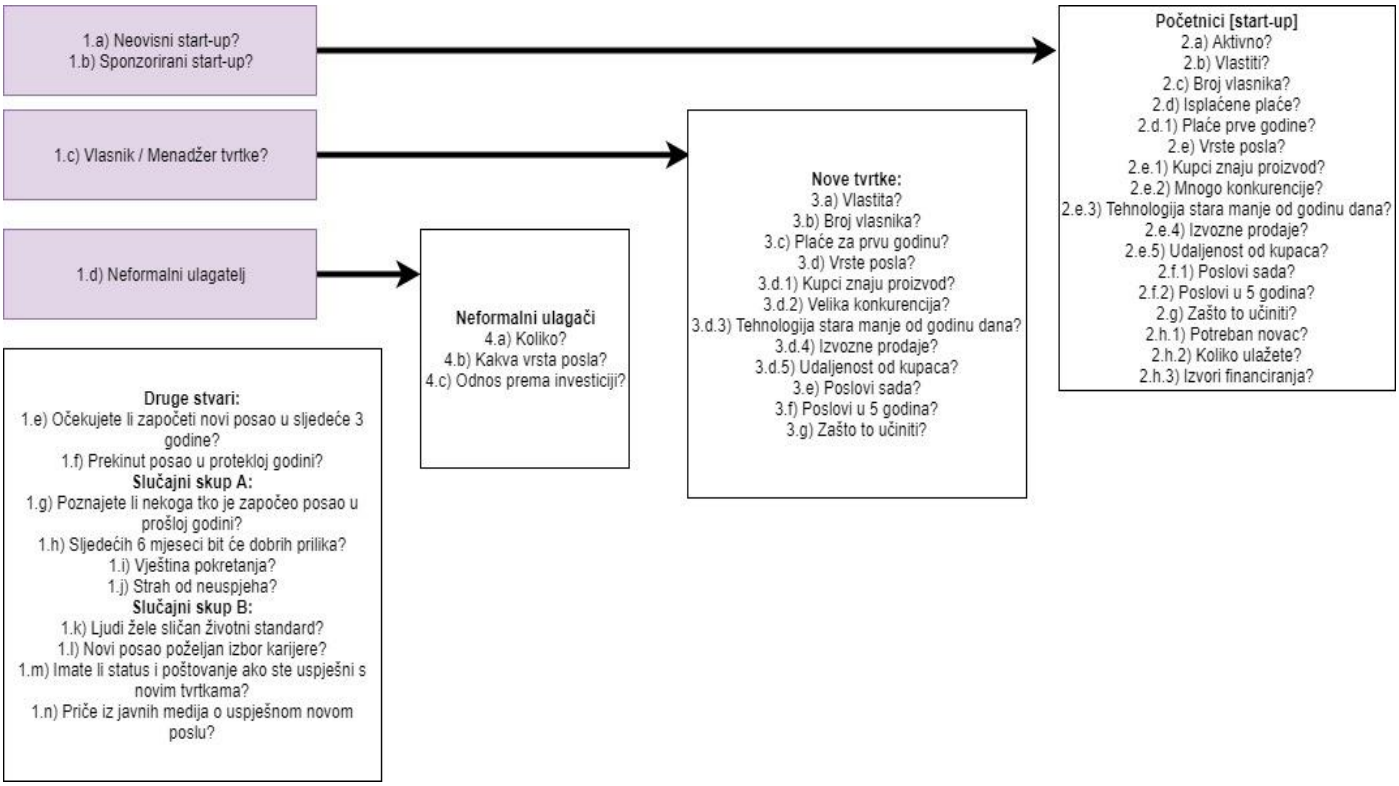
KONCEPTUALNE DOMENE	Socijalni, kulturni i politički kontekst	Opći nacionalni uvjeti	Uvjeti poduzetničkog okvira	Poduzetničke mogućnosti	Poduzetnički potencijal	Dinamika poslovanja	Ekonomski rast
IZVORI PODATAKA							
Standardizirani nacionalni podaci: Različiti izvori (OECD, Svjetska banka; Ujedinjene nacije; EU, ILO itd.):	X		X				X
Izvješća o globalnoj konkurentnosti: 1997, 1998		X					
Ankete o populaciji odraslih , standardizirano i nadzirano od strane koordinacijskog tima				X	X	X	
Ključni informativni intervju: Face-to-face od strane nacionalnih timova			X	X	X		
Ključni informativni intervju: Samo-ispunjavajući upitnik			X	X	X		

Tablica 1. nadopunjuje prethodni dijagram i pokazuje uzročno-posljedične veze između domene koje smo naveli na dijagramu i izvora podataka, tako npr.: Anketa o populaciji

odraslih otkriva poduzetničke mogućnosti i potencijal, kao i dinamiku poslovanja određene tvrtke. Kao okosnicu kod opisa i objašnjavanja strukture koristit ćemo ankete o populaciji odraslih, tako se nadzor, pregled i procjena istraživanja ankete o populaciji odraslih prikazuje na slici 2. , dok se raspored i struktura intervjua, koji odobravaju nacionalni timovi GEM-a kao kolektivnu odluku, prikazuje na slici 3.



