Sustavi preporuke kao alati efikasnijeg donošenja odluka : primjer aplikacija za odabir smjera na Ekonomskom fakultetu u Zagrebu

Nikolić, Borna

Master's thesis / Diplomski rad

2022

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Economics and Business / Sveučilište u Zagrebu, Ekonomski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:148:690803

Rights / Prava: Attribution-NonCommercial-ShareAlike 3.0 Unported/Imenovanje-Nekomercijalno-Dijeli pod istim uvjetima 3.0

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



Repository / Repozitorij:

REPEFZG - Digital Repository - Faculty of Economcs & Business Zagreb







Sveučilište u Zagrebu

Ekonomski fakultet

Integrirani preddiplomski i diplomski studij Poslovna ekonomija

Sustavi preporuke kao alati efikasnijeg donošenja odluka: Primjer aplikacija za odabir smjera na Ekonomskom fakultetu u Zagrebu

Diplomski rad

Borna Nikolić

Zagreb, prosinac 2021.

Sveučilište u Zagrebu

Ekonomski fakultet

Integrirani preddiplomski i diplomski studij Poslovna ekonomija

Sustavi preporuke kao alati efikasnijeg donošenja odluka: Primjer aplikacija za odabir smjera na Ekonomskom fakultetu u Zagrebu

Recommendation engines as tools for efficient decision making: Example application for specialization selection at the Faculty of Economics and Business Zagreb

Diplomski rad

Student: Borna Nikolić
JMBAG: 0067541177
Mentor: prof. dr. sc. Mario Spremić

Zagreb, prosinac 2021.

Sažetak i ključne riječi

Donošenje odluka je jedno od najzanimljivijih područja znanstvenih istraživanja u društvenim znanostima. Bihevioralna ekonomija nam je pokazala da suprotno prethodno uvaženom mišljenju, pojedinci nisu u potpunosti racionalni agenti te padaju pod utjecaj kognitivnih pristranosti koje rezultiraju ne optimalnim odlukama i ishodima. Opisani problemi se ne javljaju samo u tradicionalnim situacijama poput kupovine, već i u svim bitnim životnim odlukama poput onih koje studenti moraju donosit za vrijeme svojeg obrazovanja. Kako je iznimno teško donositi odluke čije nas posljedice prate čitav život, osobe razmatraju čitav niz faktora pri ovakvom odlučivanju. Nadalje pokazalo se da su studenti određenih akademskih grana više skloni gledati eksterne faktore od drugih. To ih stavlja u opasnost da padnu pod utjecaj mentaliteta krda, odnosno da prate odluke većine makar one ne predstavljale najbolje odluke za njih same. Istraživanja su pokazala da se takav efekt može izbjeći ukoliko studenti ne prate većinu, već pojedince koji su najsličniji njima samima. Sa tom niti vodiljom autor je izradio posebnu aplikaciju sa sustavom za preporuku koja se temelji na pronalasku najsličnijih alumnija samom studentu (kroz dimenzije osobnosti, karijernih interesa i preferencija na studiju) te koristi njihova iskustva da bi dao studentu preporuku koji bi mu smjerovi mogli najbolje ležati. Ovaj rad predstavlja teorijsku pozadinu problema odabira smjera unutar konteksta obrazovanja, pokazuje trenutnu situaciju kako studenti Ekonomskog Fakulteta u Zagrebu biraju smjer te opisuje izradu i predstavlja gotovu aplikaciju EFZG smjer – koja ukomponira predloženi sustav za preporuku.

Ključne riječi: donošenje odluka u obrazovanju, predrasude i utjecaj okoline, sustavi za preporuku, web aplikacija za preporuku smjera

Summary and keywords

Decision making is one of the most interesting areas of scientific research in social sciences. Behavioral economics has shown us that, contrary to previously held opinion, individuals are not entirely rational agents and fall under the influence of cognitive biases that result in non-optimal decisions and outcomes. The problems described occur not only in traditional situations such as shopping, but also in all important life decisions such as those that students have to make during their education. As it is extremely difficult to make decisions whose consequences last a lifetime, people consider a number of factors in such decisions. Furthermore, it has been shown that students of certain academic branches are more inclined to look at external factors than others. This puts them in danger of falling under the influence of the herd mentality, that is, of following the decisions of the majority, even if they are not the best decisions for themselves. Research has shown that such an effect can be avoided if students do not follow the majority, but individuals who are most similar to themselves. With this idea in mind, the author developed a special application with a recommendation engine based on finding the most similar alumni to the student (through personality, career interests and study preferences) and using their experiences to recommend to the student which specialties might be best for him. This paper presents the theoretical background of the problem of choosing a field within the context of education, shows the current situation in which students of the Faculty of Economics and Business in Zagreb choose a field, describes the development and presents the finished EFZG smjer web app - which incorporates the proposed recommendation system.

Keywords: decision making in education, prejudices and peer pressure, recommendation engines, web application for college specialty selection

Sadržaj

1 Uvod 1

1.1 Predmet i cilj rada 1

1.2 Izvor podataka i metode prikupljanja 1

1.3 Sadržaj i struktura rada 2

2 Donošenje odluka u situacijama neizvjesnosti 3

2.1 Tradicionalni ekonomski model odlučivanja 3

2.2 Kognitivne pristranosti i heuristike 4

2.2.1 Reprezentivnost 5

2.2.2 Dostupnost 5

2.2.3 Sidrenje i prilagodba 6

2.2.4 Framing efekt i mentalni računi 6

2.3 Choice overload 7

2.4 Sustavi za preporuku 9

2.4.1 Tehnička pozadina sustava za preporuku 10

2.4.2 Sustavi za preporuku u kontekstu obrazovanja 12

2.5 Donošenje odluka o obrazovanju 13

2.5.1 Utjecaj osobnosti na odabir smjera 14

2.5.2 Utjecaj ostalih studenata i mentalitet krda 16

2.5.3 Problematika odabira smjera i potencijalno rješenje 17

3 Analiza trenutnog stanja odabira smjera na Ekonomskom fakultetu 19

3.1 Anketno istraživanje o trenutnim stavovima studenata EFZG-a o upisu smjera 20

3.1.1 Demografski podaci 20

3.1.2 Analiza razlika ocjena po upisanim smjerovima 23

3.1.3 Motivacijski faktori pri izboru smjera te izvori informacija 29

3.1.4 Mišljenje okoline i predrasude 33

3.1.5 Zaključak istraživanja 35

4 Aplikacija za preporuku smjera na Ekonomskom fakultetu 38

4.1 Sustav za preporuku 38

4.1.1 Upitnik za izradu alumni baze 38

4.1.2 Algoritam preporuke 43

4.2 Tehnička pozadina aplikacije i razvoj 47
4.2.1 Razvoj 48
4.2.2 Produkcija 48
4.2.3 Lansiranje i feedback korisnika 50
4.3 Web stranica/aplikacije EFZGsmjer 52
5 Zaključak 64
POPIS LITERATURE 66
POPIS TABLICA 71
POPIS GRAFIKONA 72
POPIS SLIKA 73
ŽIVOTOPIS STUDENTA 74
PRILOZI 75

1 Uvod

1.1 Predmet i cilj rada

Donošenje odluka predstavlja temeljni dio poslovnog i privatnog života svake osobe. Usprkos tradicionalnim ekonomskim idejama racionalnog potrošača, novija istraživanja iz bihevioralne ekonomije su pokazala da su pojedinci skloni raznim kognitivnim pristranostima koje rezultiraju sub optimalnim odlukama i negativnim rezultatima u dužem roku, kako za njih same tako i za okolinu. To se najviše odražava u iznimno neizvjesnim situacijama gdje postoji velika količina podataka koje pojedinac mora uzeti u obzir pri donošenju odluke. Cilj ovog rada je na primjeru odluke o odabiru smjera na Ekonomskom fakultetu u Zagrebu predstaviti sustave za preporuku kao alate za efikasnije donošenje odluka kroz njihov efekt smanjenja negativnih utjecaja kognitivnih pristranosti. U tu svrhu je izrađena u potpunosti funkcionalna web aplikacije „EFZG Smjer“ koja olakšava odabir smjera studentima Ekonomskog Fakulteta u Zagrebu tako da pronalazi alumnije najsličnije njima samima po osobnosti i interesima te pokaže što su isti upisali te njihovo zadovoljstvo upisanim smjerovima.

1.2 Izvor podataka i metode prikupljanja

U izradi rada su korišteni primarni i sekundarni izvori podataka. Za teorijsku podlogu radu su korištene međunarodne znanstvene baze dostupne za pristup studentima Ekonomskog Fakulteta u Zagrebu. Nadalje, kako se u radu provodi i statistička analiza trenutnog procesa odabira smjera, na postojećim studentima je proveden anketni upitnik u svrhu boljeg razumijevanja problematike te potkrjepljenja hipoteza o potrebitosti sustava za preporuku u navedenoj situaciji. Završno, kako se u pozadini izrađene web aplikacije nalazi sustav za preporuku te njegov algoritam se bazira na uparivanju studenata sa najsličnijim alumnijima, prikupljena je baza alumnija. Sudjelovanje je bilo dobrovoljnog karaktera te su podaci o osobnosti, interesima te zadovoljstvu studiranja prikupljeni putem online distribuiranog anketnog upitnika.

1.3 Sadržaj i struktura rada

Rad je strukturiran u 5 glavnih dijelova. U prvom dijelu se daje uvid u problematiku koja se obrađuje u nastavku te se predstavlja sama struktura i metodika izrade rada. Drugi dio predstavlja teorijsku podlogu te analizu dostupnih saznanja iz područja donošenja odluka i sustava za preporuku. Sljedeće poglavlje je analiza trenutnog stanja odabira smjera na Ekonomskom fakultetu u Zagrebu. Ono uključuje statističku analizu prikupljenih podataka među studentima te služi kao uvod u samu aplikaciju „EFZG smjer“. Četvrto poglavlje je fokusirano na aplikaciju, odnosno na tehničke karakteristike, razvoj te primjer korištenja iste. U njemu je detaljno dokumentiran svaki korak nastanka aplikacije te korištenja iste, te istovremeno služi kao priručnik za nastavak razvoja i unaprijeđenije same „EFZG Smjer“ stranice. Završno poglavlje predstavlja zaključak u kojemu se rezimiraju saznanja iz dostupne literature te provedene statističke analize te predstavljaju podaci o uspješnosti izrađene aplikacije.

2 Donošenje odluka u situacijama neizvjesnosti

2.1 Tradicionalni ekonomski model odlučivanja

Donošenje odluka je područje koje privlači raznovrstan skup znanstvenika iz psihologije, neuroznanosti i ekonomije. Razumijevanje procesa odlučivanja pojedinca u raznim okolnostima može rezultirati optimiziranjem situacija kako bi se povećala korist kako za pojedinca tako i za njegovu okolinu. Ipak, predviđanje ponašanja osobe je još uvijek jedno od najzahtjevnijih područja ne samo u znanosti već i u raznim poslovnim granama poput marketinga. Kako bi što efikasnije mogli predvidjeti ponašanje potrošača stručnjaci su formulirali razne teorije i modele koji daju pojednostavljen prikaz na ovu kompleksnu dinamiku te tako omogućuju kontrolirano istraživanje utjecaja raznih varijabli na samu odluku.

Još od 50-tih godina prošlog stoljeća ekonomisti predstavljaju koncept racionalnog agenta (Savage, 1954.). Iz njegovih definicija unutar akademske literature (Mas-Colell et al., 1995.; Varian, 1992.;) mogu se izdvojiti četiri najvažnija obilježja koja ga karakteriziraju:

1. Agent je u kompletnosti informiran o svim mogućim alternativama
2. Agent može rangirati sve dostupne mogućnosti po privlačnosti makar ne može kvantificirati razlike medu rangovima
3. Njegove preferencije su konzistentne
4. Agent optimizira svoju očekivanu korist na temelju tih rangova

Ovaj model je temelj znatnog dijela ekonomskih istraživanja u prošla 2 stoljeća, no predstavlja li on uistinu najefikasniji način promatranja odluka o potrošnji?

Kapeller, Schütz i Steinerberger (2012.) su u svojem istraživanju pokazali da se sve četiri pretpostavke ne mogu pouzdano koristiti kod multidimenzionalnih dobara, dobara koja se promatraju kroz više od jedne dimenzije korisnosti. Kada uzmemo u obzir da većina dobara, bilo materijalnih ili nematerijalnih, danas posjeduje tu karakteristiku dolazi se do jednostavnog zaključka da ovakav model ne može služiti u praktičnoj primjeni predviđanja ponašanja pojedinca.

2.2 Kognitivne pristranosti i heuristike

Alternativa klasičnoj ekonomskoj teoriji racionalnog potrošača dolazi u području popularno nazvanom Bihevioralna Ekonomija. Kahneman i Tverski (1974.) promatraju ponašanje pojedinca u situacijama neizvjesnosti i prisutnosti rizika. Njihova istraživanja ukazuju u cijeli nesvjesni proces koji se odvija pri donošenju odluka koji se do tog trenutka nije razmatrao u ekonomskim krugovima. Oni dijele mentalne procese osobe na dva sistema - Sistem 1 čiji je cilj brza i efikasna procjena situacija te djeluje u kombinaciji sa Sistemom 2 koji je sporiji i svjesni dio te se može smatrati racionalnim dijelom našeg mozga (Kahneman, 2011.). Oba sistema imaju svoju svrhu te djeluju u sinergiji kako bi pojedinac efikasno obavljao svakodnevne zadatke. Sistem 2 je tako zadužen sa sve zadatke koji zahtijevaju zaključivanje ili kompleksne kalkulacije dok Sistem 1 obraduje automatske zadatke te procesuira informacije iz okoline koje onda šalje dalje kao inpute za Sistem 2. Usprkos kritikama koje ističu problematiku takve eksplicitne podjele mentalnih procesa na dualne odluke (Grayout, 2019.) ovakav pristup se i dalje smatra standardom za promatranje „iracionalnog“ potrošača.

Postojanje Sistema 1 dovodi do kognitivnih pristranosti, greški u procesuiranju informacija, koje utječu na zaključke i ponašanje osobe. One su rezultat korištenja heuristika, mentalnih prečaca koje naš mozak koristi kako bi olakšao obradu informacija iz okoline (Kahneman, 2011.).

2.2.1 Reprezentativnost

Reprezentativnost je heuristika koja olakšava pojedincima procjenu vjerojatnosti da neki događaj A proizlazi iz događaja B, da događaj B generira događaj A ili da A pripada klasi B. Ovakva pitanja su često iznimno bitna pri donošenju odluka uslijed ograničenih informacija o samim alternativama. Da bismo razumjeli kako ova heuristika djeluje pogledajmo sljedeći primjer:

Razmotrite pojedinca kojega opisuje izjava „Steve je povučen i stidljiv dečko koji želi pomoći, ali nije pretjerano zainteresiran za vanjski svijet. On je skromna i uredna persona iznimno orijentirana na detalje i strukture.“

- Procijenite što je vjerojatnije, da Steve radi kao knjižničar ili farmer?

Ispitanici koji su sudjelovali u originalnom istraživanju su dali pretežno veću vjerojatnost da je Steve knjižničar. To se naravno krši sa zakonima statistike jer je udio farmera unutar populacije znatno veći od knjižničara te je zbog toga veća vjerojatnost da je Steve također farmer. Ovo je rezultat heuristike reprezentativnosti. Kako pojedincima nije poznata činjenica o vjerojatnostima zanimanja Stevea, oni gledaju koliko je dani opis reprezentativan njima dostupnim stereotipovima o knjižničarima i farmerima.

2.2.2 Dostupnost

Dostupnost je druga heuristika koja se također koristi u sličnim situacijama kao i Reprezentativnost. Kad pojedinac procjenjuje vjerojatnost o nastupanju nekog događaja, daje veću vjerojatnost događajima koji su mu brze dostupni iz sjecanja. Uzmimo primjer požara. Osoba koja je vidjela kuću u požaru vlastitim ocima će dati veću vjerojatnost da postoji opasnost da njihova kuca bude uhvaćena u požaru od osobe koja je samo pročitala o tom požaru.

To se događa jer je vizualni stimulans snažniji te je pojedincu dostupnije sjećanje na incidenciju požara te to dovodi do toga da mu je percipirana vjerojatnost veća.

2.2.3 Sidrenje i prilagodba

Zadnja bitna heuristika koju ističu Kahneman i Tversky je Sidrenje i prilagodba od samog sidra. Sidrenje je mehanizam gdje pri procjeni neke vrijednosti svoju procjenu temeljimo na odredenoj referentnoj točki koja ne mora nužno kvalitetno opisivati problem. Uzmimo za primjer ovu situaciju:

Kupac želi kupiti novi auto te mu je budžet 15000 USD. Prodavač mu prvo pokaze auto od 40 000 USD makar si ga on ne može priuštiti. Nakon što je vidio prvi auto, prodavač pokazuje kupcu automobile od 20 do 25 tisuća dolara. Nakon prvog auta, ovi modeli se ne cine preskupi te je kupac vjerojatniji da će potrošiti više od svog planiranog budžeta.

U ovoj situaciji možemo vidjeti primjer Sidra i prilagode. Inicijalni auto od 40000 USD sluzi kao sidro, odnosno referentna točka prema kojoj se uspoređuju sve sljedeće vrijednosti. Povećanje budžeta je prilagodba od Sidra odnosno pomicanje procjene na temelju referentne točke koja je zadana od prije makar nije relevantna za samu transakciju u tom trenutku.

2.2.4 Framing efekt i mentalni računi

Kahneman i Tversky (1979.) su u nastavnim istraživanjima također dokazali da pojedinci sistematski ruse pretpostavke racionalnog potrošača odnosno teorije očekivane koristi. Jedna od važnih pretpostavki koje su srušene je ta da potrošači imaju konzistentne preferencije kroz vrijeme te da mogu rangirati sve dostupne alternative po korisnosti. Narednih godina su kroz niz eksperimenata pokazali da odluka pojedinca ovisi o načinu na koji se oblikuje samo pitanje (Kahneman D. i Tversky A., 1981.).

Ovisno o tome je li formulacija u pozitivnom ili negativnom tonu, preferencije pojedinca su se pokazale kontradiktorne. Pogledajmo sljedeći primjer:

Problem 1: Odlazite u kino, ispred samog ulaza primijetite da ste izgubili 10$. Hoćete li svejedno otići u kino?

Problem 2: Odlazite u kino, ispred samog ulaza primijetite da ste izgubili kartu koju ste platili 10$. Hoćete li kupiti novu kartu i svejedno otići u kino?

U ovom eksperimentu (Kahneman D. i Tversky A. ,1981.) se gledalo kako pojedinci donose odluke uslijed jednakih uvjeta, ali različitih psiholoških stanja. U prvom problemu ispitanici su se u velikoj većini (88%) odlučili potrošiti drugih 10$ te otići u kino dok su u drugom problemu bili podvojeni (54% ih je odlučilo ne otići u kino). U oba slučaja se racionalno gledajući dogodila ista stvar. Osoba je izgubila 10$ te treba odlučiti hoće li potrošiti novih 10$. Prema racionalnom modelu potrošača bitno je samo procijenjena korisnost koju osoba vidi u odlasku u kino te oblik u kojem je nastao inicijalni trošak je u potpunosti nebitna. Ipak iz prikazanog je lako uvidjeti da takvo razmišljanje je daleko od realnosti. Tversky i Kahneman argumentiraju da je ovo rezultat mentalnih „računa“ gdje je pojedinac klasificirao nastali trošak. U prvom primjeru trošak je došao iz nekategoriziranog računa, dok je u drugom primjeru 10$ došlo iz računa „zabava/kino“ te pojedinac ne želi trošiti dodatno budžet iz te kategorije. Ovakve mentalne računice su osnovica efikasnog predviđanja ponašanja potrošača, jer nam daju strukturu u sami proces odlučivanja te se mogu u odredbenoj mjeri uračunati pri dizajniranju situacije koja bi trebala rezultirati u željenom ishodu.

2.3 Choice overload

Povezana istraživanja psihologa su gledala povezanost odluka i broja dostupnih alternativa u trenutku odlučivanja. Njihovi rezultati su nam otkrili da suočeni s brojnim opcijama, potrošači prekomjerno pojednostavljuju izbor.

Taj mehanizam je rezultat potrebe za smanjenjem kognitivnog napora kojeg bi morali uložiti za racionalno promišljanje o svakom mogućem ishodu. Iz provedenih eksperimenata zaključili su da takav proces rezultira manjim zadovoljstvom odabranim izborom pojedinca ili da čak potiče izbjegavanje donošenja odluke u potpunosti (Chernev i sur., 2015.; Iyengar i Lepper, 2000.).

Taj učinak potrošačevog suboptimalnog donošenja odluka uslijed preopterećenosti dostupnim alternativama nazivaju „Choice overload".

Prve sveobuhvatne analiza dostupnih istraživanja su ukazale na nekonzistentnost u mjerenju negativnog utjecaja prekomjernog izbora kod potrošačkog izbora (Scheibehenne B., Greifeneder R. i Todd, P. M., 2010.). Njihovi rezultati su isticali lošu opisanost efekata te činjenicu da su se tada dostupna istraživanja međusobno pobijala. Kao odgovor na te nalaze Chernev i suradnici (2015.) su proveli vlastitu analizu dostupnih studija. Svrha njihove meta analize je bila sistematizirati saznanja o efektu „choice overloada". U tu svrhu su predstavili okvir koji ističe četiri moderatorska čimbenika:

- Složenosti dostupnih opcija
- Težina samog procesa odluke
- Nejasne preferencije
- Ciljevi odluke

Prvi argument je da je negativan utjecaj prevelikog izbora prije svega prisutan u situacijama gdje je visoka složenost samih opcija koje se razmatraju. Daljnja istraživanja pokazuju da je kupnja potrošača mnogo izglednija u situacijama gdje postoji dominantna opcija (Oppewal i Koelemeijer , 2005.), dok u izborima sa pretežito sličnim alternativama češće dolazi do prekida kupovne namjere (Dhar i Simonson, 2003.).

Drugi faktor koji ističu je ukupna privlačnost. Kada se u izboru nalazi veliki broj atraktivnih mogućnosti, potrošači preferiraju manji broj probranih opcija iz većeg asortimana (Chernev i Hamilton, 2009.). Ovo povlaci zanimljivu poveznicu sa poslovnim poduhvatima koji temelje svoju konkurentsku prednost na sustavima preporuke čija funkcionalnosti se upravo preklapa sa ovim istraživanjem. Na taj način direktno profitiraju zbog učinka efekta „Choice overload".

Nadalje mora se promatrati kolika je težina samog zadataka donošenja odluke. Primjerice, zadaci sa vremenskim ograničenjem povećavaju osjećaj žaljenja koje pojedinac osjeća zbog svog izbora (Inbar i sur., 2011.). Ovi rezultati pokazuju mogućnost da izbori sa velikim izborom te nedovoljno vremena za kvalitetno procesuiranje dostupnih informacija mogu negativno utjecati na mentalno zdravlje pojedinca.

Ipak, neki moderirajući faktori imaju i pozitivan utjecaj na samog potrošača. Osobe koje imaju izraženu preferenciju za neku opciju prije odluke (Chernev , 2003.) ili žele imati raznolikost mogućnosti (Oppewal i Koelemeijer, 2005.) manje su vjerojatni da će imati negativne efekte „choice overloada“. Kod ovakvih vrsti potrošača velika je vjerojatnost da će oni doživjeti zadovoljstvo ne samo rezultatom svojih izbora, već i cjelokupnim procesom donošenja odluka.

2.4 Sustavi za preporuku

Većina dostupnih istraživanja temelj ima u potrošačkim situacijama poput tradicionalne kupovine u supermarketu. Kako suvremeni svijet donosi u potpunosti drugačije životne stilove i dostupnu tehnologiju, mora se dodatno razmotriti konzistentnost tih saznanja u modernom kontekstu.

Nagar i Gandotra (2016.) su krenuli upravo sa tom pretpostavkom te su kroz svoj rad pokazali da je „choice overload“ jedan od signifikantnih faktora koji utječu na smanjenje kupovne namjere u online modnim trgovinama. Isto istraživanje ističe da je tražena raznolikost, sukladno sa prethodnim znanstvenim saznanjima, bitna odrednica o zadovoljstvu i navikama kupnje u online okruženju. Kupci skloni raznolikosti imaju manju vjerojatnost manifestiranja anksioznosti povezane uz internet kupovinu te su otporniji na negativne utjecaje prekomjernog izbora. Ipak, kako je ovaj primjer povezan za specifičnu industriju gdje dolazi do velikih promjena asortimana relativno često, potrebno je dodatno sagledati i ostale grane trgovine.

Nedavna zanimljiva studija je pokazala da veća lepeza izbora pri online rezervaciji hotela rezultira također i većim brojem uspješnih rezervacija (Aparicio i Prelec , 2018.). To je u suprotnosti s nalazima dotadašnjih eksperimenata. Aparicio i Prelec ističu da su se opcije

filtriranja i personalizacije pokazale iznimno poželjne za informirane potrošače koji već posjeduju znanja i preferencije o proizvodima iz asortimana. One sprječavaju nastanak nepoželjnog mentalnog napora usred velikog broja izbora te olakšavaju pronalazak nišnih ponuda koje su povezane sa iznimno visokim zadovoljstvom kod kupca.

Nadalje istraživanje je pokazalo da to vrijedi i za manje informirane potrošače u slučajevima gdje koriste sustave za preporuke (Aparicio i Prelec , 2018.). To omogućuje pojedincima sa manje izraženim preferencijama ili nedovoljno informacija o proizvodima da ostvare koristi većeg izbora i širih asortimana.

Preporuke iz sustava smanjuju broj opcija koje je potrebno sagledati te daju osjećaj sigurnosti zbog personalizacije postupka filtriranja upravo prema željama i potrebama samog pojedinca.

Cak i starija istraživanja ukazuju na takve utjecaje te ističu potrebu online trgovaca za strategijom pružanja personaliziranih preporuka. Razlog je taj da takvi sustavi povećavaju zadovoljstvo potrošača donesenom odlukom cak i u okolnostima gdje je visoka opterećenost informacijama (Aljukhadar et al., 2012.).

2.4.1 Tehnička pozadina sustava za preporuku

Sustavi za preporuku se definiraju kao alati za pretraživanje informacija koji služe za rješavanje problema preopterećenosti informacijama i pomažu ljudima da donosu odluke ili ostanu informirani o određenoj temi (Wakil et al., 2015.). Oni daju preporuke na temelju dostupnih podataka, određenih preferencija te prethodne povijesti korištenja korisnika. Danas se koriste u raznim domenama kao što su bankarstvo, trgovina, ali i zapošljavanje (Al-Badarenah i Alsakran, 2016.).

Sustavi za preporuku se klasificiraju po metodici na koji dolaze do preporuke. Bazni modeli koriste dva seta podataka:

1. Korisnik-stvar interakcija – npr. ocjene ili korisničko ponašanje

2. Korisnik-stvar atributi – npr. ključne riječi

Nadalje tehnike unutar sustava za preporuku se također dijele u dvije najvažnije kategorije: Bazirane na memoriji i one Bazirane na modelu.

Algoritmi bazirani na memoriji tj. podacima rade na cjelokupnom spoju korisnik-stvar rang matrica dok kontrastno tehnike bazirane na modelu koriste podatke za treniranje modela koji se na posljetku koristi za davanje preporuka.

U skladu sa tim klasifikacijama, 4 najvažnije vrste sustava za preporuku su:

1. Kolaborativno filtriranje
2. Bazirani na sadržaju
3. Bazirani na znanju
4. Hibridni sustavi

2.4.1.1 Kolaborativno filtriranje

Metoda bazirane na kolaborativnom filtriranju je među najkorištenijima u sustavima za preporuku. Ona radi tako da preporuku ciljnom korisniku daje tako da odredi druge korisnike najsličnije njemu te koristi njihove asortimane za preporuku. Česta primjena ovakvih sustava se može vidjeti u online forumima te bazama sa filmovima ili glazbom.

2.4.1.2 Metode bazirane na sadržaju

Sustavi bazirani na sadržaju se temelje na povijesnim podacima samog korisnika. Na primjer, prije same preporuke ovaj algoritam bi prvenstveno pogledao kakve je proizvode prije korisnik pretraživao i koristio te na temelju toga daje preporuku za povezane opcije. Ovaj algoritam naročito koristi ocjene samog korisnika pri davanju preporuka. Ovakvi sustavi imaju veliku

vjerojatnost da će biti primijenjeni u trgovini, informativnim granama i obrazovanju (Li et al, 2012.).

2.4.1.3 Metode baziranje na znanju

Sustavi bazirani na znanju se primarno koriste kad je domena u kojoj se donosi odluka iznimno kompleksna u kontekstu atributa dostupnih opcija. Ovakvi sustavi će usporediti preferencije i potrebe kupca sa dostupnim svojstvima proizvoda u asortimanu za filtriranje i davanje preporuka onih koji maksimiziraju zadovoljstvo kupca. Ovakvi sustavi su se pokazali posebno uspješnima u poslovnim situacijama gdje ne postoji visok broj transakcija proizvoda jer su iznimno skupi, te je posljedično teško temeljiti preporuku na ocjenama korisnika zbog manjka istih.

2.4.1.4 Hibridni sustavi

Hibridni sustavi sa preporuku koriste metode temeljene na spoju snaga prethodno navedenih sustava. Cilj je kombinirati više metoda za izradu posebnih tehnika koje su efikasnije i robusnije u specifičnim situacijama.

2.4.2 Sustavi za preporuku u kontekstu obrazovanja

U visokom obrazovanju postoji veliki broj mogućnosti za primjenu sustava za preporuku. Epidemija COVID-19 virusa je istaknula potrebu za kvalitetnim e-learning sadržajem. Sustavi za preporuku se mogu koristiti za generiranje efikasnijeg i personaliziranog kurikuluma sadržaja dostupnog u online platformama (George i Lal, 2019.)

Nadalje postoji mogućnost primjene u knjižničnim centrima kako bi se olakšalo studentima i nastavnom osoblju fakulteta pronalazak relevantnih knjiga (Jomsri, 2018.) ili znanstvenih istraživanja i konferencija (Wang et al, 2018.).

Lynn i Emanuel (2021.) su napravili analizu dostupnih istraživanja korištenja sustava za preporuku pri odabiru predmeta u visokom obrazovanju. Kroz njihovo istraživanje se pokazao signifikantan pozitivan utjecaj za studente te ističu upravo hibridne sustave za preporuku kao izvrstan odabir za rješenja u obrazovnom sektoru.

2.5 Donošenje odluka o obrazovanju

Kao što znamo, kognitivne pristranosti se pojavljuju u svim elementima ljudskog života, a ne samo u situacijama kupnje. One su sastavni element bilo kojeg donošenja odluka. Tako možemo promatrati i jednu od najvažnijih velikih odluka koje pojedinac donosi – odluka o smjeru obrazovanja (Galotti, 2007.).

Ta odluka je temelj bilo koje karijerne putanje te može uvelike utjecati na dohodak, zadovoljstvo te socijalni status pojedinca. No to postavlja pitanje, koji su to faktori najznačajniji pri odabiru smjera obrazovanja?

Aryani i Umar (2020.) u svom istraživanju nad Gen Z studentima koriste klasifikaciju na interne i eksterne motivirajuće faktore (Lent et al 2000.) Individualne dimenzije su uzete na temelju karijernog upitnika Kazi i Akhlaq (2017.).

Istaknuti faktori su:

Interni:

- Utjecaj obitelji
- Interesi
- Akademski razlozi
- Spol
- Kultura

Eksterni:

- Vršnjaci
- Prestiž obrazovne institucije
- Financijski razlozi
- Mogućnost zaposlenja

Oni su promatrali individualno i skupno ove faktore kroz tri skupine studenata – Prirodne znanosti, Društvene znanosti i Umjetničke studije. Promatrajući individualno faktore Utjecaj obitelji, Akademska pozadina te Kultura su pokazale signifikantne utjecaje na sve studente dok se iz eksternih zajednički motivator pokazao Prestiž obrazovne institucije. Ipak gledajući rezultate iz perspektive skupina dolazi do bitnih razlika gdje određeni faktori poput Zapošljivosti pokazuju utjecaj za studente Društvenih znanosti dok je nebitan za studente Umjetničkih grana.

Grupni rezultati su pokazali signifikantan utjecaj i internih i eksternih faktora na sve vrste studenata uz malo zračniji utjecaj internih faktora naročito obitelji i akademske pozadine pojedinca. Ipak važno je istaknuti zanimljivu razliku gdje su interni faktori bili signifikantno manje bitni kod studenata društvenih studija naprema studentima Prirodnih i Umjetničkih grana, dok je suprotno vrijedilo za eksterne faktore.

Iz tih saznanja dolazimo do zaključka da će se u situacijama odluke o obrazovanju, studenti društvenih grana oslanjati više na svoju okolinu, bilo u obliku eksplicitnih koristi poput financijskog prosperiteta ili implicitnih kao što je prestiž fakulteta/smjera.

2.5.1 Utjecaj osobnosti na odabir smjera

Iznimno bitan interan faktor koje prethodno istraživanje zanemaruje je osobnost. Big Five model je jedan od najispitanijih psiholoških metodologija za kvantifikaciju osobnosti pojedinca. (Caprara et al, 2006.)

On dijeli osobnost na 5 glavnih dimenzija:

1. Ekstraverzija
2. Savjesnost
3. Otvorenost
4. Ugodnost
5. Neuroticizam

Studenti koji odabiru smjer obrazovanja sukladan njihovoj osobnosti su vjerojatniji da će ostvariti visok uspjeh u životu prema Hollandovoj teoriji zanimanja (1985., 1996., 1997.). No kako utječe svaka od ovih dimenzija na upis u smjerove?

Iako postoji poveznica sa svakom od važnijih akademskih grana, uzmimo za primjer studente Poslovne ekonomije i Prava. Oni su se pokazali Ekstrovertniji i Savjesniji od studenata humanističkih studija te savjesniji od ostalih studenata društvenih znanosti. (De Fruyt i Mervielde, 1996.)

To je u sukladnosti sa karakteristika koje se povezuju sa najčešćim zanimanjima što studenti na posljetku studija obavljaju –pravnik, poduzetnik, marketing menadžer, voditelj projekta itd. Ta zanimanja zahtijevaju visoku razinu komunikacije sa ljudima te autonomnosti i odgovornosti zbog čega je logično da pojedinci sa tim obilježjima gravitiraju prema studijima koji ih pripremaju za te poslove. Kako postoji vjerojatnost da okruženje formira osobnost pojedinca, kroz društveni utjecaj imitiranja ostalih ljudi koji pripadaju skupini, potrebno je razmotriti postoji li uistinu konzistentnost rezultata kad se kontrolira za tu pojavu.

Balsamo, Lauriola i Saggino (2012) sa tim ciljem provode istraživanje nad srednjoškolcima koji su pred upisom fakulteta. Oni pokazuju da Ekstraverzija i Savjesnost imaju statistički signifikantan utjecaj čak kad se gledaju potencijalni studenti. Odnosno, srednjoškolci koji su visoko na skali Ekstraverzije su pokazali više interesa za upisom ekonomije, društvenih znanosti, prava i umjetničkih smjerova, dok su pokazali manje interesa za prirodne znanosti i humanističke znanosti. Savjesnost pokazuje suprotne tendencije, odnosno potencijalni studenti prirodnih znanosti su se pokazali visoko savjesni, no humanistički nastrojeni srednjoškolci nisu pokazali istu razinu savjesnosti kao njihovi kolege koji su upisali studij.

Kako postoji znanstveni koncensus, utjecaj osobnosti je sigurno jedan od važnijih motivatora za upisom određenih studija. Nadalje se pokazalo da Big Five model može služiti kao adekvatan alat za promatranje osobnosti u kontekstu donošenja odluka, te da može konzistentno prepoznati koje dimenzije utječu najviše na određene odluke.

2.5.2 Utjecaj ostalih studenata i mentalitet krda

Kao što smo vidjeli, jedan od važnih faktora pri odabiru fakulteta ili predmeta u studiju će uvijek biti okolina, odnosno što većina ostalih studenata bira. No zašto ljudi kopiraju ponašanje drugih?

Izdvajaju se 2 najveća motivatora. Prvi je društveno učenje, odnosno činjenica da pojedinci izvlače informacije o vlastitim odlukama na temelju odluka ostalih (Moretti, 2008.). Drugi su mrežne eksternalije – pojedinci mogu ostvariti korist od same činjenice da rade ono što rade ostali. Uzmimo sljedeće primjere (Moretti, 2008.):

Pojedinac može zaključiti kvalitetu filma po tome koliko ljudi čeka da ga pogleda u kinu. U drugu ruku ponekad je veći užitak gledati los film sa prijateljima i ismijavati scene nego gledati dobar film usamljen.

Prvi primjer pokazuje društveno učenje gdje informacije o odluci koji film gledati može derivirati iz toga da neki film gleda puno ljudi što najčešće govori da posjeduje određenu kvalitetu. U drugom primjeru su pokazane eksternalije pripadanja mreži, odnosno iako se gleda los film koji sam po sebi treba donijeti manje koristi, zbog činjenice da se gleda u društvu drugih ta pripadnost nosi svoju korisnost koja je veća nego sama korisnost gledanja boljeg filma.

Isler i suradnici (2021.) provode istraživanje na uzorku 23000 studenata između 1996. i 2015. upravo sa ciljem otkrivanja poveznice ovih dvaju faktora i odluka o diplomskom studiju.

Oni saznaju da studenti cesto kopiraju njihove starije kolege u odabiru smjerova. Većina smjerova ima veću vjerojatnost za upisom ukoliko ih je velik broj prijašnjih generacija upisao. Ovo je jedinstveno saznanje naprema ostalim istraživanjima u odabir diplomskog studija, koja uglavnom gledaju poveznicu utjecaja ostalih studenata samo u kontekstu vršnjaka. Spomenuto istraživanje odstupa od toga jer gleda sekvencijalnu prirodu upisa studija koja vodi do efekta mentaliteta krda – svatko radi što svi ostali rade (Banerjee, 1992.). Dodatno pojedinci koji su se priklonili preporuci starijih studenata sličnih njima, su pokazali optimalnije odluke

najvjerojatnije kroz efekt društvenog učenja sa smanjenom distorzijom informacije jer je ukupni uzorak studenata probran u one studente sa najrelevantnijim iskustvom za njih same.

Nadalje, otkrivaju da signali o ocjenama, težina kolegija i zanimljivost destimuliraju pripadnost krdu. Studenti koji koriste starije kolege da se informiraju o smjerovima diplomskog studija, manje su skloni praćenju ostalih jer dobivaju iskustvo iz prve ruke. To nas vodi zaključku da je društveno učenje jedan od važnijih motivatora zašto ljudi prate mase, pogotovo kad im nedostaje određena razina osobne informiranosti.

Zaključno, gledali su posljedične efekte na ocjene koje su studenti ostvarili. Pokazalo se da pojedinci koji su se priklonili krdu nisu imali nikakav pozitivan utjecaj na svoje ocjene, odnosno da nisu bili uspješniji od studenata koji nisu birali „popularne“ smjerove.

2.5.3 Problematika odabira smjera i potencijalno rješenje

Znamo da svako donošenje odluke sa sobom nosi heuristike uslijed potrebe za sistematizacijom dostupnih informacija te da one vode do kognitivnih pristranosti i grešk u donošenju odluka. Nadalje postoji poveznica između količine odabira i negativnih efekata na samo biranje i zadovoljstvo odlukom. Takav utjecaj „choice overloada“ je prisutniji kada osoba ne posjeduje zadovoljavajuću razinu informiranosti o situaciji u kojoj donosi odluku. Primjer koji se može povezati sa tom problematikom je svakako odabir diplomskog studija za studente. Broj ljudi koji studira je kontinuirano u porastu te se zbog te potražnje velikom brzinom otvaraju novi studiji i nišne specijalizacije koje prije nisu postojale. To sve vodi do toga da studenti pri odabiru studija ne samo da imaju utjecaje stresa koji je povezan sa tako važnom odlukom već i negativan efekt „choice overloada“ i kognitivnih pristranosti.