Slika 2. Organizacija postupka prikupljanja podataka o GEM Anketi o populaciji odraslih [9]

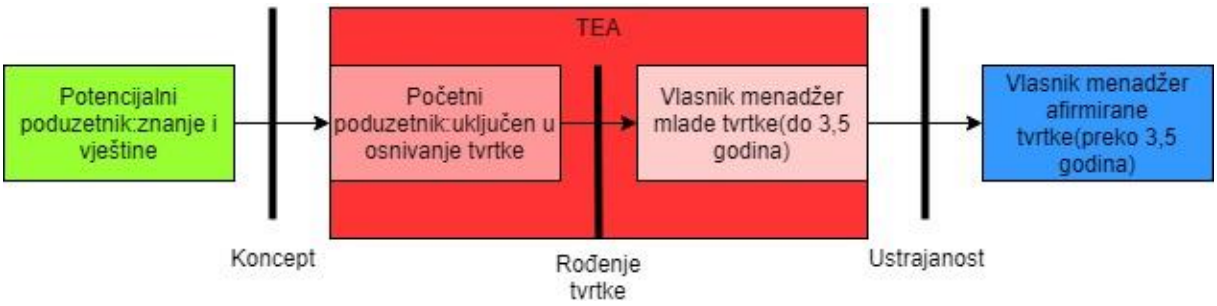


Slika 3. GEM 2003; Anketa o populaciji odraslih: shema struktura intervjua [9]

3.1. „Stvaranje novog posla/nečeg novog“

Poduzetništvo se u konceptu i okviru GEM zajednice često definira kao stvaranje novog posla ili stvaranje nečeg novog. Postupci istraživanja GEM podataka za procjenu nacionalne poduzetničke aktivnosti nisu razvijeni kao nešto potpuno novo već kao modifikacije postupaka razvijenih u tekućem istraživačkom programu poduzetničkog procesa. Prvi uspješni napori za pronalaženjem reprezentativnog uzorka poduzetnika-početnika završeni su u Wisconsinu 1992. godine, zatim slijedi razvoj reprezentativnog uzorka odraslih iz SAD-a dodavanjem modula američkog istraživanja o stavovima potrošača u jesen 1993. Već iz ovih početnih studija pokazalo se da je izvedivo razviti reprezentativni uzorak odraslih koji su započeli posao u bilo kojem dobro definiranom rasponu populacije [9].

Već smo ranije u radu spomenuli da postoje sličnosti između GEM i PSED projekta, no nismo izrazili bitne razlike kroz koje najlakše možemo vidjeti kako se stvara poduzetnička aktivnost. Primarni cilj GEM projekta je procijeniti učestalost pojedinca koji su uključeni u poduzetničke aktivnosti u jednom trenutku, a ne pratiti ljude koji osnivaju posao tijekom nekoliko godina i procijeniti one čimbenike koji dovode do uspješnog stvaranja tvrtke. Drugi cilj je da se pored onih koji implementiraju novi posao, prikupljaju i podaci od vlasnika-menadžera osnovanih tvrtki, bez obzira na starosnu dob. Na temelju PSED postupka, GEM program je implementirao model koji pokriva većinu životnog puta tvrtke, od osnivanja, preko ranih godina kao novo poslovanje, sve do faze gdje se firma smatra stabilnom na tržištu [9].



Slika 4. Poduzetnički proces i operativne definicije GEM-a [9]

Poduzetnički proces se sastoji od četiri faze i 3 prijelazne točke, koje označavaju tipične poduzetničke barijere. Prva faza „start-upa“ sastoji se od ljudi u odrasloj populaciji koji razmišljaju o osnivanju poduzeća. Kada pojedinci učine prve korake i odmaknu se od „samo

pričanja“ prošli su prvu barijeru odnosno koncept ili dizajn, te od potencijalnog poduzetnika postaju poduzetnici početnici. Sljedeća tranzicija se odnosi na rođenje tvrtke. GEM zajednica definira rođenje tvrtke kada se provede isplata plaća i nadnica za razdoblje dulje od 3 mjeseci, isplata bilo kome pa i vlasnicima. Prije prelaska na posljednju barijeru možemo vidjeti da slika prikazuje kako se faza početnog poduzetnika i vlasnika menadžera nalazi u „ranoj fazi poduzetničke aktivnosti“ odnosno u TEA-fazi ili indeksu koji smo već ranije u radu objasnili. Barijera ustrajnosti odnosno razlika između mlade tvrtke i afirmirane tvrtke je upravo u godinama poslovanja.Tvrtka koja provede isplatu plaća za više od 3 mjeseci i manje od 3,5 godina se smatra „novom“ a tvrtke s isplatom dužom od 3,5 godina se nazivaju „afirmirane tvrtke“ odnosno često imaju i naziv „tvrtke koje su preživjele odgovornost početništva“ [9].

3.2. Trenutno i buduće korištenje GEM podataka

GEM program je osmišljen tako da osigura empirijske mjere kritičnih varijabli koje su povezane s GEM konceptualnim modelom, uz najniže troškove. Namjena modela bila je voditi istraživanje o ulozi poduzetništva u nacionalnom gospodarskom rastu te radi daljnjeg razumijevanja razlika na nacionalnoj razini poduzetništva i pomoći u izradi učinkovitih politika za jačanje poduzetništva. S obzirom na to da je projekt bio uspješniji nego što se očekivalo, rezultati GEM istraživanja su preobrazili perspektivu političara i znanstvenika. Više nikada se na poduzetništvo neće gledati kao na perifernu aktivnost koja nije povezana s ekonomskom prilagodbom i promjenama. Također veliki udio, čak 500 milijuna od 6 milijardi ili jedan od šestorice svih odraslih na svijetu je izravno uključen u stvaranju firme a ako uzmemo i neizravno sudjelovanje, u stvaranju firme sudjeluju i obitelji, rodbina, prijatelji, susjedi, itd [9]...

Kao neka vrsta finalnog proizvoda nakon GEM istraživanja ili određenog GEM projekta smatraju se veliki broj akademskih članaka, iako još uvijek postoji potencijal za buduća istraživanja. Na primjer, ako gledamo temu inovacije i internacionalizacije koje su do sada privukle samo neke publikacije, vidimo da ima prostora za napredak. S obzirom na dostupnost podataka za veliki broj zemalja, kao i duljinu GEM upitnika, GEM podaci pružaju široki raspon mogućnosti za istraživanja koja kombiniraju GEM podatke s podacima iz drugih izvora. Takvo kombiniranje podataka se koristilo u većini publikacija te čini osnovu za buduća istraživanja. Kada bismo analizirali GEM istraživanja i njihovu strukturu onda treba

spomenuti da postoji razina istraživanja gdje je ovisna varijabla na mikro razini a privremene varijable su mikro i makro razine. Opće je prihvaćeno da istraživači trebaju iskoristiti dostupnost mikro podataka i razmotriti izračun vlastite mjere poduzetničke aktivnosti koja najbolje odgovara njihovom istraživačkom pitanju. Istraživači također trebaju imati na umu da GEM obuhvaća sve poduzetničke vrste aktivnosti, uključujući samozapošljavanje, honorarno i neformalno gospodarstvo. To se s jedna strane smatra nedostatkom a s druge kao mogućnost jer ne postoji druga baza podataka koja nudi informacije o cijelom spektru novih poslovnih nastojanja. Kada istraživači koriste podatke iz standardiziranog upitnika potrebno je paziti na pouzdanost pitanja i odgovora, odnosno osiguravanje pouzdanosti i točnosti jedna je od neophodnih mjera, odnosno preduvjet za objavljivanje u časopisima o poduzetništvu i menadžmentu. Prijedlozi za budućnost GEM istraživanja se najčešće izlažu na već spomenutim GEM konzorcijima koji se sastoje od nacionalnih timova koji rade s ciljem stalnog poboljšavanja kvalitete prikupljanja i uporabe podataka. Kako je skup podataka prilično opširan, znanstvenicima bi koristila knjiga s kodovima koja opisuje svojstva varijable. Takva knjiga kodova može potaknuti upotrebu niza varijabli i tako proširiti granice istraživanja temeljenih na GEM-u. Osigurana dodatna transparentnost pomoću knjige bi moglo potaknuti donositelje politika i organizacije poput OECD-a da češće koriste podatke u statističke svrhe [10].

4. Analiza podataka u poduzetništvu

Cilj ovog završnog poglavlja je analizirati istraživanja s kojima su stvoreni modeli za proučavanje poduzetničkih namjera studenata odnosno mladih, koji ćemo objasniti u prvom potpoglavlju te predviđanje poduzetničkih odluka kod žena u drugom potpoglavlju.

U prvom potpoglavlju, gdje se istražuju poduzetničke namjere uz pomoć neuronskih mreža, stabla odlučivanja i stroja za podršku vektora, ukupan skupa podataka se sastojao od 237 studenata poslovne administracije na prvoj godini studija na Sveučilištu J.J. Strossmayera u Osijeku. Istraživanje je provedeno u srpnju 2010. godine. Izbor ulaznih varijabli birane su po dva teorijski priznata modela; Ajzen-ova teorija planiranog ponašanja i Shaperov model poduzetničkog događaja. Osim demografije studenata, korišteni su i drugi prediktori koji su grupirani u tri glavne komponente: očekivanje poduzetničkog ishoda, društvene norme i uvjerenja o poduzetništvu i poduzetničkoj karijeri te predispozicije odnosno poduzetnička samoefikasnost [11].

U drugom potpoglavlju, gdje se pomoću hipoteza istražuju poduzetničke odluke žena, u fokusu su bile 585 maturantica privatne ustanove koje su diplomirale između 1984-1989. Fokus grupa je imala su vrlo jasnu i različitu percepciju svog iskustva na radnom mjestu u odnosu na žene i muškarce s kojima su radile [12].

4.1. Istraživanje poduzetničkih namjera uz pomoć neuronskih mreža, stabla odlučivanja i metode potpornih vektora

Poduzetničke namjere studenata je najvažnije prepoznati tijekom studija kako bi im se pružila obrazovna podloga koja će podržati njihove namjere i dovesti ih do uspješnog poduzetničkog pothvata nakon studija. Cilj ovog potpoglavlja je razviti model kojim će se studente moći klasificirati prema njihovim poduzetničkim namjerama, model se temelji na uspoređivanju tri klasifikatora strojnog učenja, a to su: neuronske mreže(neural networks,(NN)), stablo odlučivanja(decision tree(CART)) i metoda potpornih vektora(support vector machines(SVM)). Podaci su izvučeni iz ankete koja je provedena na hrvatskom sveučilištu s uzorkom studenata koji pohađaju prvu godinu studija. Ulazne varijable predočile su demografiju studenta, važnost poslovnih ciljeva i poduzetničke predispozicije. Rezultati

pokazuju da je najbolji model, model neuronske mreže, odnosno da je proizveo najvišu prosječnu brzinu pogotka, no sama razlika s ostalim klasifikatorima i nije toliko značajna. Sva tri modela imaju sličan skup značajki relevantnih za razvrstavanje studenata, što bi moglo poslužiti raznim sveučilištima prilikom dizajniranja njihovih akademskih programa. Sljedeći odjeljak sadrži pregled metodologije NN-a, CART-a i SVM-a, te opis podataka i eksperimenata. Rezultati pojedinih modela i usporedba njih samih se iznose u drugom potpoglavlju [11].