Kako studenti biraju fakultet na temelju internih i eksternih faktora, te studenti društvenih fakulteta su skloniji biti motivirani eksternim faktorom, vjerojatniji su da padnu pod utjecaj mentaliteta krda. Studenti stoga imaju višestruko negativne posljedice ukoliko ne mogu

osigurati dovoljnu razinu informiranosti kako bi spojili interne motivatore sa kvalitetnim eksternim te tako donijeli optimalnu odluku za sebe.

Kao što smo vidjeli sustavi za preporuku imaju snažan efekt u smanjenu negativnog utjecaja preopterećenosti informacijama. Iako su najčešće primijenjeni u elektronskoj trgovini ili zabavnoj industriji, već postoje primjeri u kojima se koriste u obrazovanju za odabir smjera ili predmeta na studiju sa pozitivnim krajnjim ishodom.

Kako bi studentima mogli omogućiti optimalne uvjete za donošenje odluke treba razmotriti kakav sustav za preporuku koristiti. Iako je najčešći slučaj primjena sustava koji se temelje na interesima ili prethodno odabranim predmetima, takvi sustavi imaju limitirani potencijal naprema hibridnim sustavima koji djeluju u više sfera istovremeno. Iz istraživanja (Isler et al, 2021.) vidimo da najvažniji eksterni utjecaj na odluku od strane ostalih studenata imaju prijašnje generacije kroz mehanizam društvenog učenja. Oni kroz svoje direktno iskustvo mogu dignuti razinu informiranosti te tako potaknuti donošenje boljih odluka uslijed manjeg negativnog utjecaja eksternalija te boljeg prepoznavanja vlastitih potreba.

Autor na temelju tih saznanja predlaže novi oblik sustava za preporuku smjera na diplomskom studiju koji bi se temeljio na dva mehanizma preporuke. Prvi mehanizam bi bili interni motivatori sa najistaknutijim utjecajem odnosno interesi te osobnost. Sustav bi na temelju psihološkog upitnika odredio osobnost te karijerne interese studenta. Drugi mehanizam bi bila iskustva prijašnjih studenata – naročito alumnija kao bivših studenata koji su mogli direktno vidjeti utjecaj svojih odabira o smjeru na njihovu karijeru. Kako bi se dodatno istakao pozitivan utjecaj prenošenja iskustva sa alumnija na trenutne studente, bili bi izabrani samo oni koji najsličniji samim studentima. To bi se osiguralo tako da bi alumniji ispunili isti upitnik kao i sami studenti te bi se mogli usporediti po dimenzijama interesa te osobnosti, dok bi iskustva alumnija služila za formiranje preporuka te obrazloženje istih kroz više varijabli kao što su iskustvo sa smjerom, osobno zadovoljstvo sa odabirom te karijerni put.

U svrhu provjere efikasnosti predloženog rješenja uzet je primjer institucije na kojoj je pisan ovaj rad – Ekonomski Fakultet Sveučilišta u Zagrebu. Ekonomski fakultet u Zagrebu ima 9 smjerova na diplomskom dijelu svog integriranog preddiplomskog i diplomskog studija. To nam daje savršen „use case“ za izradu sustava za preporuku.

Sljedeće poglavlje će promatrati trenutni proces donošenja odluka na fakultetu te postoji li negativan utjecaj mišljenja okoline pri samom odabiru smjera. Nastavno poglavlje će prikazati izrađenu aplikaciju koja ukomponira predloženi sustav za preporuku.

3 Analiza trenutnog stanja odabira smjera na Ekonomskom fakultetu

Studenti ekonomskog Fakulteta u Zagreba od 2015. godine upisuju integrirani preddiplomski i diplomski studij. Za razliku od prethodnog oblika studija, studenti ne upisuju jednu godinu diplomskog studija već imaju tri godine općenitog obrazovanja iz područja Ekonomije i Poslovne ekonomije, te specijalizaciju, odnosno smjer, zadnje dvije godine njihovog obrazovanja. Trenutni smjerovi koji se nude su:

1. Analiza i poslovno planiranje
2. Ekonomija
3. Financije
4. Marketing
5. Menadžerska informatika
6. Menadžment
7. Računovodstvo i revizija
8. Trgovina i međunarodno poslovanje
9. Turizam

Smjerovi se biraju pred upis 4. godine studija kroz online aplikaciju. Kriterij za rangiranje studentskih prijava je ostvareni prosjek kroz dotadašnje studiranje. Svaki student se izjasni kojih 5 smjerova smatra najprivlačnijima te se po tom rangu upisuje na prvi dostupni smjer za koji je ostvario dovoljan uspjeh naprema ostalim prijavljenim studentima.

Između smjerova postoje signifikantne razlike u interesu studenata. Određeni smjerovi su popunjeni do maksimalnog kapaciteta te je potreban iznimno visok prosjek za upasti na njih dok drugi smjerovi ne popune ni polovično svoj kapacitet te završe kao alternativne opcije za studente koji ne upišu željeni smjer.

3.1 Anketno istraživanje o trenutnim stavovima studenata EFZG-a o upisu smjera

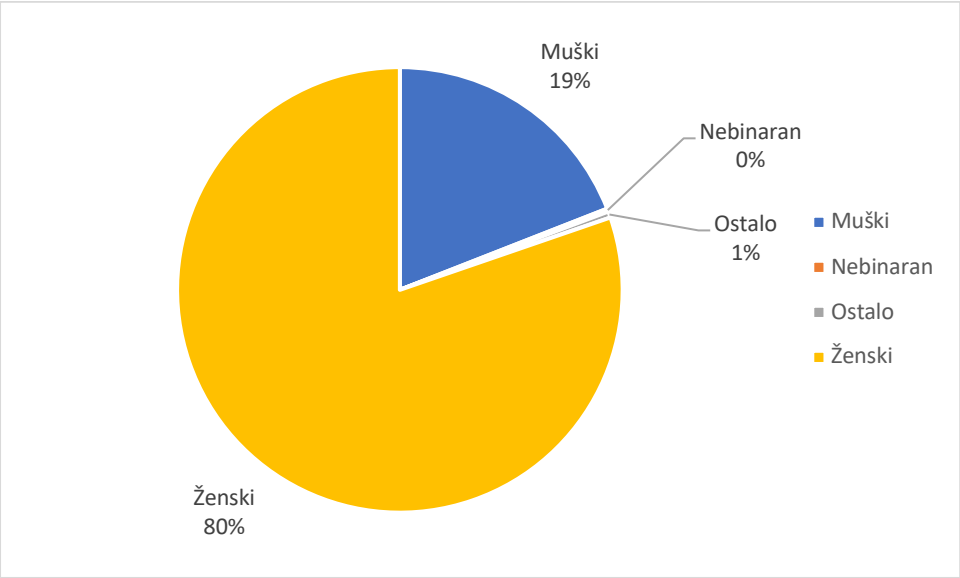
3.1.1 Demografski podaci

Kako bi stekli bolji uvid u mišljenja i faktore odluke studenata provedeno je istraživanje u obliku anketnog upitnika medu studentskom populacijom Ekonomskog Fakulteta u Zagrebu.

Upitnik je kreiran pomoću online servisa Google Forms te je distribuiran kroz društvene mreže, sa posebnim fokusom na grupama koje okupljaju studente EFZG-a.

U istraživanju je sudjelovalo 446 ispitanika, od kojih je 358 bilo ženskog roda, 85 muškaraca, 1 osoba ne binarnog roda te 2 ispitanika koja se nisu izjasnila.

Grafikon 1 Distribucija ispitanika po spolu

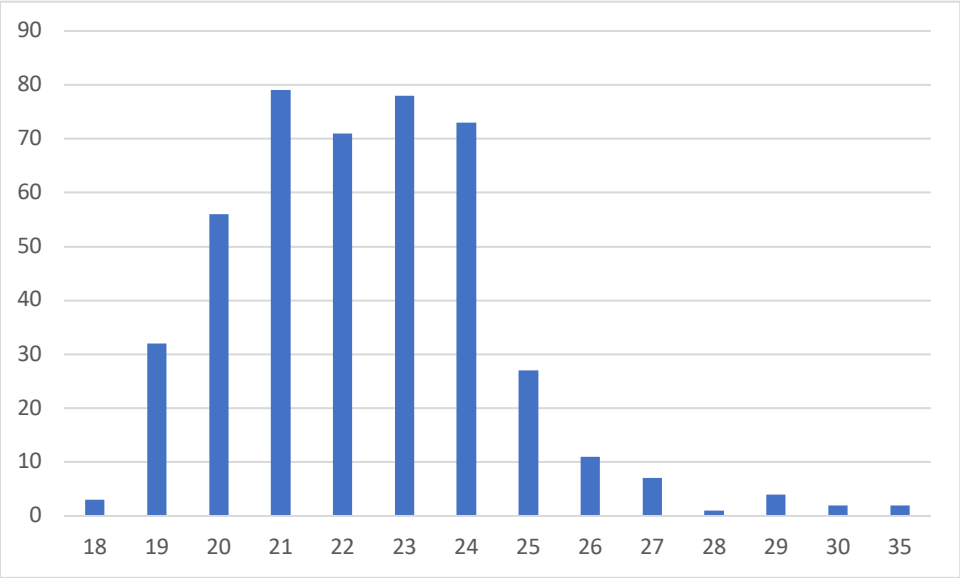


Izvor: Izrada autora

Iako postoji snažan disbalans u uzorku, on se preklapa sa trendom upisa u prethodnim godinama gdje je većinski broj novoupisanih studenata bio ženskog roda te upravo iz tog razloga uz relativno velik broj ispitanika, možemo smatrati uzorak adekvatan za procjenjivanje mišljenja sveukupne studentske populacije na Ekonomskom fakultetu.

Dob ispitanika je varirala od 18 godina, sve do 35 godina. Ipak većina ispitanika se nalazila u dobi između 19 i 25 što se preklapa sa dobi u kojima se nalaze studenti uz redovan tijek studiranja od 5 ili 6 godina.

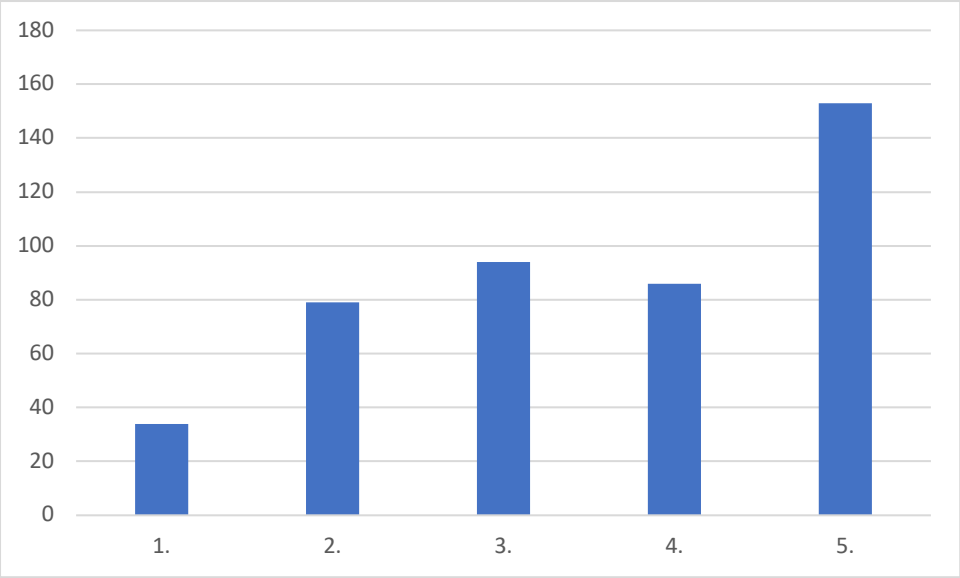
Grafikon 2 Distribucija ispitanika po dobi



Izvor: Izrada autora

Lako se može vidjeti da su prevladavali stariji ispitanici pa tako i gledano po upisanim godinama većina ispitanika je sa završne dvije godine studija uz dovoljne brojke ispitanike u svim kategorijama koje su od interesa za promatranje.

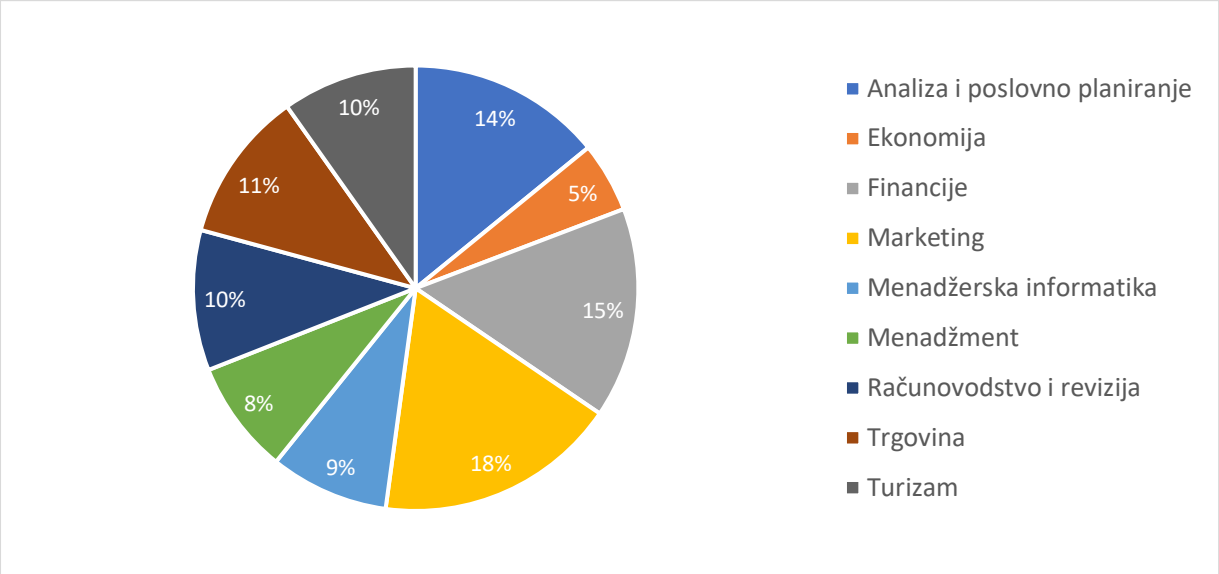
Grafikon 3 Distribucija ispitanika po upisanoj godini



Izvor: Izrada autora

Studenti koji su već upisali smjer (studenti 4. i 5. godine studija) su ravnomjerno raspodijeljeni po svim smjerovima.

Grafikon 4 Stariji studenti po upisanom smjeru



Izvor: Izrada autora

Od 255 starijih studenata iz ispitivanja, najviše ih je upisivalo smjerove Marketing, Financije i Analizu i poslovno planiranje, što su ujedno i smjerovi koji uvijek imaju najveću potražnju pri upisima.

Unutar svake pojedinačne kategorije se nalazi najmanje 20 ispitanika, osim smjera Ekonomija koji je sadržavao samo 13 ispitanika. Saznanja o tom smjeru se ne bi trebala generalizirati na populaciju studenata sa smjera Ekonomija zbog premalog uzorka u ispitivanju.

3.1.2 Analiza razlika ocjena po upisanim smjerovima

Kako bismo provjerili povezanost prosjeka ocjena i smjerova napraviti ćemo kratku ANOVA analizu prosjeka ocjena po smjerovima.

Radi malog broja ispitanika i razlike predmeta koja potrebna za upisivanje smjera ukoliko student nije upisao odvojeni studij „Ekonomija“ istoimeni smjer je isključen iz analize.

U nastavku se nalazi tablica sa sumarnom statistikom za prosječne ocjene po smjerovima:

Tablica 1 Sumarna statistika za prosjek ocjena po smjerovima

smjer	*n*	*mean*	*sd*	*median*	*min*	*max*	*range*
APP	36	3,91	0,47	3,83	3	4,97	1,97
Financije	37	4,18	0,38	4,19	3,43	4,91	1,48
Marketing	45	3,72	0,34	3,67	3,07	4,94	1,87
Menadžerska informatika	22	3,59	0,32	3,57	3,05	4,44	1,39
Menadžment	20	3,51	0,42	3,59	2,90	4,50	1,60
Računovodstvo i revizija	25	3,69	0,52	3,50	2,89	4,59	1,70
Trgovina	26	3,52	0,41	3,51	2,85	4,40	1,55
Turizam	19	3,49	0,36	3,48	2,81	4,16	1,35

Izvor: Izrada autora

Iz navedenog vidimo da su studenti ravnomjerno raspodijeljeni po smjerovima, sa većom količinom koji pripadaju popularnim smjerovima poput Financija, APP i Marketinga. Iz razlike između aritmetičke sredine i medijana možemo vidjeti da ne postoji asimetričnost u distribuciji ocjena po studentima unutar grupa sa iznimkom smjera Računovodstvo i revizija i APP koji posjeduju veću koncentriranost visoko ocijenjenih studenata koji dižu prosjek iznad medijanske razine.

Prosječna ocjena varira od 3,49 do 4,18 sa tim da smjerovima sa većim brojem upisanih studenata također imaju i više prosječne ocjene.

Za provjeru signifikantnosti razlika između prosječnih ocjena koristit ćemo ANOVA test.

Hipoteza je:

H0: Ne postoji signifikantna razlika između prosječnih ocjena po smjerovima
H1: Postoji signifikantna razlika između prosječnih ocjena po smjerovima

Test smo proveli koristeći programski jezik R.

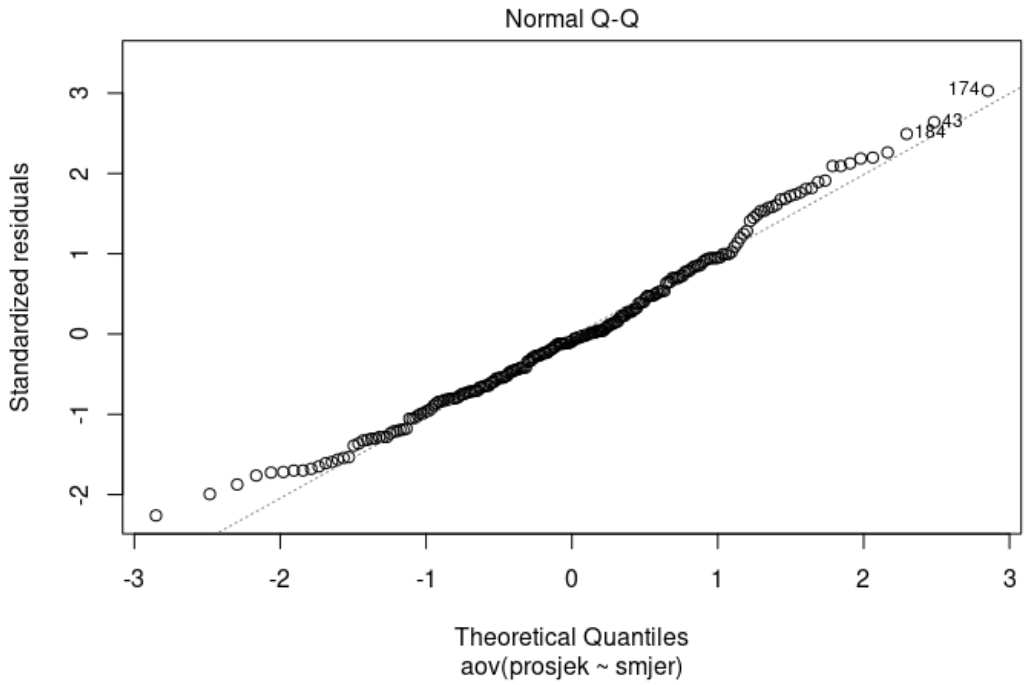
Napravljen je inicijalni ANOVA test objekt te je ispitan za potrebne pretpostavke:

- Neovisnost podataka među grupama
- Normalna distribucija unutar svake pojedinačne grupe
- Jednaka varijanca između grupa

Kako pojedinačni ispitanici pripadaju uvijek samo jednom smjeru zadovoljena je prva pretpostavka.

Za pretpostavku normalnosti najprije radimo grafički pregled podataka pomoću Q-Q grafikona.

Grafikon 5 Q-Q plot ANOVA analize prosječne ocjene



Izvor: Izrada autora

Iz grafikona lako vidimo da standardizirani reziduali prate kut od 45 stupnjeva te su grupe normalno distribuirane.