4.1.1. Metodologija

Neuronske mreže(dalje u radu „NN“) uspješno su korištene za razvrstavanje, predviđanje i pridruživanje u različitim problematskim domenama. Glavna prednost NN-a je mogućnost približavanja bilo koje nelinearne matematičke funkcije. U ovom istraživanju je korištena najčešća vrsta NN-a, koji se naziva *višeslojni perceptron*(MLP). NN se sastoji od n ulaznih jedinica $x_i \ \epsilon \ \mathbb{R}$, $i = 1,2,\dots,n,$ i slučajno određenih početnih težina w_i obično iz intervala [-1,1]. Svaka jedinica u skrivenom sloju dobiva ponderirani zbroj svih x_i vrijednosti kao ulaz. Izlaz skrivenog sloja označenog sa y_c izračunava se kao:

$$y_c = f\left(\sum_{i=1}^{n} w_i \ x_i\right)$$

gdje je f aktivirajuća funkcija koju je odabrao korisnik, a koja može biti logistička, hiperbolička, eksponencijalna, linearna, itd... Izračunati izlaz uspoređuje se sa stvarnim izlazom y_a , a izračunava se lokalna pogreška $\mathcal{E}$. Pogreška se zatim koristi za podešavanje težina ulaznog vektora prema *„Delta“* pravilu učenja. Sam postupak se ponavlja u više iteracija, pri čemu se silazni gradijent koristi za minimiziranje pogreške [11].

Stabla odlučivanja ili stabla klasifikacije često se koriste u vođenju podataka, zbog svoje sposobnosti pronalaženja skrivenih odnosa među podacima. Cilj ove metode je izgraditi binarno stablo dijeljenjem ulaznih vektora na svaki čvor u skladu s funkcijom jednog ulaza. Najpopularniji algoritam za izgradnju stabla odlučivanja se naziva *„CART“* ili stabla klasifikacije i regresije. Kada bi morali sažeti CART algoritam na korake to bi izgledalo ovako:

1. Dodijeliti sve objekte korijenskom čvoru
2. Podijeliti svaku objašnjenu varijablu na sve moguće točke razdvajanja

3. Za svaku podijeljenu točku, podijeliti nadređeni čvor na dva podređena čvora odvajanjem objekta čija je vrijednost niža i viša od točke razdvajanja za razmatranu objašnjenu varijablu
4. Odabir varijable i točke razdvajanja s najvećim smanjenjem nečistoće
5. Izvršava se podijeljene nadređenog čvora na dva podređena prema odabranoj točki razdvajanja
6. Ponavljaju se koraci 2.-5., koristeći svaki čvor kao novi roditeljski čvor, sve dok drvo ne dobije maksimalnu veličinu
7. „Obrežite“ stablo koristeći unakrsnu provjeru za odabir stabla prave veličine

Evaluacijska funkcija korištena u ovom istraživanju za „cijepanje“ se zove Gini indeks koji se definira kao:

$$Gini(t) = 1 - \sum_i p_i^2$$

gdje je t trenutni čvor, a p_i vjerojatnost klase i u t [11].

Metoda potpornih vektora (dalje u tekstu „SVM“) je metoda strojnog učenja namijenjena korištenju za nelinearno preslikavanje ulaznih vektora u prostor s velikim dimenzijama. Osnovno načelo učenja u SVM-u je da se traži optimalni takozvani „hyper-plan“ koji udovoljava zahtjevu za klasifikaciju, a zatim koristi algoritam za izradu granica odvajanja pored optimalnog maksimalnog hyper-plana uz istovremeno osiguranje točnosti ispravne klasifikacije. U slučaju linearnog odvajanja, linearni SVM za optimalno razdvajanje hyper-plana ima sljedeći problem optimizacije:

Umanjiti $\emptyset(w) = \frac{1}{2}\, w^t w$

prema $y_i(x_i \cdot w + b) \geq 1, i = 1,2, \ldots, n.$

rješenje gornjeg problema optimizacije može se pretvoriti u dvostruki problem. Negativne Lagrangeove množitelje možete pretraživati rješavanjem sljedećeg problema s optimizacijom ako je problem nelinearan:

Povećati $\varrho(\alpha) = \sum_{i=1}^{n} \alpha_i - \frac{1}{2} \sum_{i=1}^{n} \sum_{j=1}^{n} \alpha_i\, \alpha_j y_i y_j\, K(x_i x_j)$

prema $\sum_{i=1}^{n} \alpha_i y_i = 0, 0 \leq \alpha_i \leq C,\ i = i = 1,2, \ldots, n.$

gdje je C negativni parametar koji su odabrali korisnici. Konačna klasifikacija je:

$$f(x) = sgn\{\sum_{i=1}^{n} \alpha_i^* \, y_i K(x_i, y_i) + b^*\}$$

gdje je K funkcija kernela koja može biti linearna ili polinomna [11].

Svaka od tri metode testirana je na dva skupa ulaznih varijabli: Model 1->svi dostupni podaci i Model 2->varijable odabrane postupkom odabira značajki na temelju statistike *„hi-kvadrat“* i p vrijednost za svaku varijablu prediktora (p <0,05 korišten je kao kriterij za odabir važnih varijabli). Učinkovitost svih modela mjeri se učestalošću pojavljivanja klase 0(tj. „Nedostatak poduzetničkih namjera“->hit_0 ili „negativna stopa pogodaka“), brzinom učitavanja klase 1(tj. „Postojanje poduzetničkih namjera“-> hit_1 ili „pozitivna stopa pogodaka“), te postoji i prosječna brzina pogodaka:

$$hit_0 = \frac{c_0}{t_0}, \; hit_1 = \frac{c_1}{t_1}, \; pros.pogodak = \frac{hit_0 + hit_1}{2}$$

gdje je c_0 broj učenika za koji je točno predviđeno da imaju izlaz 0, t_0 je broj studenata koji ima stvarni 0 izlaz, c_1 je broj učenika za koji je točno predviđeno da imaju izlaz 1, a t_1 je broj studenata sa stvarnim izlazom 1. Omjeri osjetljivosti i specifičnosti izračunati su prema:

$$osjetljivost = \frac{c_1}{(c_1 + d_0)}, \; specifičnost = \frac{c_0}{(c_0 + d_1)}$$

gdje je d_0 broj lažnih negativa(broj studenata koji lažno predviđaju da će imati izlaz 0), a d_1 je broj lažnih pozitivnih rezultata(broj studenata koji su predvidjeli da će imati izlaz 1). Pogreške su izračunate kako bi se usporedili troškovi pogrešne klasifikacije proizvedene od strane tri modela [11].

4.1.2. Rezultati i zaključak istraživanja

Tablica 2. Rezultati modela dobivenih NN, CART i SVM-om na testnom uzorku [11]

Model	**Model 1**			**Model 2**		
	Hit0 (%)	**Hit1 (%)**	**AvgHit (%)**	**Hit0 (%)**	**Hit1 (%)**	**AvgHit (%)**
MLP-logistički	52.00	88.00	70.00	84.15	64.71	74.43*

MLP-tangentna hiperbolika	70.00	70.00	70.00	46.00	70.00	58.00
MLP-eksponencijalan	51.00	82.00	66.50	59.00	76.00	67.50
MLP-funkcija linearne aktivacije	68.00	70.00	69.00	42.00	94.00	68.00
RBF-mreža	0.00	100.00	50.00	68.00	76.00	72.00
CART-stablo odluke	71.95	70.59	71.27	71.95	70.59	71.27
SVM-linearna jezgra	63.41	52.94	58.18	59.76	64.71	62.23
SVM RBF-jezgra	57.32	64.71	61.01	63.41	64.71	64.06
SVM-sigmoidna jezgra	60.98	70.59	65.78	63.41	70.59	67.00
SVM-polinomna jezgra	71.95	64.71	68.33	71.95	64.71	68.33

Iz tablice 2. se vidi da je najbolji model (s najvišom prosječnom brzinom) MLP neuronska mreža-Modela 2, koja koristi logističku aktivacijsku funkciju i proizvodi prosječnu brzinu pogotka od 74,43%. Mreža RBF također bolje funkcionira s modelom 2 nego s modelom 1, što daje prosječnu brzinu pogotka od 72%. CART stablo odluka pokazuje stabilnost rezultata u svim modelima, a prosječna brzina pogotka od 71,27% dobivena je za Model 1 i Model 2. Odabrano stablo odluka imalo je samo dva rascjepa, a varijabla „Prethodno obiteljsko poduzetničko iskustvo“ bila je jedina varijabla dijeljenja. Podijeljena kategorija je 1, što znaci da su svi studenti u skupu istraživanja koji imaju poduzetničku povijest (tj. da imaju poduzetnika u obitelji) klasificirani tako da imaju pozitivne poduzetničke

namjere, dok su ostali klasificirani tako da nemaju te namjere. Najbolji SVM model je Model 2 s polinomnom jezgrom, dobiven sljedećim parametrima: stupanj = 3,0, gama = 0,0625, koeficijent = 0. Ukupni broj izvučenih potpornih vektora iznosio je 86, pri čemu su 43 korištena za razred 0, a 43 za klasu 1. Može se primijetiti da su rezultati SVM modela niži od rezultata modela proizvedenih s druge dvije metodologije i da točnost ovisi o izboru funkcije kernela. Polinomna jezgra proizvela je najveću prosječnu brzinu udaranja od svih SVM jezgara (68,33%).

Da bi se usporedila točnost klasifikacije modela, provedeno je ispitivanje razlika u proporcijama (t-test), a njegovi rezultati prikazani su u tablici 3 [11].

Tablica 3. Statistička usporedba NN, CART i SVM modela [11]

Hipoteza	**Model**	**Prosječne stope pogodaka**	**T-test rezultati**
HO:NN=CART	NN	74.43	p=0.3089
	CART	71.27	
HO:NN=SVM	NN	74.43	p=0.1718
	SVM	68.33	
HO:CART=SVM	CART	71.27	p=0.3264
	SVM	68.33	

Test razlika u proporcijama pokazuje da se prosječna brzina pogotka MLP mreže ne razlikuje značajno od prosječne brzine pogotka CART modela, kao ni od prosječne brzine pogotka SVM modela. Na temelju ovog testa, ne može se zaključiti da bilo koji od tri modela nadmašuje ostala dva u točnosti predviđanja. Međutim, prijedlozi najboljeg modela za promatrani skup podataka mogli bi se usmjeriti na druge kriterije, poput pogreške tipa I i tipa II (ili osjetljivosti i specifičnosti). Tablica 4. prikazuje osjetljivost i specifičnost (na dijagonali svake matrice), kao i pogreške tipa I i tipa II najboljih modela NN, CART i SVM [11].