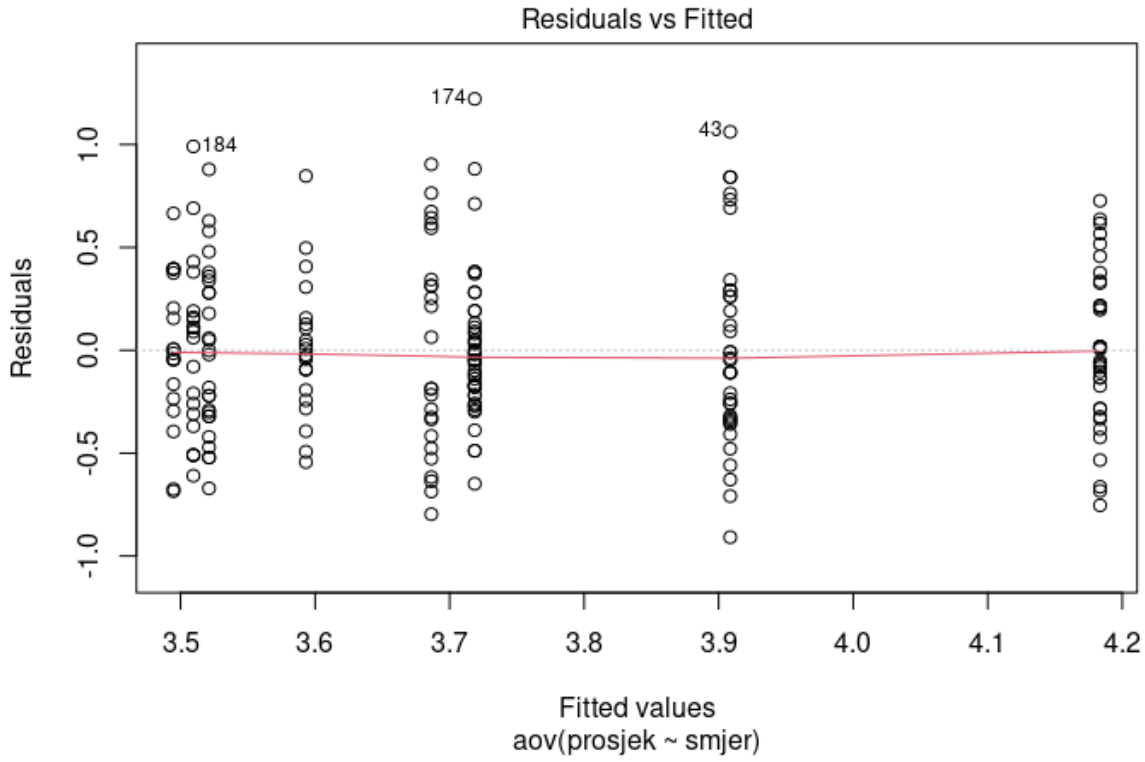
Dodatno pretpostavku provjeravamo Shapiro-Wilik testom za normalnost:

```
Shapiro-Wilk normality test

data:  aov_residuals
W = 0.98459, p-value = 0.01352
```

Rezultati testa su signifikantni odnosno možemo reći da je pretpostavka normalnosti distribucija zadovoljena. Sljedeća pretpostavka je o jednakosti varijanci grupa.

Grafikon 6 Grafikon reziduala i vrijednosti Anova test o prosječnim ocjenama



Izvor: Izrada autora

Iz pogleda na grafikon vidimo da reziduali snažno variraju u svim vrijednostima stoga moramo dodatno provjeriti homogenost varijanci pomoću Levene testa.

```
Levene's Test for Homogeneity of Variance (center = median)
           Df F      value      Pr(>F)
group       7       2.3194.    0.02658 *
residuals  222
---

Signif. codes:  0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1
```

Signifikantnost testnog rezultata znaci da se ne može potvrditi homogenost varijanci te ovi podaci narušavaju treću pretpostavku.

Kako je narušena pretpostavka o homogenosti varijanci uz potvrđenu pretpostavku normalnosti podataka u grupama koristiti ćemo Welchovu varijantu ANOVA testa koja ne zahtjeva prijašnju pretpostavku.

```
One-way analysis of means (not assuming equal variances)

data:  prosjek and smjer
F = 11.162, num df = 7.000, denom df = 84.187, p-value = 6.517e-10
```

Rezultati testa pokazuju da postoji signifikantna razlika između prosječnih ocjena među smjerovima. Kako bismo saznali konkretno među kojim smjerovima koristiti ćemo Games-Howell post-hoc test koji također ne zahtjeva homogenost varijanci.

Tablica 2 Rezultati Games-Howell post-hoc testa

group1	group2	estimate	p.adj	p.adj.signif
Analiza i poslovno planiranje	Financije	0.27490240	1.33e-01	ns
Analiza i poslovno planiranje	Marketing	-0.18994444	4.82e-01	ns
Analiza i poslovno planiranje	Menadžerska informatika	-0.31542929	7.10e-02	ns
Analiza i poslovno planiranje	Menadžment	-0.39911111	4.40e-02	*
Analiza i poslovno planiranje	Računovodstvo i revizija	-0.22221111	6.83e-01	ns
Analiza i poslovno planiranje	Trgovina	-0.38745726	2.30e-02	*
Analiza i poslovno planiranje	Turizam	-0.41387427	1.60e-02	*
Financije	Marketing	-0.46484685	5.30e-06	****
Financije	Menadžerska informatika	-0.59033170	1.62e-06	****
Financije	Menadžment	-0.67401351	2.24e-05	****
Financije	Računovodstvo i revizija	-0.49711351	4.00e-03	**
Financije	Trgovina	-0.66235967	9.04e-07	****
Financije	Turizam	-0.68877667	2.19e-06	****
Marketing	Menadžerska informatika	-0.12548485	8.22e-01	ns
Marketing	Menadžment	-0.20916667	5.35e-01	ns
Marketing	Računovodstvo i revizija	-0.03226667	1.00e+00	ns
Marketing	Trgovina	-0.19751282	4.51e-01	ns
Marketing	Turizam	-0.22392982	3.31e-01	ns
Menadžerska informatika	Menadžment	-0.08368182	9.96e-01	ns
Menadžerska informatika	Računovodstvo i revizija	0.09321818	9.95e-01	ns
Menadžerska informatika	Trgovina	-0.07202797	9.97e-01	ns
Menadžerska informatika	Turizam	-0.09844498	9.83e-01	ns
Menadžment	Računovodstvo i revizija	0.17690000	9.08e-01	ns
Menadžment	Trgovina	0.01165385	1.00e+00	ns
Menadžment	Turizam	-0.01476316	1.00e+00	ns
Računovodstvo i revizija	Trgovina	-0.16524615	9.08e-01	ns
Računovodstvo i revizija	Turizam	-0.19166316	8.32e-01	ns
Trgovina	Turizam	-0.02641700	1.00e+00	ns

Izvor: izrada autora

Iz rezultata možemo vidjeti da postoji signifikantna razlika između smjera APP i smjerova Menadžment, Trgovina i Turizam te smjera Financije i svih ostalih smjerova osim APP. Studenti koji su upisali APP su prosječno ostvarili oko 0.4 višu prosječnu ocjenu od studenata

navedenih smjerova, dok su studenti Financija ostvarili najmanje 0.4 do najviše čak 0.69 više od svojih kolega.

Iz ovih rezultata vidimo da određeni smjerovi imaju studente s višim prosjekom te je pitanje u kojem smjeru ide utjecaj – biraju li uspješniji studenti te smjerove jer smatraju da bi „trebali“ ili ti smjerovi uistinu privlače uspješnije studente.

3.1.3 Motivacijski faktori pri izboru smjera te izvori informacija

Drugi dio upitnika se odnosio na faktore koji utječu na izbor smjera svakog pojedinca te na način na koji se isti informiraju o potencijalnim smjerovima.

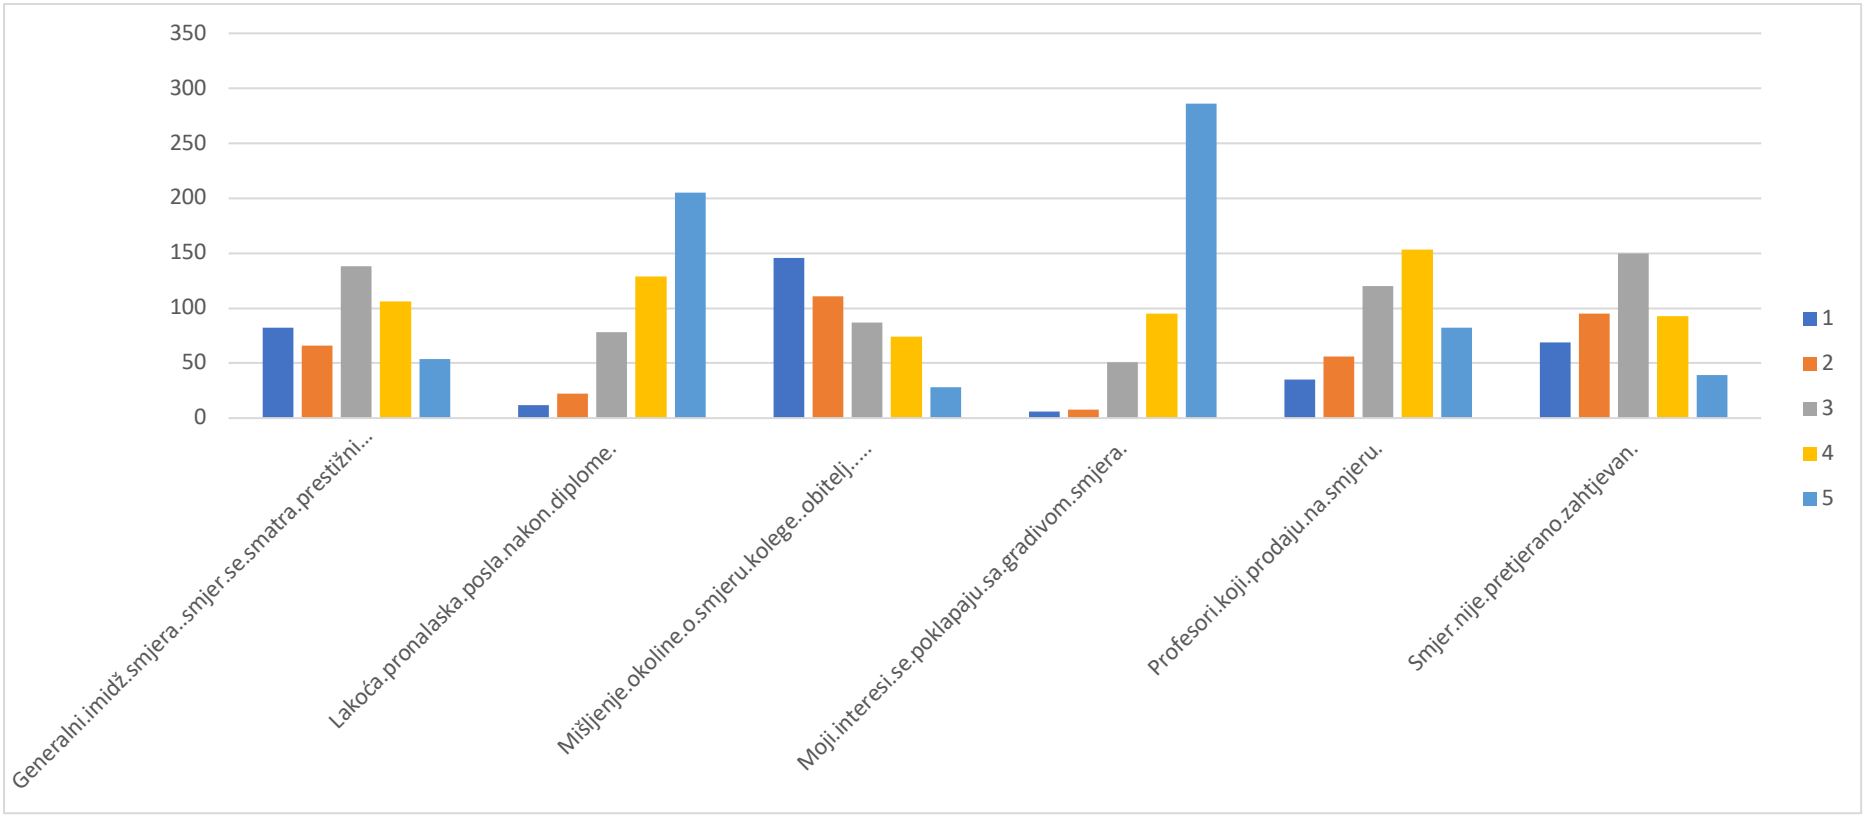
Ispitanici su dobili 6 tvrdnji za koje su morali odrediti koliko su im (bili) utjecajni pri odabiru smjera. Za svaku tvrdnju su morali dati ocjenu na Likertovoj skali od 1 – Nije mi uopće bitno do 5 – Jako mi je bitno.

Tvrdnje su bile:

- Moji interesi se poklapaju sa gradivom smjera
- Smjer nije pretjerano zahtjevan
- Lakoća pronalaska posla nakon diplome
- Mišljenje okoline o smjeru(kolege, obitelj...)
- Profesori koji predaju na smjeru
- Generalni imidž smjera (smjer se smatra prestižnim)

Rezultati upitnika se nalaze na grafikonu na sljedećoj stranici.

Grafikon 7 Motivatori upisa smjera



Izvor: Izrada autora

Iz grafikona lako možemo vidjeti da najvažniji faktor za ispitanike je svakako poklapanje njihovih interesa sa gradivom smjera te lakoća pronalaska posla. Ovi rezultati se poklapaju sa istraživanjem Ayrani i Umar (2020.) koji su pokazali Zapaljivost kao signifikantno utjecajan faktor za studente Društvenih fakulteta uz Interes kao zajednički najvažniji motivator za sve studente.

Rezultati ovog upitnika nisu pokazali jednaku snagu utjecaja prestiža na odabir smjera obrazovanja te se upravo on pokazao kao najslabiji motivator. To može biti povezano uz razliku u kulturi visokog obrazovanja u Aziji (gdje je provedeno spomenuto istraživanje) i Hrvatskoj. U Aziji je visoko obrazovanje privilegija te statusni simbol unutar društvenih krugova, dok u Hrvatskoj velika brojka populacije je visoko obrazovana te ne postoji znatna statusna razlika između visoko i niže obrazovanog stanovništva.

Drugi cilj ovog dijela upitnika je bilo odrediti kako se studenti Ekonomskog fakulteta informiraju prije donošenja odluke o smjeru. Informiranost se pokazala u dosadašnjim istraživanjima kao najbolji protu čimbenik negativnim efektima donošenja odluka. Također ovisno o obliku informiranja koji studenti koriste, količina informacija koju moraju obraditi te stoga i vjerojatnost nastupanja efekta „choice overload“ znatno variraju.

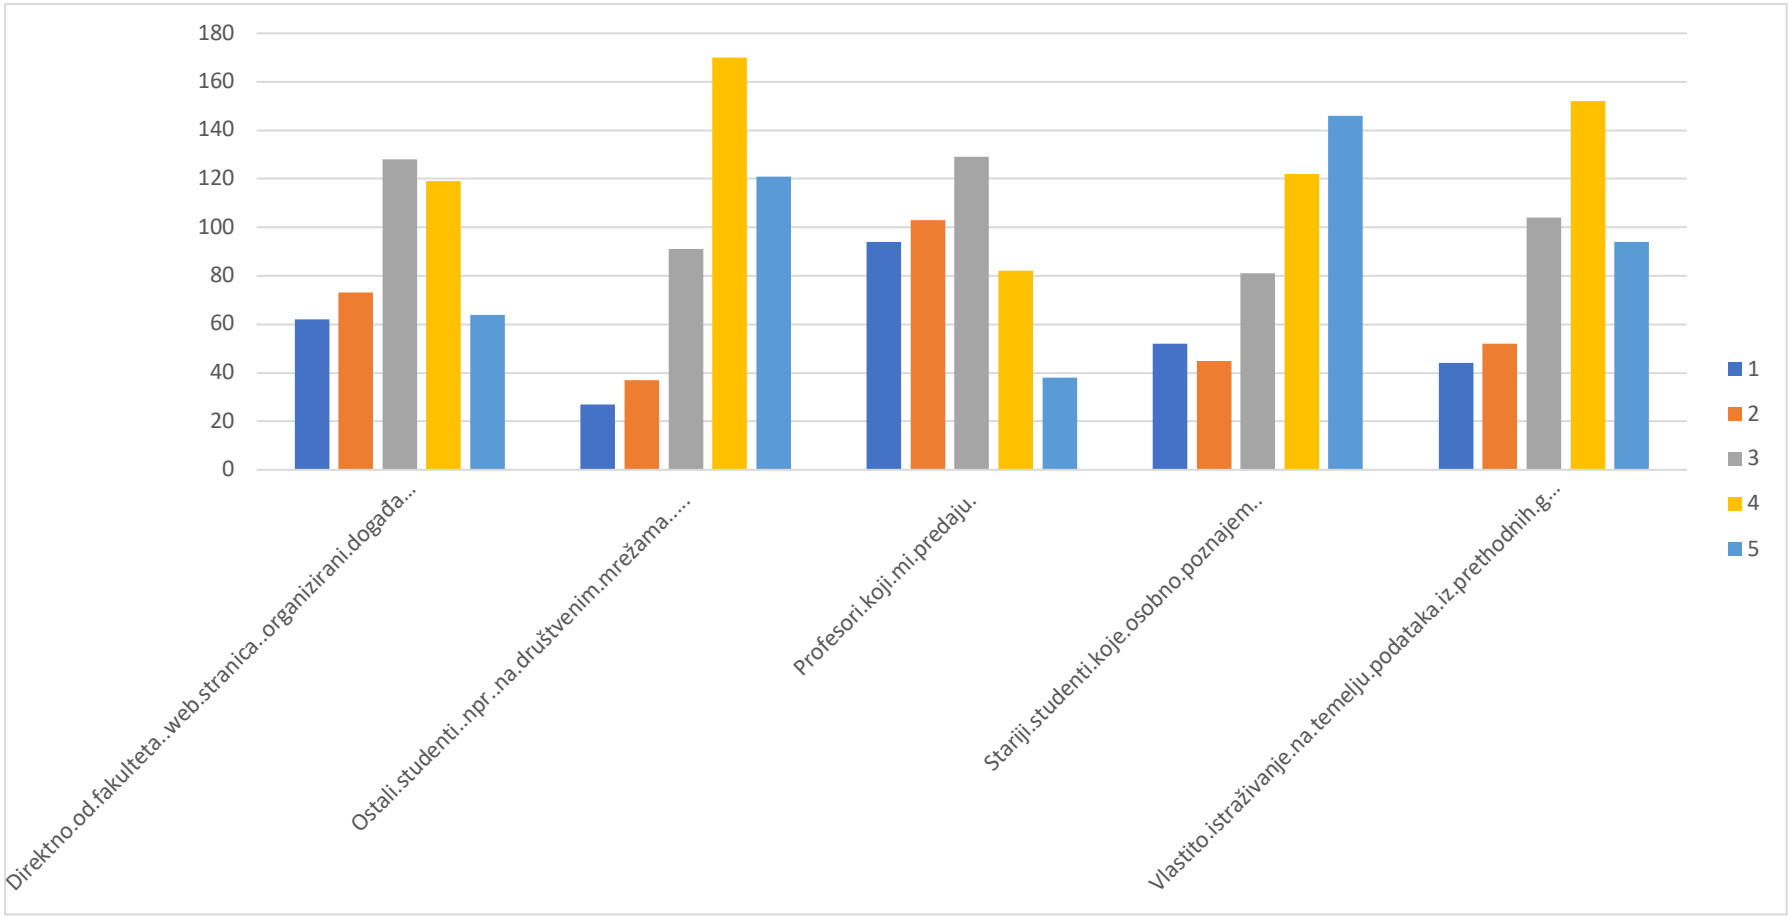
Slično prethodnom pitanju i u ovu svrhu je korištena Likertova skala sa 5 točaka. Za svaku od narednih tvrdnji ispitanici su se morali izjasniti sa vrijednosti između: 1 - Ne koristim ih uopće i 5 – Koristim ih neprestano.