Tablica 4. Specifičnost i osjetljivost NN, CART i SVM modela [11]

Stvarni izlaz	**Izlaz predviđen NN modelom**		**Izlaz predviđen CART modelom**		**Izlaz predviđen SVM modelom**	
	1	0	1	0	1	0
1(poz)	0.65	0.35	0.71	0.29	0.65	0.35
0(neg)	0.16	0.84	0.28	0.72	0.28	0.72

Iz tablice 4. se vidi da specifičnost NN modela iznosi 0,65, dok je njegova osjetljivost 0,84. Lažno pozitivna stopa (tj. Greška tipa I) NN modela iznosi 0,35, dok je lažna negativna stopa (tj. Greška tipa II) 0,16. Otkriva da je NN model osjetljiviji od specifičnog, teži da klasificira više studenata koji zapravo nisu imali poduzetničke namjere u kategoriju pozitivnih s poduzetničkim namjerama. Kad se primijete isti koeficijenti CART modela, može se primijetiti da je specifičnost ovog modela najveća (0,71) medu sva tri modela, dok je osjetljivost CART-a jednaka osjetljivosti SVM-a (0,72), što je niža od osjetljivosti NN modela. Najniža stopa lažne pozitivne brzine postignuta je u NN i SVM modelima (0,35), dok je najmanja lažna negativna brzina pogotka dobivena NN modelom. CART model ima najmanju razliku između pogreške tipa I i tipa II, što implicira da je ovaj model sposoban uravnotežiti osjetljivost i specifičnost. Da bi se dobio bolji uvid u važnost ulaznih varijabli u predviđanju studentskih poduzetničkih namjera, analiza osjetljivosti provedena je na najboljem NN modelu korištenjem izvan uzorka podataka. Najvažnija varijabla je „prethodno obiteljsko poduzetničko iskustvo“ što znači ako u obitelji postoji poduzetnik, studentske namjere će vjerojatno biti pozitivne. Ostale visoko rangirane varijable po NN modelu su „Prethodna radna izloženost“, „Razumijevanje za poduzetnički način razmišljanja“, „Percipirana kontrola“

i ostale varijable većinom iz skupine „Poduzetničke predispozicije i poduzetnička samoefikasnost“. Iako je rangiranje po CART modelu različito od onog po NN modelu, oba su modela predviđala vrlo važna oba modela, poput "Druženje s poduzetnicima", "Prethodno radno izlaganje", "Ljudi misle da sam osoba s neobičnom / nekonvencionalnom idejom "i" Razumijevanje poduzetničkog načina razmišljanja " [11].

Možemo zaključiti sljedeće, ovo istraživanje ima za cilj analizirati učinak tri metode strojnog učenja u modeliranju poduzetničkih namjera studenata na temelju demografskih varijabli, očekivanja poduzetničkog ishoda, društvenih normi i uvjerenja o poduzetništvu i poduzetničkoj karijeri. Iako je model s najvećom preciznošću u klasifikaciji NN model, njegova prosječna brzina pogotka ne razlikuje se značajno od stope pogotka druga dva modela. Također kroz istraživanje pokazalo se da NN model pokazuje najveću osjetljivost a CART model je najspecifičniji u prepoznavanju pozitivnih poduzetničkih namjera.

4.2. Predviđanje poduzetničkih odluka kod žena

U posljednjih šest desetljeća, priliv žena u radnu snagu dogodio se izrazito brzim tempom, što je dovelo do stope sudjelovanja u ukupnoj radnoj snazi s 46 do 48%. Unatoč stopama sudjelovanja u radnoj snazi, brojna istraživanja otkrivaju kako se žene i dalje suočavaju sa stereotipima, bore se s problemima u zapošljavanju, napredovanju, daljnjoj obuci i plaćama. Jedno područje koje je dobilo adekvatan fokus je razina zadovoljstva ženama poslom u usporedbi s njihovim muškim kolegama. Međutim, nijedna poznata studija nije proučila vezu između nivoa zadovoljstva poslom i razine zadovoljstva vještinama i obukom stečenih ženskim fakultetskim obrazovanjem. Zadovoljstvo poslom definirano je kao pozitivan osjećaj o nečijem poslu te su različita istraživanja pokazala da se zadovoljstvo poslom pozitivno odnosi na motivaciju, uključenost u posao, ponašanje u organizacijskom građanstvu, organizacijsku predanost, zadovoljstvo životom, mentalno zdravlje i radnu uspješnost, a negativno je povezano s izostancima, prometom i percipiranim stresom. Upravo kod istraživanja koje ćemo proučiti u ovom potpoglavlju se odnosu na zadovoljstvo poslom među ženama što u konačnici i rezultira njihovom poduzetničkom perspektivom i poduzetničkim odlukama. Istraživanje uključuje tri glavna pitanja: 1. hoće li žene iz iste diplomatične skupine izraziti različite razine zadovoljstva poslom kad promatraju različite rodne perspektive? 2. hoće li žene iz iste skupine iskazati različito zadovoljstvo poslom s napredovanjem posla i naknadom, ponovo, kad se promatraju iz različitih rodnih perspektiva? Treće, koja će biti veza između zadovoljstva postignutim fakultetskim obrazovanjem i razine zadovoljstva poslom za spomenutu skupinu žena? Samo istraživanje pred sebe postavlja 6 hipoteza, dok ćemo mi detaljnije proučiti samo jednu od njih [12].