Tvrdnje su bile sljedeće:

- Direktno od fakulteta (web stranica, organizirani događaji...)
- Profesori koji mi predaju
- Stariji studenti koje osobno poznajem
- Ostali studenti (npr. na društvenim mrežama...)
- Vlastito istraživanje na temelju podataka iz prethodnih godina

Rezultati istraživanja se nalaze na sljedećoj stranici.

Grafikon 8 Izvori informacija o smjerovima



Izvor: Izrada autora

Iz rezultata vidimo da se student pretežito oslanjaju na ostale studente za informacije o smjerovima – bilo osobne poznanike ili pojedince na društvenim mrežama.

To se preklapa sa dosadašnjim istraživanjima koja su pokazala utjecaj društvenog učenja i mrežnih eksternalija (Isler et al., 2021.) kao mehanizme utjecaja ostalih studenata na odluke o smjeru obrazovanja. Važno je istaknuti da su se studenti izjasnili da mišljenje okoline ne utječe na njihovu odluku, ali suprotno tomu primarno se informiraju od svoje neposredne okoline za tu odluku. Tu dolazi do paradoksa jer je neminovno da će ostali studenti projicirati svoje subjektivne dojmove na informacije koje prenose kolegama te tako zapravo studenti padaju pod utjecaj mišljenja okoline makar nesvjesno.

Ipak kao što je Islerovo istraživanje pokazalo, utjecaj starijih studenata ne mora biti nužno loš. Zapravo je korisno da se studenti informiraju od starijih kolega jer tako mogu izbjeći padanje pod utjecaj mentaliteta krda što bi ih vodilo do lošijih odluka i rezultata o obrazovanju. Bitno je da njihovo informiranje bude konkretno te da starije kolege ne budu samo osobni poznanici jer je vjerojatnost da student poznaje više kolega sa svakog od 9 smjerova relativno malena. Tu se pokazuje prilika za spomenuti sustav za preporuku jer bi mogao popuniti ovu potrebu na efikasan način te potpomoći studentima da se informiraju i na dosad najtraženiji način – od iskustava drugih studenata, bez pristranosti koji mogu nastupiti zbog malog uzorka poznanika.

3.1.4 Mišljenje okoline i predrasude

Završni dio upitnika je želio procijeniti stavove studenata prema pojedinačnim smjerovima te postoji li utjecaj okoline na njihovo mišljenje.

U tu svrhu su postavljeni parovi pitanja za svaki smjer. Studenti su prvo morali procijeniti objektivnu privlačnost svakog smjera te zatim procijeniti koliku prosječnu ocjenu su dali ostali ispitanici. Cilj je bio vidjeti koliko odstupa osobna ocjena svakog ispitanika od ocjene koju on smatra da posjeduje okolina.

Tablica 3 Ocjene privlačnosti smjerova

	VLASTITA OCJENA	OCJENA OKOLINE	RAZLIKA
ANALIZA I POSLOVNO PLANIRANJE	6,54	6,85	-0,31
EKONOMIJA	4,67	5,05	-0,38
FINANCIJE	7,63	7,89	-0,26
MENADZMENT	6,95	7,24	-0,28
MENADZERSKA INFORMATIKA	6,36	6,32	0,04
MARKETING	7,42	7,82	-0,40
RACUNOVODSTVO I REVIZIJA	6,75	6,67	0,08
TRGOVINA I MEDUNARODNO POSLOVANJE	5,39	5,43	-0,04
TURIZAM	5,72	5,91	-0,19

Izvor: Izrada autora

Rezultati su očekivano pokazali da smjerovi sa najvećim interesom za upis također najbolje kotiraju po privlačnosti samim studentima. Najprivlačniji smjerovi su se pokazali Financije i Marketing dok su Ekonomija i Trgovina i Međunarodno poslovanje najlošije ocijenjeni. Treba istaknuti da Ekonomija zbog svoje specifičnosti te odvojenog preddiplomskog dijela ima iznimno nepovoljan položaj kako većina studenata nije upisala ni preddiplomsku razinu, te vjerojatno nema namjeru ni upisati sami smjer. Ipak, kako je dopušteno da studenti upišu smjer uz polaganje razlike predmeta smjer se ipak nalazio u anketi.

Zanimljivo je istaknuti da većina smjerova ima negativnu razliku naprema ocjenama okoline, odnosno studenti smatraju da okolina ima pozitivnije stavove o samim smjerovima nego što zaslužuju. Smjerovi koji imaju pozitivnu razliku su Menadžerska informatika te Računovodstvo i revizija, te su po mišljenju studenata to smjerovi koji imaju negativnu sliku u okolini, a zaslužuju višu privlačnost. Po ocjenama iz upitnika granica u kojoj smjerovi popunjavaju svoj kapacitet je oko 6.5 (ocjena koju smatraju da daje okolina).

Također možemo promatrati skalu razlike. Smjerovi koji popunjavaju svoju kvotu imaju veću razliku od smjerova koji ne popunjavaju kvotu .

Primjerice smjer APP koji ima visoku potražnju te zahtjeva više ocjene za upasti se nalazi na granici, ali ima visoku pozitivnu razliku u ocjeni okoline. Suprotan primjer je smjer Menadžerska informatika koji također ima graničnu ocjenu, ali ima negativan smjer prema ocijeni okoline. Potencijalno da postoji pozitivnije mišljenje studenata o percepciji ostalih ,uslijed utjecaja društvenog učenja i mrežnih eksternalija bi i rastao interes za upisom smjera.

Zadnji zanimljiv slučaj za promatranje je Računovodstvo i revizija koji makar ima negativne predrasude i dalje posjeduje dovoljnu razinu privlačnosti za studente.

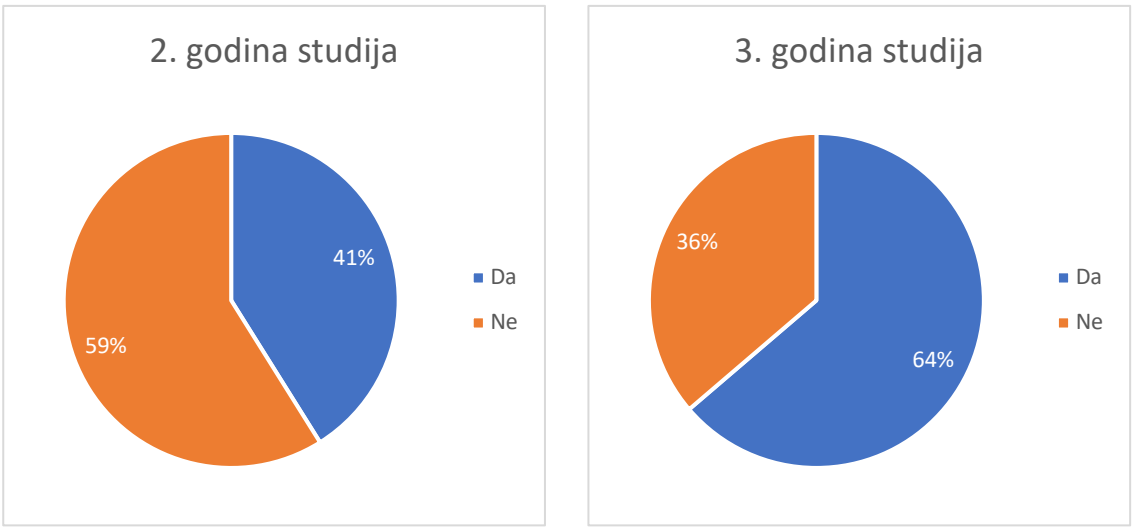
3.1.5 Zaključak istraživanja

Iz ovih rezultata vidimo da postoji razlika u privlačnosti među smjerovima. Ona je također povezana i za upisnim brojkama, gdje privlačniji smjerovi imaju više upisanih studenata što je i očekivano. Ipak apsolutna ocjena privlačnosti nije u potpunosti korelirana sa upisnim brojkama jer smjerovi sa sličnim ocjenama mogu imati drastične razlike u upisnim brojkama. Nadalje, vidimo da smjerovi sa višim ocjenama također imaju i veću razliku kada se gleda usporedba sa ocjenama koje studenti smatraju da posjeduje okolina. To može biti povezano sa elementima da studenti mimiciraju starije studente, odnosno da daju višu ocjenu privlačnosti određenim smjerovima nesvjesno jer prate okolinu, makar smatrali da ti smjerovi ne zaslužuju toliku razinu privlačnosti.

Također se postavlja pitanje zašto studenti sa višim ocjenama upisuju smjerove koji ne rangiraju visoko po privlačnosti. Uzmimo ponovno za primjer smjer APP koji ima drugi najviši prosječni prosjek ocjena studenata i smjer Menadžment koji ima drugi najlošiji. Zanimljivo je da usprkos tomu što je Menadžment više rangiran po objektivnoj privlačnosti on nema jednako visok udio uspješnih studenata niti apsolutan broj upisanih studenata. Ovo dokazuje da studenti nisu racionalni agenti te ne maksimiziraju svoju korisnost kao što tradicionalna teorija igara govori. Oni su skloni pristranostima te to ponovno potvrđuje teze bihevioralnih ekonomista o potrebi šireg promatranja donošenja odluka.

Ovo sve predstavlja opasnost da studenti padnu pod mentalitet krda te donesu pogrešne odluke pri odabiru smjera. Skoro polovina studenata mlađih godina se u upitniku izjasnila da ne zna koji smjer žele upisati. Ta brojka naravno varira od godine studija.

Grafikon 9 Postotak studenata sa odabranim smjerom po godinama studija



Izvor: Izrada autora

Gledajući pojedinačno 2. i 3. godinu studija, mlađi studenti velikom većinom još nemaju određenu preferenciju te su podložniji utjecaju ostalih pri donošenju te odluke. Stariji studenti imaju veću vjerojatnost da imaju definirane preferencije te su manje vjerojatni da će pasti pod mentalitet krda. Ipak treba istaknuti da i dalje postoji signifikantan udio studenata 3. godine koji nemaju određeni smjer koji žele upisati – skoro 40%. Uzimajući u obzir da svake godine više od 600 studenata upisuje smjer, govorimo o 240 potencijalnih korisnika predloženog sustava za preporuku. On bi mogao olakšati odabir neodlučnim studentima tako da im izoštri preferencije kroz mehanizam društvenog učenja u obliku iskustava starijih studenata. Također kako sustav ne diskriminira medu smjerovima, neki manje popularni smjerovi poput Turizma i Trgovine bi mogli dobiti priliku da se predstave studentima, jer usprkos niskoj ocjeni privlačnosti i dalje postoji određeni dio studenata čiji

osobni interesi se preklapaju sa gradivom tih smjerova, ali su više orijentirani na smjerove koji su popularniji i zbog toga imaju dostupnije informacije o njima.

U sljedećem poglavlju predstaviti će se aplikacija EFZG smjer koja ukomponira predloženi sustav za preporuku te nastoji olakšati problem odabira smjera za neodlučne studente.

4 Aplikacija za preporuku smjera na Ekonomskom fakultetu

4.1 Sustav za preporuku

Glavna funkcionalnost web aplikacije je svakako sustav za preporuku koji u beck-endu uzima odgovore iz upitnika te ih obrađuje da bi pronašao najsličnije aluminije samim studentima te njihova iskustva sa smjerovima koje su pohađali.

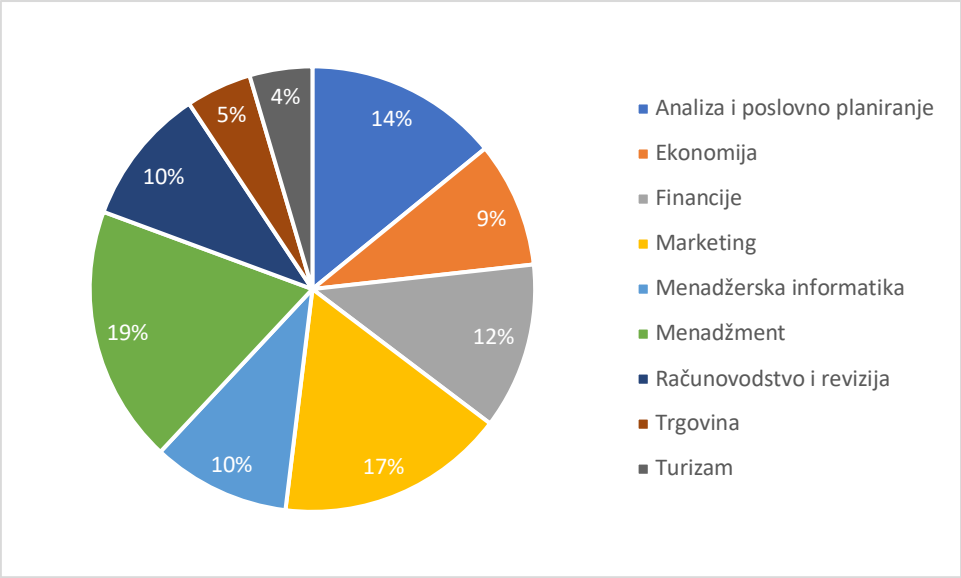
Za izradu ovog sustava je bilo potrebno skupiti što veću bazu sa alumnijima kako bi se moglo pronaći dovoljno sličnih pojedinaca samim studentima za kvalitetne preporuke. U tu svrhu je izrađen upitnik koja određuje osobnost i karijerne interesa pojedinca te je proveden medu alumnijima Ekonomskog Fakulteta u Zagrebu.

4.1.1 Upitnik za izradu alumni baze

Upitnik je izrađen ponovno pomoću Google Forms servisa. Distribucija se odvijala pomoću društvenih mreža (Facebook, LinkedIn) te kroz mailing liste profesora sa fakulteta.

Odgovori su prikupljivani kroz period od 2. mjeseca u 2020. godini. Anketi se odazvalo 442 alumnija fakulteta. Iako je ta brojka manja od željene i dalje svaki od smjerova sadrži minimalno 20 ispitanika što čini oko 5 posto ispitanika, te je baza uzeta kao adekvatna za izradu sustava uz potrebu za testiranjem pristranosti pri završetku razvoja.

Grafikon 10 Distribucija alumnija po smjerovima



Izvor: Izrada autora

Sami upitnik je podijeljen u 4 glavna seta pitanja. Kako su psihološki upitnici najčešće poprilično opširni i kompliciranu za ispuniti (zahtijevaju mnogo introspekcije te vremena) autor se odlučio za korištenje skraćenih pouzdanih metodologija. Prvi set pitanja ima cilj odrediti osobnost pojedinca. U tu svrhu je odabran već spomenuti Big Five model osobnosti zbog njegove istraživanosti te fleksibilne primjene u raznim granama znanosti i industrije. Za sami upitnik je odabran BFI-10 upitnik (Rammstedt i John, 2007.) koji je dodatno skraćena verzija BFI-44 upitnika koji je predstavljen kao kratki upitnik za određivanje Big Five dimenzija osobnosti kod ispitanika. Makar se radi o iznimno skraćenoj verziji originalnog upitnika autori su dokazali da posjeduje cak 75 postotnu korelaciju medu rezultatima.

Upitnik se sastoji od deset tvrdnji na koje ispitanik mora dati odgovor na likertovoj skali od 1- U potpunosti se ne slažem do 5-U potpunosti se slažem

Smatram se osobom koja je:

1. …rezervirana
2. … uglavnom povjerljiva

3. … ima tendenciju biti lijena
4. … opuštena, dobro podnosi stres
5. … ima nekoliko umjetničkih interesa
6. … otvorena, društvena
7. … ima tendenciju pronalaziti mane kod drugih
8. … detaljna u obavljanju svojih obaveza
9. … lako postane nervozna
10. … kreativna, posjeduje aktivnu imaginaciju

Ocjenjivanje upitnika se bazira na parovima pitanja za svaku od 5 dimenzija Big Five modela. Svaki par sadrži pitanje koje se boduje pozitivno i pitanje koje se boduje inverzno tako da za svaku dimenziju pojedinac može ostvariti ocjenu između 2 i 10.

Kodiranje za ocjenjivanje je bilo:

Ekstraverzija: 1R + 6
Ugodnost: 2 + 7R
Savjesnost: 3R + 8
Neuroticizam: 4R + 9
Otvorenost: 5R + 10
** R označava inverzno bodovanu tvrdnju*

Drugi dio upitnika je bio fokusiran na određivanje karijernih interesa pojedinaca. Kao metodologija za klasifikaciju je uzet Hollandov RIASEC model (Holland, 1997.) kao „de facto“ standard u ovom području istraživanja karijera i pojedinaca. U svrhu smanjenja opterećenja studenta pri ispunjavanju upitnika ponovno je odabran skraćen oblik upitnika (Ambiel et al, 2018.).

Skraćenica RIASEC predstavlja 6 karijernih tipova koje je odredio Holland: R – Realisti, I – Istraživači, A – Umjetnici, S – Socijalni, E – Poduzetan i C – Konvencionalan.

Upitnik Ambiel i suradnika koristi set od 18 pitanja kako bi odredio kombinaciju 3 tipa koja su najistaknutija kod pojedinca. Ispitanici na svako od pitanja, odnosno tvrdnji, ponovno daju odgovor na Likertovoj skali od 1 do 5. Kako je upitnik namijenjen za opću populaciju, autor je prilagodio nekolicinu tvrdnji da bi se više odrazila na ekonomske i poslovne svrhe. Lista tvrdnji se nalazi u nastavku:

1. … raditi sa računalima, novim tehnologijama
2. … održavati programe/alate potrebne za obavljanje posla
3. … računati, rješavati matematičke probleme
4. … čitati znanstvene radove i knjige
5. … raditi analize i eksperimente
6. … objašnjavati društvene pojave (poput ponašanja potrošača)
7. … sudjelovati u dizajniranju proizvoda/servisa
8. … prezentirati ispred publike
9. … imati slobodne ruke da budem kreativan na poslu
10. … pružati socijalne (društveno korisne) servise svojoj zajednici
11. … davati smjernice pojedincima za poboljšanje njihovog blagostanja
12. … biti dostupan za pomoći ljudima
13. … raditi na strateškim pitanjima u poduzeću
14. … upravljati ciljevima i performansama radnih timova
15. … pregovarati sa kupcima
16. … nadgledati usklađenost sa pravilima/zakonima
17. … analizirati makroekonomska pitanja/scenarije
18. … upravljati važnim dokumentima i datotekama

Bodovanje ovog upitnika je iznimno jednostavno. Za svaki od tipova karijernih interesa postoje tri tvrdnje te su tri tipa sa najvišim ocjenama kombinacija za individualnog ispitanika. Tvrdnje su poredane po imenima tipova iz RIASEC modela, odnosno tvrdnje tipa Realist su 1, 2, 3 , tipa Istraživač 4, 5, 6 i tako dalje.

Treći set pitanja se temeljio na interesu prema predmetima koje su pojedinci imali u dosadašnjem studiranju. Odabran je set od 15 predmeta koje je autor odredio na temelju

razgovora sa poznanicima sa različitih smjerova te su bili odabrani kao najbitniji za procjenu. Ispitanici su trebali ocijeniti zanimljivost svakog predmeta na Likertovoj skali od 1 do 5.