Skup hipoteza čine:

1: Žene koje iskazuju niže razine zadovoljstva smislenim poslovima imaju veću vjerojatnost za poduzetnički odabir.

2: Žene koje iskazuju niže razine zadovoljstva zbog školovanja na fakultetima, vjerojatnije će se uključiti u poduzetničke odabire.

3: Vjerojatnije je da će žene s djecom započeti posao.

4: Vjerojatnije je da će žene koje su u braku započeti posao.

5: Vjerojatnije da će žene s djecom pokrenuti posao.

6: Vjerojatnije je da će žene koje su imale visoku razinu napredovanja posla pokrenuti posao.

*Hipoteze 1-6; u odnosu na žene koje su u suprotnoj situaciji [12].

U ovom radu ćemo detaljnije proučiti 3. hipotezu; koja definira da je vjerojatnije da će žena s djecom započeti posao u odnosnu prema ženama bez djece.

Tablica 5. Istraživanje hipoteze 3. [12]

			Broj_djece		**Ukupno**
			0	1	
Pos_Tvrtku	0	Broj	67	374	441
		Očekivani broj	70.7	370.3	441.0
	1	Broj	26	113	139
		Očekivani broj	22.3	116.7	139.0
Ukupno		Broj	93	487	580
		Očekivani broj	93.0	487.0	580.0

Napomena:

Pos_Tvrtku = 1, znači da je osoba vlasnik tvrtke, Pos_Tvrtku = 0, znači da osoba nije vlasnik tvrtke.

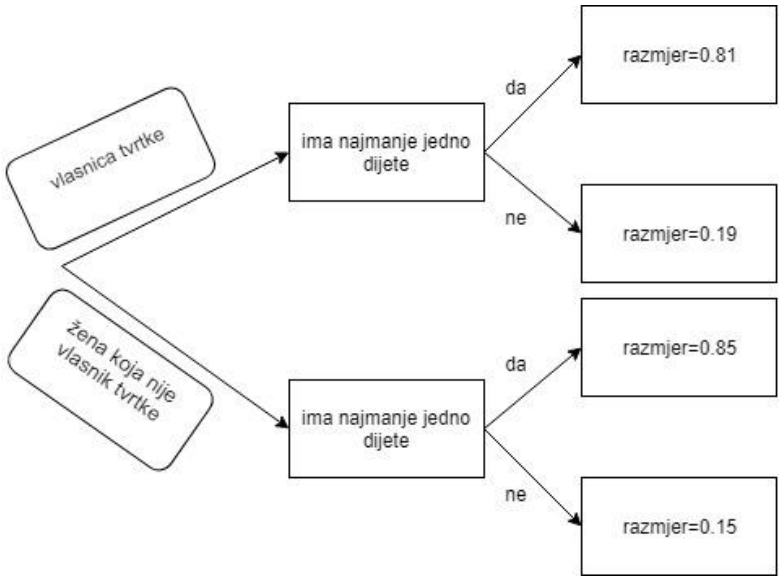
Broj_djece = 1, znači da žena ima najmanje jedno dijete, Broj_djece = 0, znači da nema dijete.

Izračunati „hi-kvadrat“ vrijednost = 0,968,

Zbirna vrijednost raspodjele „hi-kvadrata“:

$$\gamma^2\ \alpha = 2.706,\ \ 3{,}841,\ 5.412,\ 6.635\ \ za\ \alpha = 0{,}10, 0.05, 0.02, 0.01$$

„Hi-kvadrat“ test je neznatan. To znači da su kategorije vlasnici tvrtke / ne-vlasnici homogene grupe na temelju ako imaju djecu ili nemaju djecu. Dakle, samo razmatranje ove dvije varijable navodi nas da odbacimo hipotezu "Žene s djecom vjerojatnije su od kolega da pokrenu posao." Dijagram odluke u nastavku prikazuje relativne razmjere žena vlasnica tvrtki i onih koje nisu vlasnice tvrtki te onih koje imaju barem jedno dijete i nemaju dijete. Relativni udjeli izgledaju slično u dvije kategorije; žena vlasnica tvrtke i žena koja nije vlasnica tvrtke. Ovo potvrđuje hi-kvadrat test rezultata homogenosti koji smo dobili u tablici iznad [12].



Slika 5. Dijagram odluke hipoteze 3 [12]

Dakle, da potvrdimo, gornji dijagram odluka pokazuje da je hipoteza „da su žene s djecom vjerojatnije od svojih kolega da pokrenu posao“ lažna.

Možemo zaključiti sljedeće, kao što je i hipoteza 3 bila neistinita , tako su i većina hipoteza navedenog istraživanja bile neistinite. Samo istraživanje je donijelo tri značajna rezultata. Prvo smo otkrili da je oženjena žena rjeđe poduzetnica od neoženjene. Otkrili smo da, u multivarijatnom okruženju, ako je žena udana, to ima negativan značaj za nju kao

poslovnu ženu, također istraživanje je pokazalo da udane žene možda ne žele zaraditi za život jer njihov suprug može u obitelji donositi prihode. Drugo, otkrili smo da je vjerojatno da će žena s djetetom biti poduzetnica. U osnovi, ako žena ima dijete, vjerojatnije je da će imati vlastiti posao. Treće i finalno, ako je žena zadovoljna tempom napredovanja posla, vjerojatnije je da će započeti posao. Općenito, ovi rezultati vjerojatno nisu iznenađujući, međutim, jedinstvene statističke analize primijenjene u ovom istraživanju daju mogućnosti za buduća istraživanja i detaljnije analize.

5. Zaključak

Postoji neraskidiva veza poduzetništva i podataka, nemoguće je ostvariti utjecaj u modernom poduzetništvu bez dobre analize tržišta i bez proučavanja podataka na kojima se temelje trendovi i sve potrebno za uspješno poslovanje. Središnji pojam ovog završnog rada je bio GEM i sve vezano uz GEM zajednicu. GEM postoji kao rješenje s kojim se saznaje zašto su neke zemlje poduzetnije od drugih i proučenim istraživanjima i analizom nekoliko radova, lako se može doći do odgovora. Sve od poduzetničke klime, ekonomije, medija, edukacije i ostalih može utjecati na "poduzetnost" zemlje ili regije.

Glavni izvori podataka za moj završni rad su bili razni internetski članci i radovi koji su zapravo prepričavali ono što su nekad provedene ankete dale kao rezultat istraživanja. Poduzetništvo je izrazito širok pojam i internet ima milijune rezultata na dane pojmove, posebice nakon financijske krize koja je zatresla svijet 2008. godine. Nakon nje su mnogi radovi izašli i opisuju poduzetničke teme jer postoji međuodnos poduzetništva i gospodarstva, kao što sam spomenuo u radu, poduzetništvo može utjecati na gospodarski rast i dugoročni gospodarski razvoj, dok gospodarstvo može utjecati na razine poduzetničke aktivnosti.

Završni dio rada sam posvetio analizi dva istraživanja s kojim se jasno vidi kako studenti i žene "dišu" u svijetu poduzetništva. Poduzetništvo pogonjeno podacima odnosno poduzetništvo GEM zajednice je izrazito zanimljiva tema o kojoj bi se moglo razglabati i koja bi se mogla primijeniti na veliki dio tema iz ekonomije, gospodarstva, politike pa i svakodnevnog života a svojim završnim radom sam dao kratki pregled onog najbitnijeg.

Popis literature

[1] https://www.gemconsortium.org/ [pristupano 15.02.2019]

[2] Niels Bosma, Alicia Coduras, Yana Litovsky i Jeff Seama, PDF „*GEM Manual*“, 2012. [pristupano 13.02.2018]

[3] http://www.cerpod-tuzla.org/index.php/bs/ [pristupano 15.02.2019]

[4] https://oxfordre.com/business/view/10.1093/acrefore/9780190224851.001.0001/acrefore-9780190224851-e-156 [pristupano 15.02.2019]

[5] http://www.cepor.hr/ [pristupano 15.02.2019]

[6] Klyver, K. ,“*An analytical framework for micro-level analysis of GEM data*“, 2008. [pristupano 23.05.2019]

[7] Niels Bosma, „*The Global Entrepreneurship Monitor (GEM) and Its Impact on Entrepreneurship Research*“, 2013. [pristupano 23.05.2019]

[8] Zoltan J. Acs, Sameeksha Desai, Leora F. Klapper, *„What does ‘‘entrepreneurship’’ data really show?“*, 2008. [pristupano 23.05.2019]

[9] Paul Reynolds i sur., *„Global Entrepreneurship Monitor:Data Collection Design and Implementation 1998-2003“* , 2005. [pristupano 05.08.2019]

[10] Bergmann H., Mueller S., Schrettle T., *„The Use of Global Entrepreneurship Monitor Data in Academic Research: A Critical Inventory and Future Potentials“,* 2013.

[pristupano 05.08.2019]

[11] Zekić-Sušac M., Pfeifer S., Đurđević I., *„Classification of entrepreneurial intentions by neural networks, decision trees and support vector machines“* , 2010. ,

[pristupano 05.08.2019]

[12] Sharad K. Maheshwari i sur., *„Academy of information and management sciences journal“,* 2011, [pristupano 05.08.2019]

[13] Slike(dijagrami) su izrađene u web aplikaciji https://www.draw.io/

Popis slika

Slika 1: Idejni model GEM-a i aktivnosti prikupljanja podataka 10
Slika 2: Organizacija postupka prikupljanja podataka o GEM Anketi o populaciji odraslih 12
Slika 3: GEM 2003; Anketa o populaciji odraslih: shema struktura intervjua 12
Slika 4: Poduzetnički proces i operativne definicije GEM-a.....13
Slika 5: Dijagram odluke hipoteze 3.....15

Popis tablica

Tablica 1: Idejni model GEM-a i aktivnosti prikupljanja podataka.....11
Tablica 2: Rezultati modela dobivenih NN, CART i SVM-om na testnom uzorku 19
Tablica 3: Statistička usporedba NN, CART i SVM modela 21
Tablica 4: Specifičnost i osjetljivost NN, CART i SVM modela.....22
Tablica 5: Istraživanje hipoteze 3 24