Predmeti koje su ispitanici ocjenjivali su bili:

1. Informatika
2. Osnove ekonomije
3. Gospodarstvo Hrvatske
4. Statistika
5. Trgovačko pravo
6. Poduzetništvo
7. Organizacija
8. Poslovne financije
9. Računovodstvo
10. Financijske institucije i tržišta
11. Javne financije
12. Međunarodno poslovanje
13. Osnove marketinga
14. Turizam
15. Poslovni informacijski sustavi

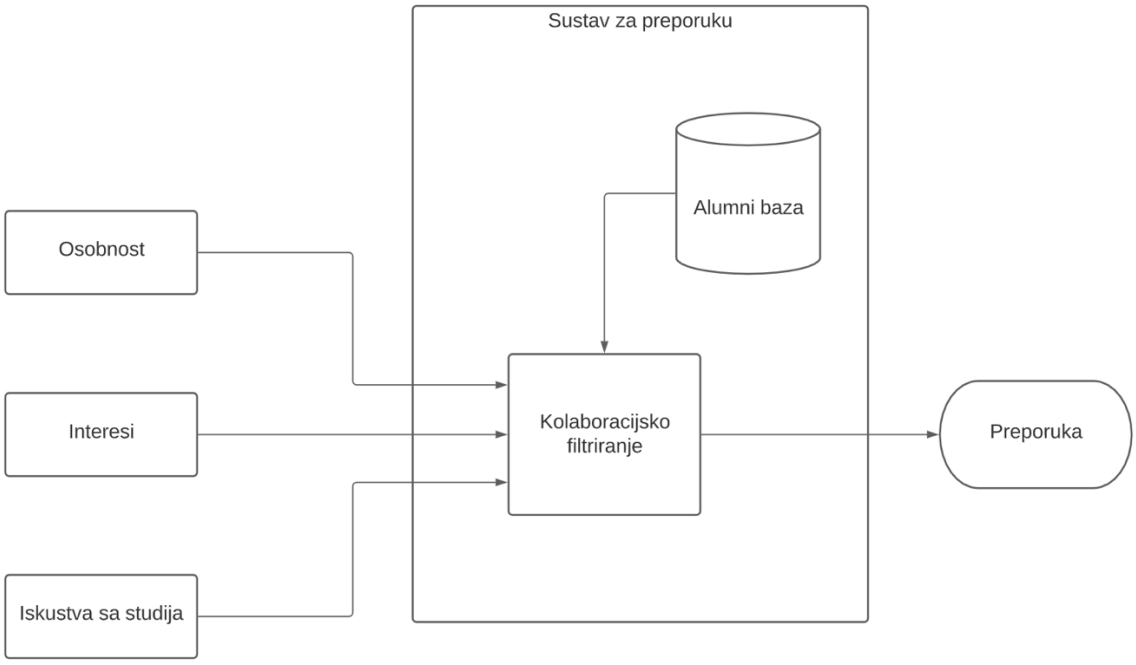
Završni set pitanja se odnosio na zadovoljstvo alumnija sa njegovim smjerom te nekoliko pitanja o sadašnjoj karijeri te utjecaju smjera na istu. Ovi odgovori su iznimno bitni jer služe kao rezultat samog sustava za preporuku, odnosno po njima student može procijeniti koji smjer je za njega najbolji odabir.

Cjelokupni upitnik se nalazi u prilozima na kraju ovog rada.

4.1.2 Algoritam preporuke

Predloženi sustav se temelji na hibridnom obliku, odnosno kombinira više metoda sustava za preporuku. Prije svega sustav koristi povijesne podatke kroz ocjene samih studenata kao jednu od dimenzija diferencijacije potreba. Nadalje to se nadograđiva sa podacima o osobnosti i interesima kroz skraćene upitnike BFI-10 i RIASEC-18. Kao što smo vidjeli, te dimenzije su se pokazale u dosadašnjim istraživanjima kao iznimno bitne pri odabiru smjera i ne smiju se nikako izostaviti. Tad se upotrebljava metoda Kolaboracijsko filtriranje gdje se te 3 dimenzije uspoređuju sa alumni bazom. Kroz usporedbu se pronalazi 20 najsličnijih alumnija te se njihovi odgovori iz zadnje kategorije upitnika (zadovoljstvo studijem, utjecaj na karijeru itd.) vraćaju studentu te prezentiraju kroz web aplikaciju kao preporuka. Time studenti dobivaju benefite društvenog učenja bez potrebe da osoba uistinu poznaje pojedince na osobnoj razini. Dodatno na temelju odgovora iz upitnika se određuje osobnost studenta po Big Five metodologiji i Karijerno interesni tipovi iz RIASEC modela te se ti podaci vraćaju uz podatke najsličnijih alumnija.

Slika 1 Dijagram sustava za preporuku



Izvor: Izrada autora

Jezik koji je odabran za pisanje algoritma je Python. Ova odluka se bazira na jednostavnosti pisanja koda za obradu podataka u Pythonu te njegovoj širokoj primjeni koja uključuje web back-end, te je zbog toga bio bolji odabir od primjerice R jezika koji se također primarno koristi za obradu podataka, ali nije predviđen za razvoj web rješenja.

Cjelokupni kod za preporuku se nalazi ispod:

```python
#!/usr/bin/python
# -*- coding: utf-8 -*-
from flask import jsonify
import pandas as pd
import json
import os


def obradi_podatke(jsdata):

    osobnost = pd.DataFrame.from_records(jsdata['osobnost'], index=[0])
    interesi = pd.DataFrame.from_records(jsdata['interesi'], index=[0])
    predmeti = pd.DataFrame.from_records(jsdata['predmeti'], index=[0])

    odgovor = pd.concat([osobnost.reset_index(drop=True),
                         interesi.reset_index(drop=True), predmeti],
                         axis=1).apply(pd.to_numeric)

    osobnost_df = pd.DataFrame(columns=['Osobina', 'Vrijednost'])

    def reverse_score(num):
        if num == 5:
            return 1
        elif num == 4:
            return 2
        elif num == 3:
            return 3
        elif num == 2:
            return 4
        elif num == 1:
            return 5
        else:
            return 0

    osobnost_df.loc[0] = ['Otvorenost', odgovor.at[0, 'q10']
                          + reverse_score(odgovor.at[0, 'q05'])]
    osobnost_df.loc[1] = ['Savjesnost', odgovor.at[0, 'q08']
                          + reverse_score(odgovor.at[0, 'q03'])]
    osobnost_df.loc[2] = ['Ekstroverzija', odgovor.at[0, 'q06']
                          + reverse_score(odgovor.at[0, 'q01'])]
    osobnost_df.loc[3] = ['Ugodnost', odgovor.at[0, 'q02']
                          + reverse_score(odgovor.at[0, 'q07'])]
    osobnost_df.loc[4] = ['Neuroticizam', odgovor.at[0, 'q09']
                          + reverse_score(odgovor.at[0, 'q04'])]

    osoba_json = osobnost_df.to_json(orient='records')

    riasec_df = pd.DataFrame(columns=['Model', 'Zbroj'])
```

```
    riasec_df.loc[0] = ['R', odgovor.at[0, 'q11'] + odgovor.at[0, 'q12'
                        ] + odgovor.at[0, 'q13']]
    riasec_df.loc[1] = ['I', odgovor.at[0, 'q14'] + odgovor.at[0, 'q15'
                        ] + odgovor.at[0, 'q16']]
    riasec_df.loc[2] = ['A', odgovor.at[0, 'q17'] + odgovor.at[0, 'q18'
                        ] + odgovor.at[0, 'q19']]
    riasec_df.loc[3] = ['S', odgovor.at[0, 'q20'] + odgovor.at[0, 'q21'
                        ] + odgovor.at[0, 'q22']]
    riasec_df.loc[4] = ['E', odgovor.at[0, 'q23'] + odgovor.at[0, 'q24'
                        ] + odgovor.at[0, 'q25']]
    riasec_df.loc[5] = ['C', odgovor.at[0, 'q26'] + odgovor.at[0, 'q27'
                        ] + odgovor.at[0, 'q28']]

    riasec_df = riasec_df.sort_values(by=['Zbroj'], ascending=False)\
        .reset_index(drop=True)

    interesi_df = pd.DataFrame(columns=['tip', 'rezultat'])

    interesi_df.loc[0] = ['primarni', riasec_df.at[0, 'Model']]
    interesi_df.loc[1] = ['sekundardni', riasec_df.at[1, 'Model']]
    interesi_df.loc[2] = ['tercijarni', riasec_df.at[2, 'Model']]

    interesi_json = interesi_df.to_json(orient='records')

    my_dir = os.path.dirname(__file__)
    json_file_path = os.path.join(my_dir, 'data/ostali.json')
    with open(json_file_path, 'r') as f:
        ostali = pd.read_json(f)

    odgovor = odgovor.sort_index(axis=1)
    ostali_usporedba = ostali.loc[:, 'q01':'q45'].T

    odgovor_usporedba = odgovor.squeeze()

    usporedba_rez = \
        ostali_usporedba.corrwith(odgovor_usporedba)\
        .sort_values(ascending=False)\
        .index.values[0:20]

    ostali_rez = ostali.iloc[usporedba_rez, 43:58]

    ostali_json = ostali_rez.to_json(orient='records')

    return jsonify(osoba=json.loads(osoba_json),
                   interesi=json.loads(interesi_json),
                   ostali=json.loads(ostali_json))
```

Čitava logika sustava za preporuku se nalazi u jednoj Python funkciji. Kod se temelji na Pandas proširenju za Python, čija je glavna namjena analiza podataka kroz DataFrame objekte. Cjelokupna funkcija ovisi o odgovorima iz upitnika koji se šalju u back-end u obliku JSON formata. Funkcija ih primi te razdvoji u 3 odvojena DataFrame objekta za svaki od 3 seta pitanja. Zatim definira funkciju za inverzno ocjenjivanje koju iskoristi za bodovanje BFI-10 upitnika te rezultate spremi u odvojeni objekt. U nastavku kod zbroji bodove za sve RIASEC dimenzije te odredi 3 primarna karijerno-interesna tipa koje ponovno spremi u odvojeni objekt. Završni dio koda prvo učita bazu alumnija iz JSON objekta spremljenog na serveru. Tu bazu pretvori u DataFrame objekt koji transponira tako da je svaki alumni predstavlja jedan stupac. Zatim uzme odgovore studenta te odredi Pearsonovu korelaciju sa svakim od alumnija te izabere 20 onih sa najvećom vrijednosti. Pearsonova korelacija je naposljetku odabrana umjesto inicijalno korištenog Dot produkta jer je manje osjetljiva na ekstremne vrijednosti u pojedinačnim odgovorima, te je lako objašnjiva svima sa osnovnim statističkim obrazovanjem. Funkcija zatim spoji odgovore iz završnog dijela Alumni upitnika za 20 odabranih alumnija te ih spremi u odvojeni objekt. U zadnjem koraku spoji 3 odvojena objekta sa rezultatima iz osobnosti, interesa i najsličnijih alumnija, te ih sve spoji u JSON format koji prosljeđuje nazad u front-end za vizualizaciju i prezentaciju.

4.2 Tehnička pozadina aplikacije i razvoj

Za razvoj aplikacije je korišten Flask framework. Flask je minimalni web framework baziran na Pythonu. Glavna obilježja su mu jednostavnost, modularnost te brzina razvoja. Uzimajući u obzir te karakteristike uz činjenicu da je kod za sustav za preporuku pisan u Pythonu nametnuo se kao logičan odabir za izradu EFZGsmjer web aplikacije.

Infrastruktura aplikacije se sastoji od standardna dva dijela – front-end i back-end. Back-end servira statičke fileove za front-end te sadrži logiku sustava za preporuku. Front-end u ovom primjeru ima zadatak prezentiranja rezultata poslanih iz sustava za preporuku.

4.2.1 Razvoj

Za izradu front-enda su se koristili razni paketi i pomoćni software-i, a temelji se na standardnom razvojnom okruženju HTML i CSS uz Javascript za interaktivnost i programsku logiku. Početna i informativne stranice su izrađene u Mobirise alatu za generaciju statičkih stranica kroz grafičko sučelje. Stranica upitnika i rezultata su pisane uz pomoć Bootstrap Frameworka nastalog u Twitteru. Za upitnik je korišteno Javascript library SurveyJS koji omogućuje brzu izradu upitnika te prijenos pitanja i odgovora u JSON obliku. Vizualizacije na stranici rezultata su rezultat ChartJS librarya koji je odabran zbog svojeg malog obujma te dizajnerskih kvaliteta bez prevelike potrebe za prilagodbu. Paket koji je također značajno korišten u skriptama je D3.js zbog svojih mogućnosti manipulacije podacima koje su bile potrebne za responzivne vizualizacije i mogućnosti filtriranja.

Flask back-end se sastoji od internog routing sistema koji je zadužen za obradu zahtjeva koji stižu na stranicu i unutar stranice. Drugi važni dio Python koda je skripta sa logikom sustava za preporuku. Unutar nje je korišteno Pandas proširenje zbog sličnih razloga kao D3.js u front-endu - olakšavanje obrade podataka.

Za verzijsku kontrolu koda je korišten Git standard odnosno Github kao poslužitelj servisa. Stranica je imala samo jednog autora tako da nisu korištene kolaboracijske mogućnosti koje nudi Github, ali je uvelike olakšao kontrolu koda te ispravljanje bugova pri uvođenju novih funkcionalnosti.

4.2.2 Produkcija

Za stavljanje stranice u Produkciju je bilo više mogućnosti. Kako je održavanje vlastitih server skup i vremenski zahtjevan posao te je trend da se svi veliki servisi baziraju na Cloudu, pala je odluka da se koristi jedan od specijaliziranih cloud servisa. Za razliku od generalnih cloud poslužitelja poput AWS-a ili Azurea, specijalizirani servisi nude olakšano sučelje za manje iskusne developere te su bolje integrirani sa automatiziranim deploymentom sa sustava za verzijsku kontrolu koda poput Githuba. Kako je Flask visoko rasprostranjen i poznat u razvojnim krugovima, postajale su mnoge opcije sa unaprijed

definiranom integracijom za web aplikacije baziranih na Flasku. Unutar ponude su se istaknuli PythonAnywhere i Heroku.

PythonAnywhere je Cloud poslužitelj koji se bazira, kako mu samo ime i kaže, na izvršavanju Python koda u Cloud infrastrukturi. Glavna prednost ovog servisa je specijaliziranost za Python kod te jednostavna integracija sa Flask aplikacijama. Heroku je u drugu stranu jedan od najstarijih PaaS servisa te je agnostičan na programski kod koji se koristi (dopušta korištenje velikog broja jezika uključujući Python). Za vrijeme razvoja se odabrao PythonAnywhere zbog lakog iterativnog lansiranja i testiranja pomoću Githuba. Kroz korištenje besplatnog razreda servisa su se pokazali mnogi nedostatci poput ne fleksibilnosti te slabe skalabilnosti. Nadalje servis u besplatnom razredu zahtjeva reaktivaciju stranice svakih 30 dana makar se u međuvremenu pokrenula nova iteracija ili je nadograđen kod stranice, što bi ujedno značilo da je aktivna. Upravo iz tih razloga za produkcijsku verziju stranice je odabran Heroku servis. Heroku nema limite korištenja te su stranice konstantno aktivne uz hibernaciju kad nisu pokrenute duži vremenski period. Glavno ograničenje besplatnog razreda je da ne prikazuje analitiku korištenja stranice. Kako je ovaj projekt zamišljen kao „one-off“ aplikacija bez konstantnog kontinuiranog razvoja, takvo ograničenje je bilo i više nego prihvatljivo. Nadalje Heroku je u vlasništvu jednih od najvećih softwarskih korporacija Salesforce-a, što znaci da ima stabilne financije te sigurnost dostupnosti servisa. Kad se tomu doda njegov status „starosjedioca“ među PaaS servisima, te velik broju zaposlenika, odabir Heroku-a za poslužitelja stranice u dugom roku je mnogo sigurniji odabir.

Aktivna instanca je vezana uz zadnji kod na glavnoj grani sustava za verzijsku kontrolu te tako osigurava da je dostupna stranica aktualna i da su ispravci bugova dostupni bez kašnjenja.

Stranica je dostupna na linku :

https://efzgsmjer.herokuapp.com/

Daljnji razvoj nije planiran osim u slučaju bug-a koji sprječava u potpunosti korištenje servisa. Ukoliko je netko zainteresiran za preuzeti razvoj i ulogu aktivnog održavača repozitorija može se obratiti autoru.

4.2.3 Lansiranje i feedback korisnika

U trenutku završetka prve produkcijske verzije stranice, pokrenuto je ograničeno beta testiranje na dobrovoljcima (studenti 3. godine EFZG-a) koji su pronađeni na društvenim mrežama. Na poziv se odazvalo 8 pojedinaca.

Svi dobrovoljci su dobili pristup stranici te obrazac sa 4 kategorije/pitanja gdje su trebali opisati svoje iskustvo korištenja stranice. Kategorije su bile:

- Dizajn i korisničko sučelje
- Korisničko iskustvo
- Rezultati
- Ostali komentari

Dizajn i korisničko sučelje

U području dizajna ispitanici su pretežito bili u potpunosti zadovoljni, uz jednog ispitanika koji je istaknuo da upitnik odstupa dizajnom od ostatka stranice te da je teško razaznati razlike medu redcima. Medu ispitanicima jednak broj ih je pristupio stranici preko mobitela kao i preko računala.

Korisničko iskustvo

U ovoj kategoriji su bili iznimno različita iskustva jer su neki ispitanici istaknuli brzo učitavanje stranice dok su drugi imali deset sekundno čekanje. Vezano za ostatak stranice, ispitanici su se složili da je jednostavna i intuitivna.

Rezultati

Ovo je bila vjerojatno i najvažnija kategorija. Od 8 ispitanika, 6 je istaknulo da su preporučeni smjerovi izvrsno opisali njihove afinitete, jedan smatra da postoji korelacija, , ali da se ne slaže sa rezultatima dok jedan ispitanik smatra da je u potpunosti pogrešna preporuka. Nadalje većina ispitanika je ocijenila procjenu njihove osobnosti kao zadovoljavajuću. Tu treba istaknuti da su ispitanici pokazali pozitivan stav prema greškama u procjeni osobnosti uslijed malog broja pitanja u upitniku.

Ostalo

Svi ispitanici su pokazali podršku prema projektu te smatraju da može pružiti vrijednosti studentima na fakulteti. Od ostalih komentara je istaknuta zelja za detaljnijim upitnikom i rezultatima te većim brojem alumnija za specifičnije rezultate.

Komentari iz testiranja su uzeti u obzir te je dodatno razrađen dizajn stranice upitnika. Nažalost razlika u učitavanju stranice je rezultat besplatne verzije Heroku servisa. Stranica kad nije pristupljena duži period odlazi u hibernaciju. Što se period hibernacije povećava ona pada dalje u rang listi stranica u hibernaciji te joj je potrebno duže da se ponovno pokrene. Ipak kako je ispitanik istaknuo da ga nije to omelo u korištenju stranica, ovaj nedostatak je uzet kao prihvatljiv. Završno, rezultati su bili prihvaćeni iznimno pozitivno uz iznimke. Kako je ovo ipak sustav za preporuku koji ne može biti pregranularan da bi izbjegnuo pristranosti, testiranje se smatralo uspješnim te je stranica, uz manje preinake, pustena u javnost.

Objava o dostupnosti stranice je puštena kroz društvene mreže te je skupila preko 450 reakcija i 20 komentara. Komentari su bili ili podrška razvoju aplikacije ili informiranje prijatelja o dostupnosti aplikacije. Kako su podaci o korištenju stranice nažalost nedostupni u besplatnom razredu Heroku servisa ne mogu se odrediti točne brojke korisnika, ali se može sa visokom sigurnošću reci da je samo u prvoj godini postojanja stranicu koristio troznamenkasti broj studenata što autor smatra apsolutnim uspjehom.

U nastavku slijedi prezentacija stranice uz detaljnu obradu sadržaja i funkcionalnosti.

4.3 Web stranica/aplikacije EFZG smjer

U svrhu provjere efikasnosti sustava za preporuku smjera izrađena je web aplikacija EFZG smjer.

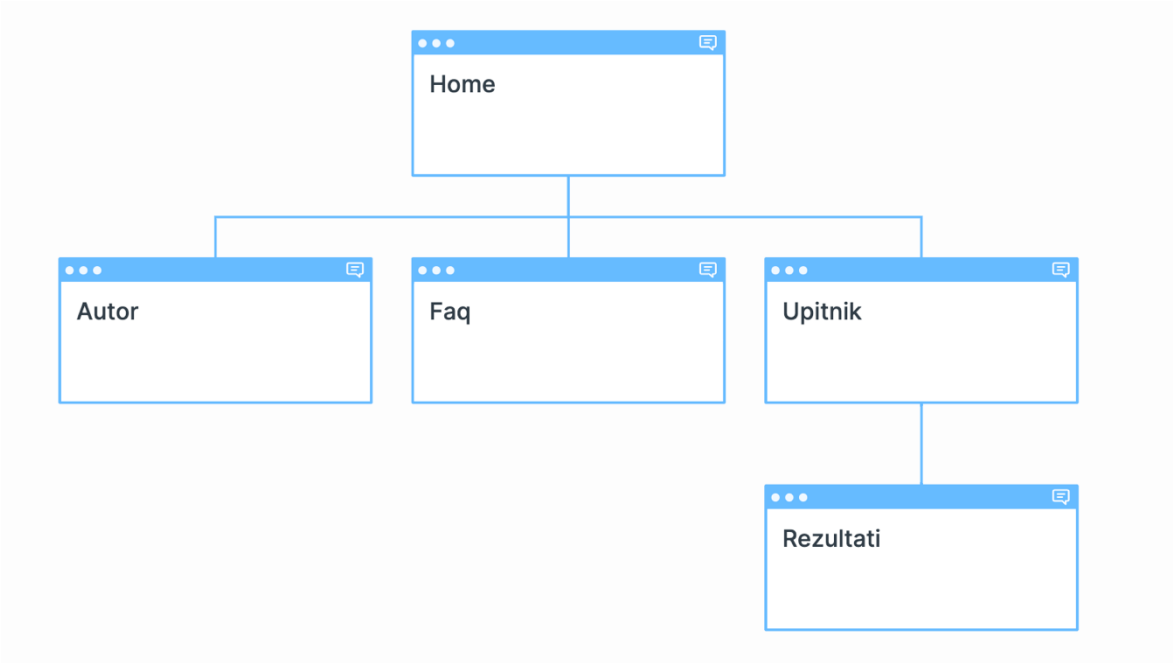
Slika 2 Logo aplikacije



Izvor: izrada autora

Aplikacija ima jednostavne funkcionalnosti, student se može informirati više o samoj aplikaciji na početnoj stranici i stranicama informacija, te ispuniti upitnik koji ga vodi na stranicu sa prikazima rezultata.

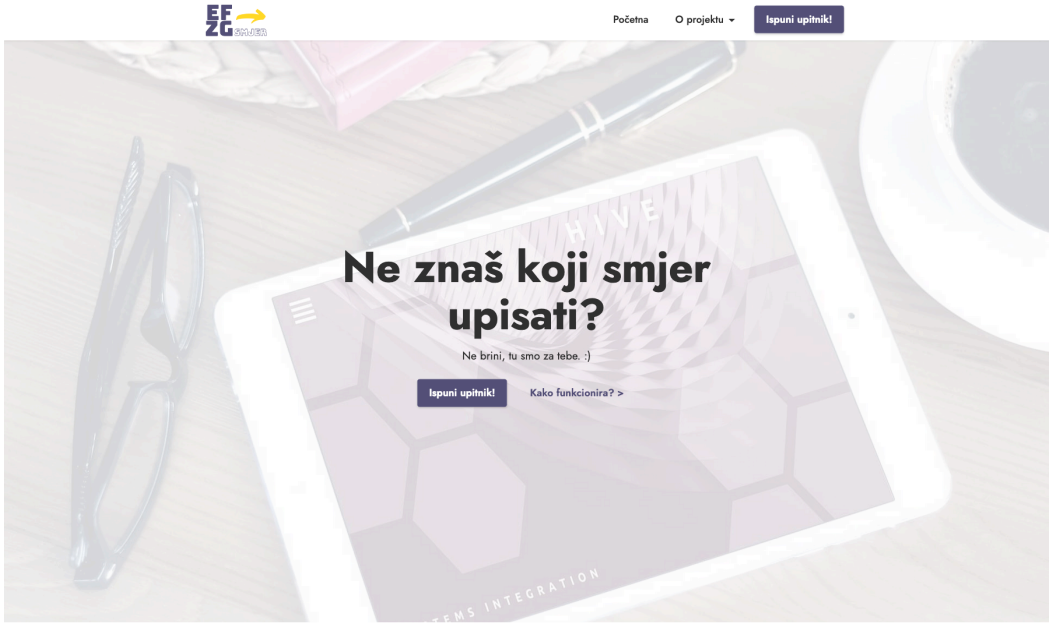
Slika 3 Site Mapa Stranice



Izvor: Izrada autora

Indeksna odnosno uvodna stranica daje kratki uvid u samu web aplikaciju i sustav za preporuku. Kroz nju se korisnik može usmjeriti na sve ostale stranice web aplikacije.

Slika 4 Uvodna stranica



O čemu se radi?

Svi znamo koliko je teško odabrati diplomski smjer. To je jedna od onih odluka o kojoj ti ovisi naredne 2 godine života. Kako bismo ti olakšali tu situaciju napravili smo posebnu aplikaciju koja će ti reći što su ljudi najsličniji tebi upisali te kako su oni zadovoljni svojim smjerom!

No kako funkcionira aplikacija?

Nakon što ispuniš upitnik, tvoje odgovore ćemo usporediti sa odgovorima Alumnija u našoj bazi te pronaći pojedince najsličnije tebi, te ćemo ti pokazati nihove ocjene smjerova koje su završili.

Kako uspoređujemo pojedince?

Osobnost

Jesi li čuo za Big Five osobine? Pomoću upitnika ćemo odrediti kakva je tvoja osobnost po najistraživanijoj psihološkoj metodologiji.

Interesi

Hollandovim model karijernih interesa odredit ćemo kakve stvari ti najbolje leže. Jesi li više umjetnički tip ili preferiraš brojke i računala?

Akademske sklonosti

Dio svakog studija su svakako i predmeti koje polažeš. Na temelju tvojih dojmova dosadašnjih kolegija vidjet ćemo što ti najviše leži.

Više od 400 alumnija je ispunilo upitnik!

U našem datasetu je veliki broj različitih pojedinaca koji su završili Ekonomski Fakultet u Zagrebu. Sigurni smo da ćeš pronaći nekolicinu sebi sličnih.

Što ćeš saznati?

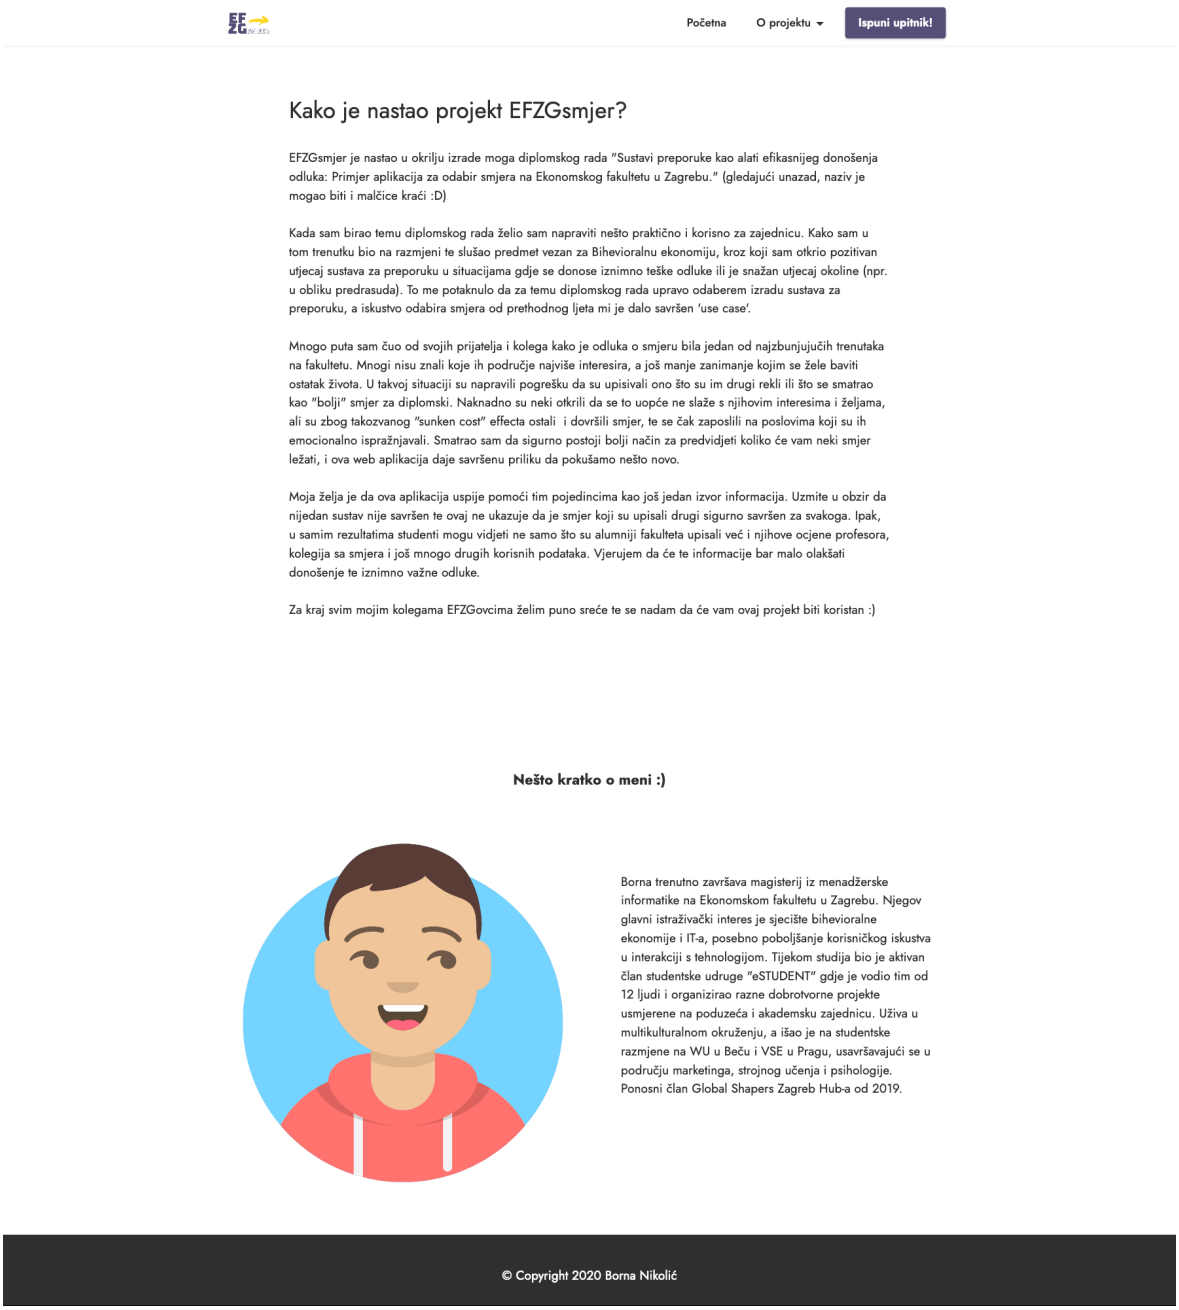
- **Svoj osobni psihološki profil.** Otkrij svoju osobnost. Saznat ćeš kako stojiš na skalama za Otvorenost, Savjesnost, Ekstroverziju, Ugodnost i Neuroticizam.
- **Preporuku smjera.** Temeljem usporedbe s alumnijima iz naše baze otkriti ćemo ti koje su smjerove upisali tebi karakterno najsličnije osobe.
- **Personalizirani podaci o smjeru.** Kada pronađemo te pojedince, napravit ćemo ti malu statističku analizu na kojoj ćeš moći vidjeti kako su oni zadovoljni svojim smjerovima.

Što čekaš, ispuni upitnik! :D

Izvor: efzgsmjer.herokuapp.com

Informativne stranice su stranice pod meni stavkom O projektu. Prva je Riječi Autora koja sadrži kratko pismo autora korisnicima gdje objašnjava razvoj projekta te daje njegov životopis u kratkim crtama.

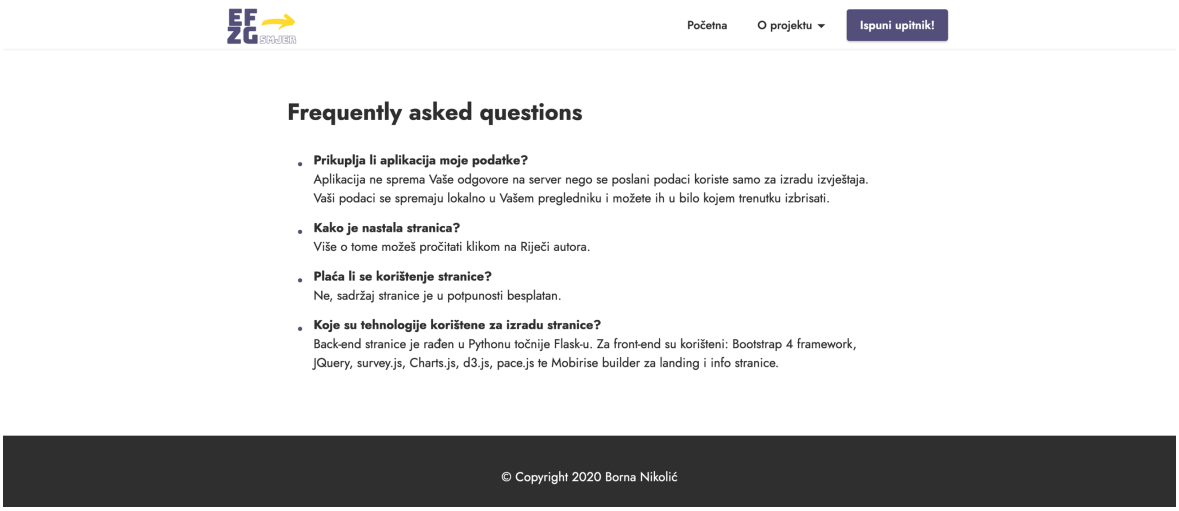
Slika 5 Stranica Rijeci Autora



Izvor: efzgsmjer.herokuapp.com

Druga informativna stranica je stranica sa najčešćim pitanjima te je ona središnje mjesto za sva korisnička pitanja.

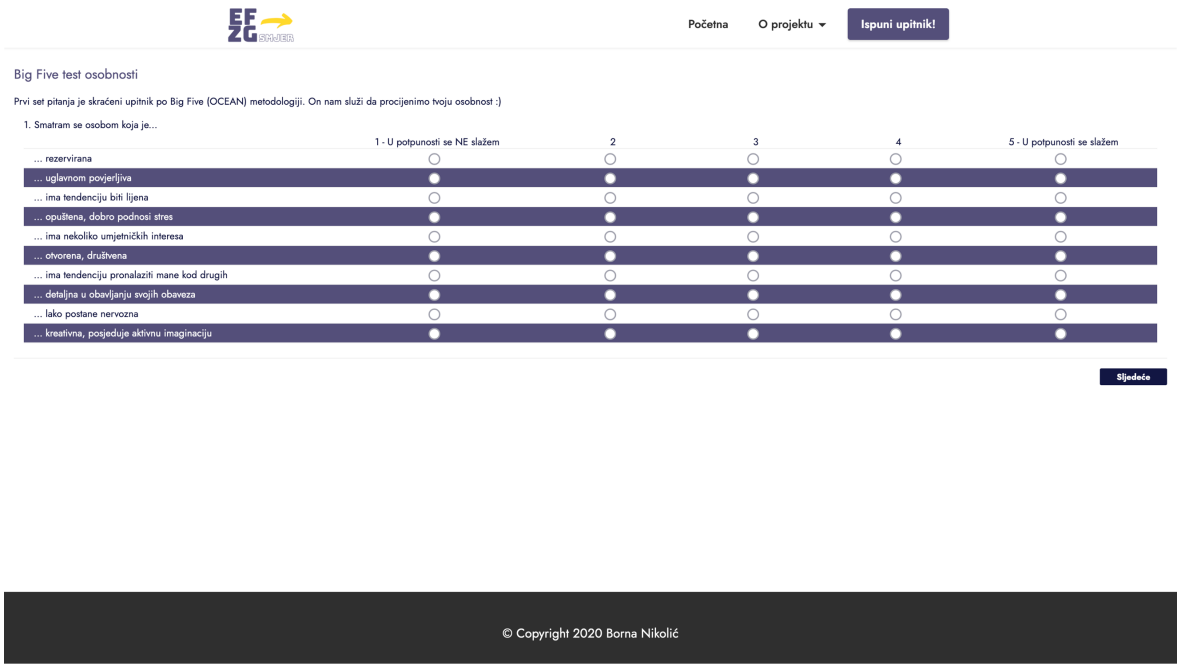
Slika 6 Stranica sa Najčešćim pitanjima



Izvor: efzgsmjer.herokuapp.com

Zadnje dvije stranice su ključne za samu funkcionalnost. Prva je stranica sa upitnikom gdje korisnik ispunjava 3 seta pitanja koja služe za određivanje njegove osobnosti i interesa.

Slika 7 Stranica sa upitnikom (Prvi od 3 seta pitanja)

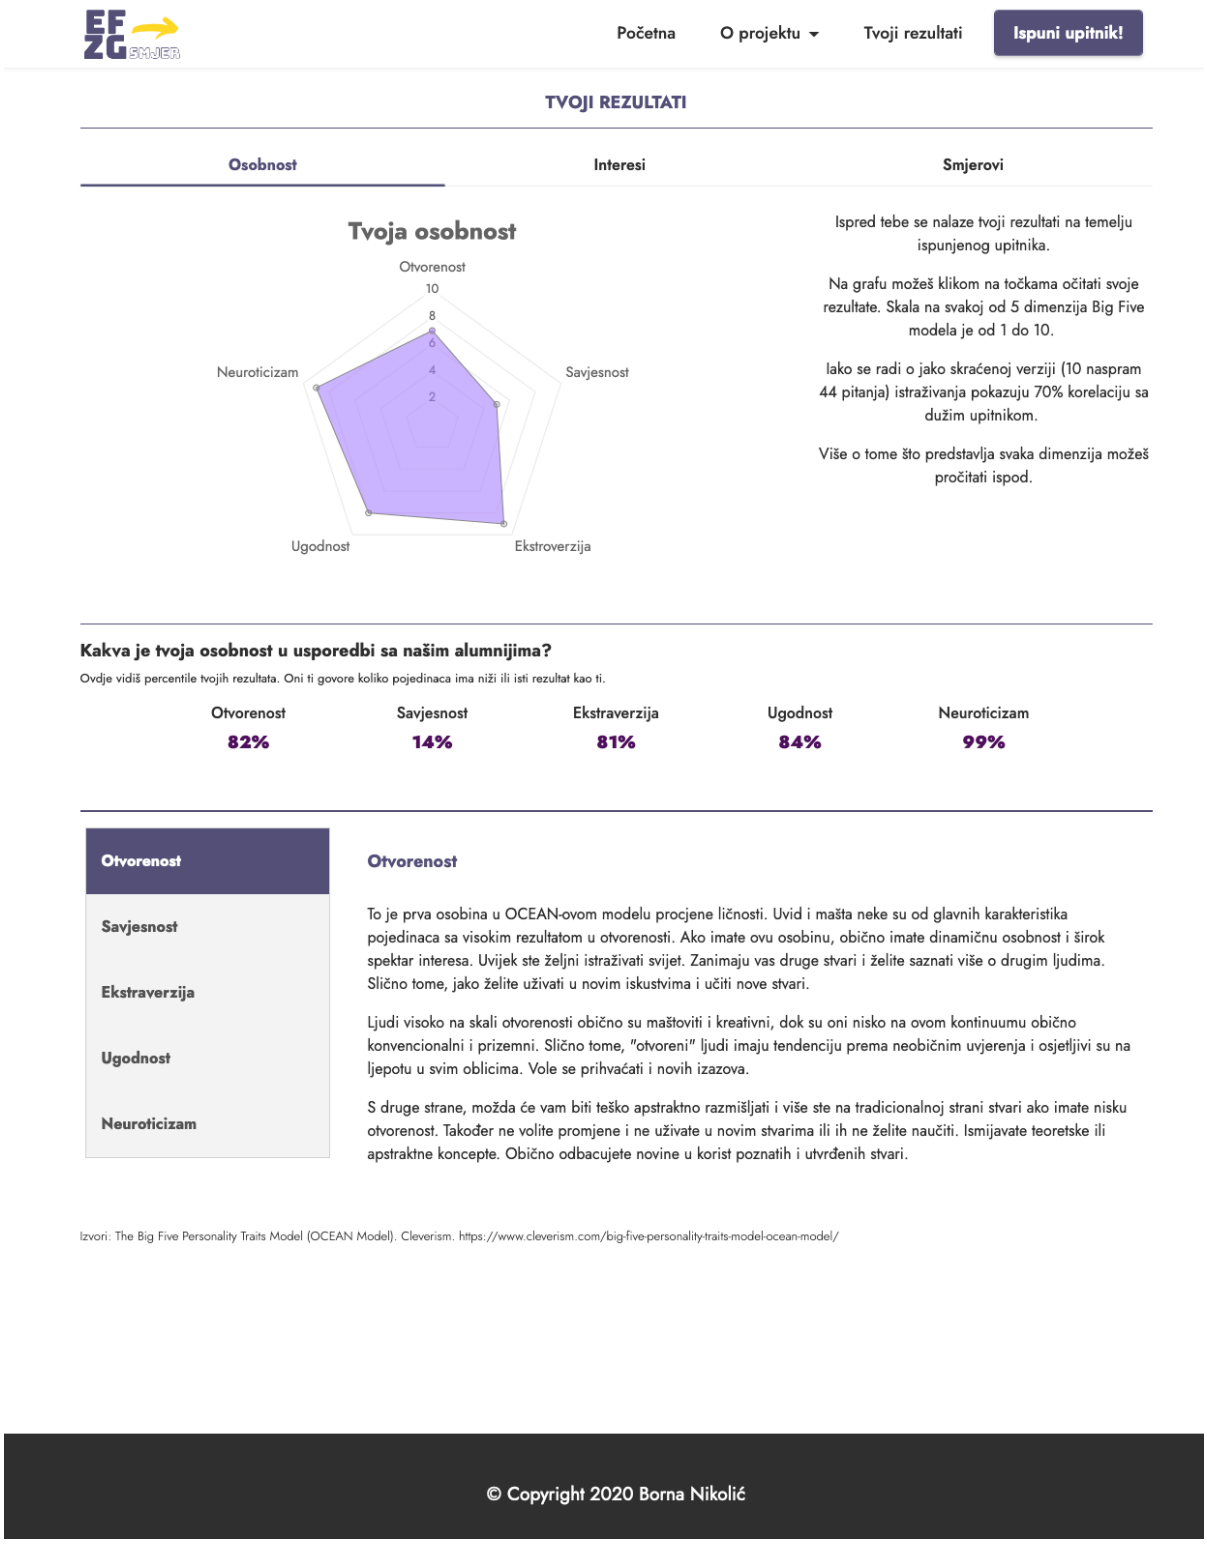


Izvor: efzgsmjer.herokuapp.com

Ovaj upitnik je istovjetan onome koji su ispunjavali alumniji smjera izuzev dijela o iskustvima sa smjerom.

Nakon što korisnik ispuni upitnik, on bude usmjeren na stranicu sa rezultatima. Na ovoj stranici korisnik ima na raspolaganju 3 kartice koje daju rezultate njegovog upitnika. Prva kartica se zove Osobnost te se na njoj nalazi Radial graf sa Big Five dimenzijama. Svaka od 5 dimenzija: Ekstraverzija, Otvorenost, Savjesnost, Empatija i Neuroticizam su ocijenjene na skali od 1 do 10. Student se nadalje može informirati o svakoj dimenziji: što znače te kakve tendencije imaju osobe visoko ocijenjene u pojedinim dimenzijama. Završno student može vidjeti svoje percentile usporedno sa rezultatima svih alumnia u bazi, odnosno od koliko posto alumnija je više ocijenjen u pojedinim dimenzijama.

Slika 8 Rezultati iz osobnosti



Izvor: efzgsmjer.herokuapp.com

Druga kartica sadrži rezultate o karijernim interesima temeljene na Hollandovim kodovima.

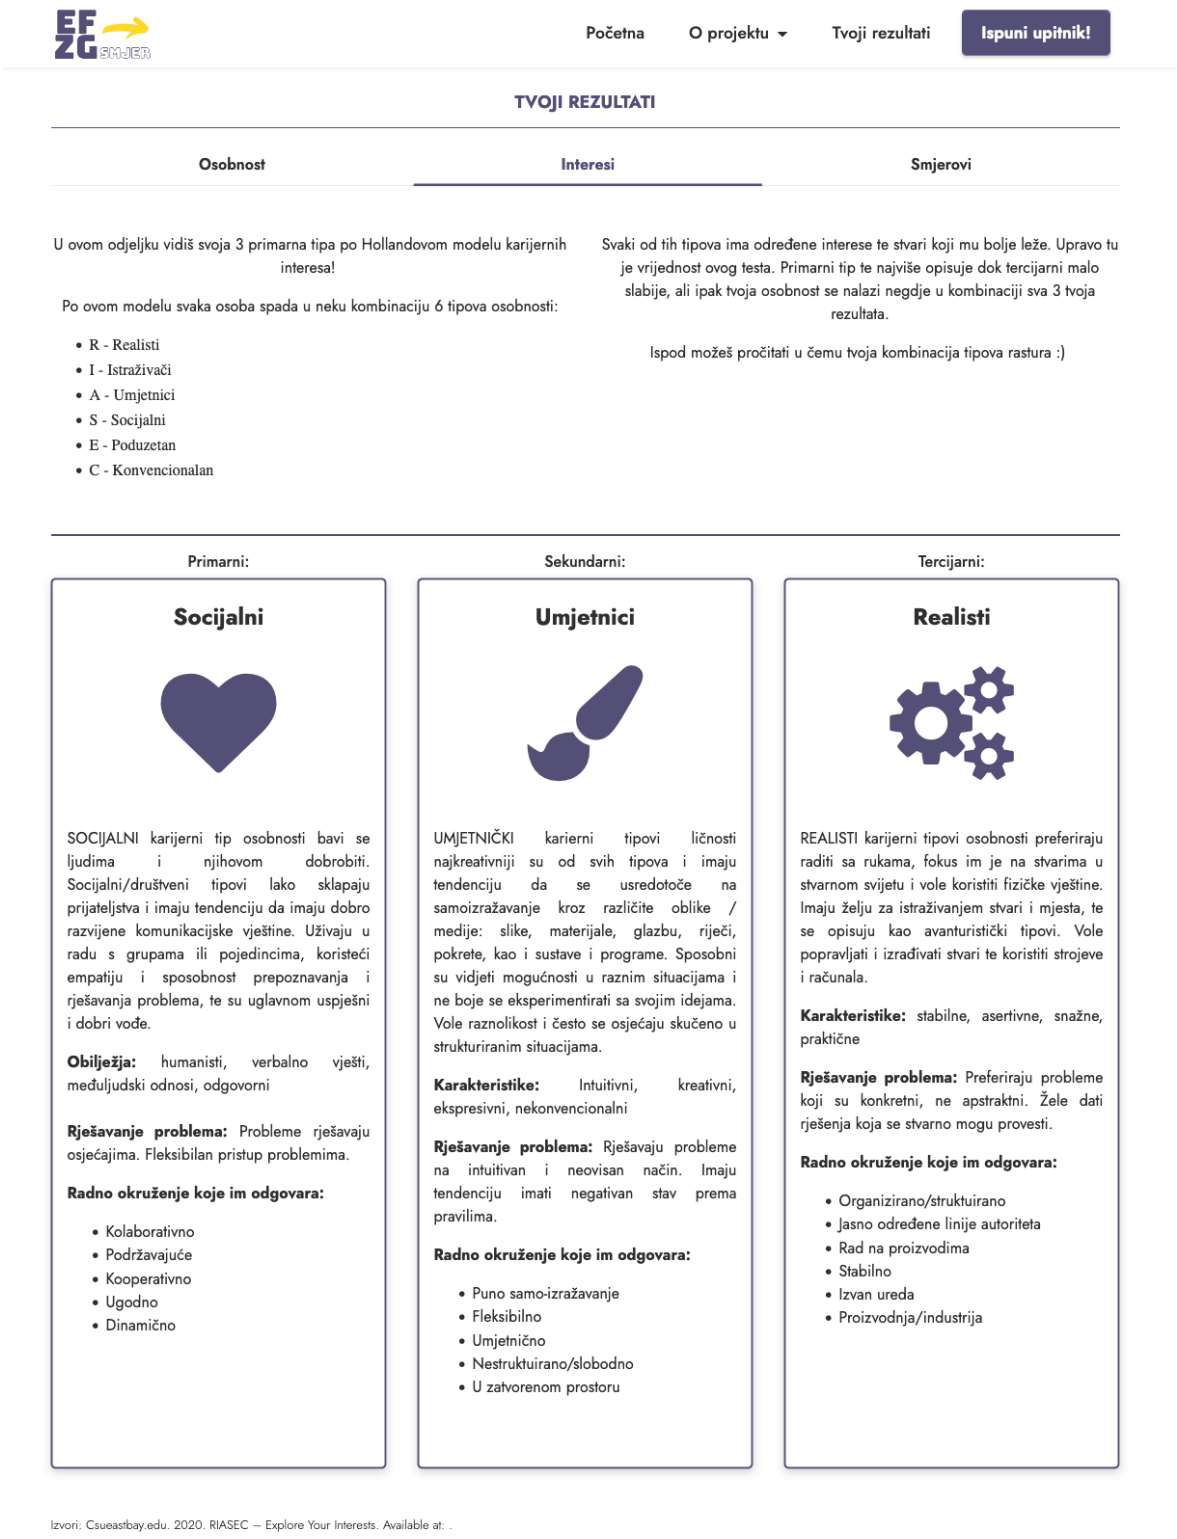
Prema Hollandovom RIASEC modelu svaka osoba se može svrstati u neku kombinaciju ovih šest karijerno-interesnih tipova:

- R – Realisti
- I - Istraživači
- A - Umjetnici
- S - Socijalni
- E - Poduzetan
- C – Konvencionalan

Svaki pojedinac ima Primarni, Sekundarni i Tercijarni tip koji čine njegovu kombinaciju te su rangirani po snazi utjecaja na osobni tip ispitanika.

Student se može informirati ukratko o RIASEC teoriji te su mu predstavljeni njegovi kombinatorni tipovi u obliku kartica. Za svaki tip može pročitati opis, što ga obilježava, kako pristupa rješavanju problema te kakvo mu radno okruženje odgovara.

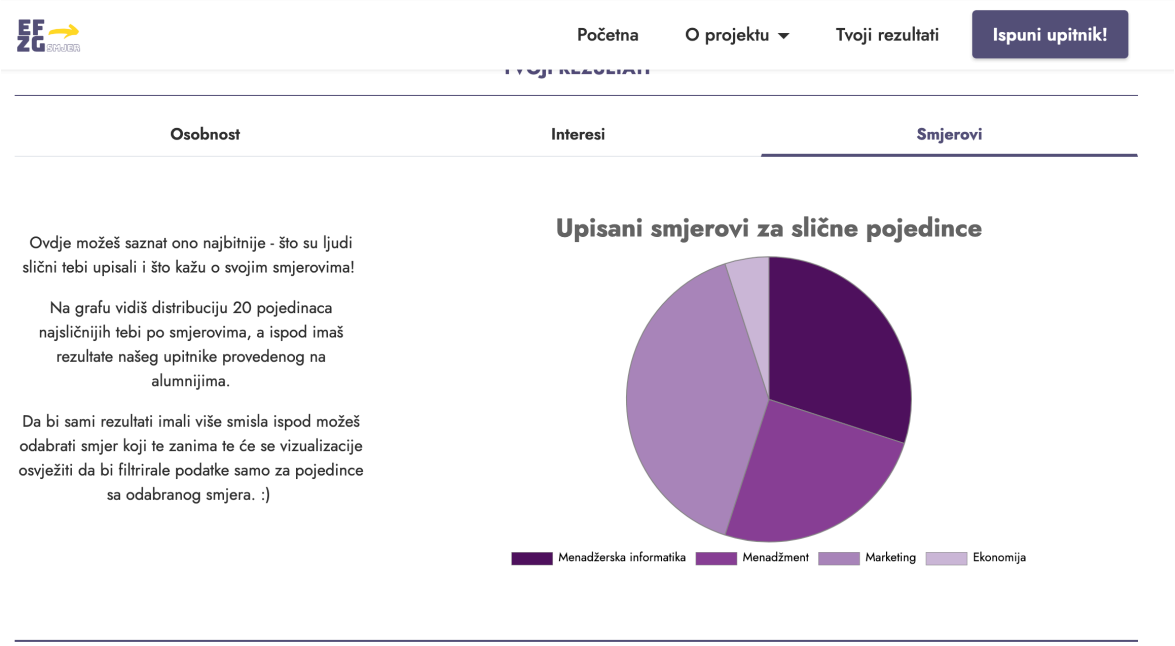
Slika 9 Stranica sa rezultatima o Interesima



Izvor: efzgsmjer.herokuapp.com

Zadnja kartica je ujedno i najvažnija jer prezentira rezultate vezane uz alumnije. Prve dvije kartice su se temeljile samo na osobnim odgovorima u upitniku samom studenta, dok zadnja kartica koristi sličnost studenta sa alumnijima u bazi, odnosno filtrira cjelokupnu bazu te pronalazi 20 alumnija najsličnijih samom studentu te prikazuje rezultate upitnika upravo tih alumnija. Prva informacija dostupna studentu je vjerojatno i najtraženija, a to je koje su smjerove najsličniji alumniji upisali.

Slika 10 Kartica Smjer - gornji dio



Izvor: efzgsmjer.herokuapp.com

Svi grafikoni na ovim stranicama su interaktivni i responzivni tako da student može pronaći apsolutne brojke po smjerovima tako da postavi miš iznad područja grafikona koji ga interesira ili pritisne prstom na mobilnom uređaju.

Kako je dokazano da nije uvijek najbolje pratiti slijepo većinu zato se u nastavku nalaze odgovori alumnija na pojedinačna pitanja iz upitnika kako bi student mogao dobiti što dublji uvid u iskustva alumnija. Za procjenu mu je dostupan i padajući izbornik gdje može odabrati smjer koji ga zanima te dodati smjer sa kojim ga želi usporediti. Zatim na vizualizacijama može vidjeti rezultate samo ta dva smjera.

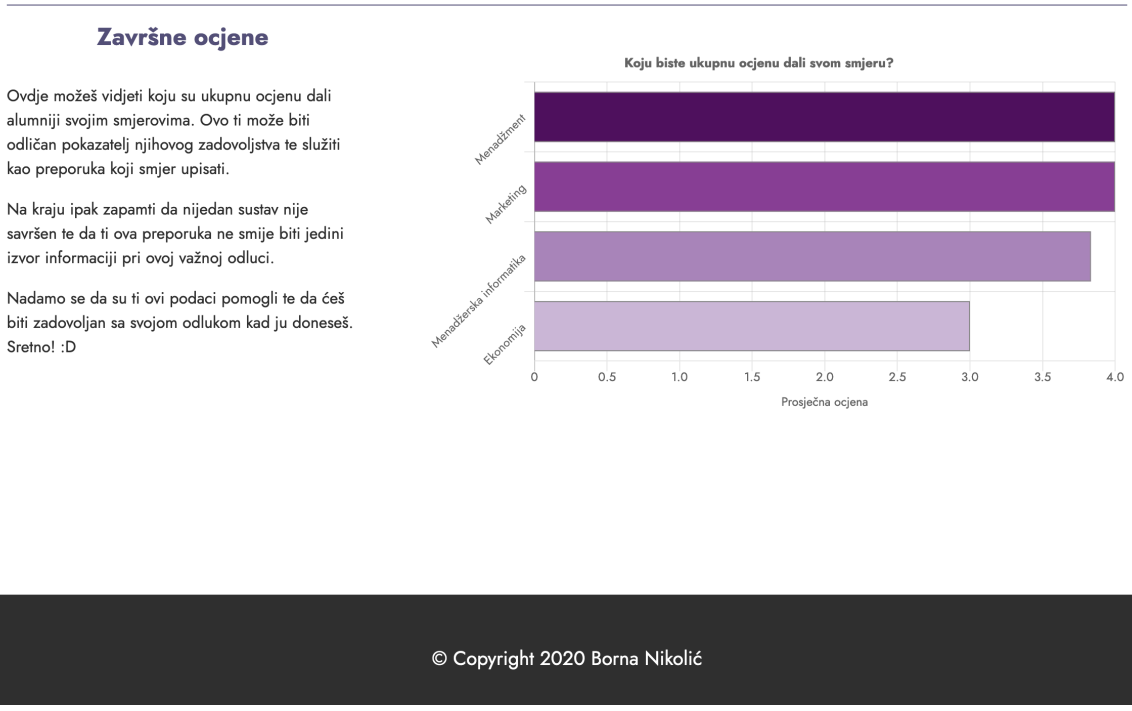
Slika 11 Kartica Smjer - Središnji dio: Upitnik



Izvor: efzgsmjer.herokuapp.com

Završni dio kartice je grafikon sa prosječnom ocjenom koju su alumniji dali svojim alumnijima. To u kompletu sa brojem ljudi koji su upisali smjer (prvi grafikon) može služiti kao kratka preporuka te usmjeriti studenta koje smjerove dodatno usporediti.

Slika 12 Kartica Smjer - donji dio



Izvor: efzgsmjer.herokuapp.com

5 Zaključak

Donošenje odluka je područje koje u dosadašnjim znanstvenim istraživanjima kontinuirano donosi nove zanimljive spoznaje. Ta saznanja vode do inovacija u industriji i kako pristupamo složenim problemima. Znanstvenici su još u sedamdesetim godinama prošlog stoljeća počeli promatrati nekonzistentnosti u načinu na koji pojedinci donose i racionaliziraju svoje odluke. Glavni uzročnik tih grešaka u odlučivanju je ljudska potreba za pojednostavnjenjem ogromne količine informacija koje moraju procesuirati da bi donijela neku odluku. Iz tog limitiranog kapaciteta su nastale heuristike, mentalni prečaci pri obradi informacija, koje iako su olakšale donošenje odluka, najčešće vode do prije spomenutih greški u odlučivanju koje znanstvenici nazivaju kognitivne pristranosti. Nadalje znanstvenici su primijetili da pojedinci predvidljivo reagiraju na situacije u kojima se pred njima nalaze veliki broj potencijalnih opcija te da tad najčešće naprave suboptimalne odluke samo da bi izbjegli mentalni napor usporedbe svih dostupnih kombinacija.

Ta problematika nije izolirana samo na kupovne situacije, već se može promatrati i u obrazovnom kontekstu kroz situacije gdje studenti biraju predmete i smjerove visokog obrazovanja. Zanimljivo je to da studenti sa različitih akademskih grana drukčije rangiraju faktore koji su im bitni pri odabiru smjera obrazovanja. Studenti društvenih fakulteta su posebno skloni biti motivirani eksternim faktorima, poput prestiža fakulteta ili lakoće pronalaska posla nakon studija. Kako su ti faktori rezultat informacija koje dobiju iz okoline, te takvi izvori ne mogu nikad u potpunosti reprezentativno predstavljati stvarnu situaciju, oni su naročito u opasnosti da padnu pod utjecaj mentaliteta krda - efekta gdje pojedinac radi ono što radi okolina makar to ne mora biti najbolje za njega samoga. Tom negativnom efektu se može suprotstaviti većom razinom informacija kod samog donositelja odluke, ali tu dolazi do ponovnog problema da pojedinci teško obrađuju takvu količinu podataka. Kao jedno od potencijalnih rješenja se nude specijalizirani sustavi za preporuku koji filtriraju informacije te ih prezentiraju korisniku u lako obradivom obliku.

Da bismo ispitali efikasnost takvog sustava autor je odlučio napraviti sustav za preporuku diplomskog smjera na Ekonomskog Fakultetu u Zagrebu. Kroz pripremna istraživanja pokazalo se da smjerovi imaju različite upisne tendencije. Određeni smjerovi su imali signifikantno više visoko ocijenjenih studenata iako nisu bili znatno više ocijenjeni po

dimenziji privlačnosti. Nastavna obrada podataka je pokazala isto tako da postoje razlike u tome kako studenti percipiraju da okolina ocjenjuje privlačnost smjerova. Smjerovi koji su bili pozitivnije ocijenjeni u očima studenata od okoline su imali i više upisne brojke naprema slično ocijenjenim smjerovima sa lošijom percepcijom kod okoline. Da bi se izbjegao taj negativan utjecaj mentaliteta krda i predrasuda, sustav je morao neutralizirati takve negativne eksterne faktore. Temelj izrađenog sustava su bila iskustva alumnija samog fakulteta. Sustav na temelju psihološkog upitnika pronalazi 20 najsličnijih alumnija samom studentu (po dimenzijama osobnosti, interesima te preferencijama na fakultetu) te studentu prezentira što su ti alumniji upisali te koliko su zadovoljni. Ovakav sustav ima prednost da studentu sužava „okolinu“ odluke na pojedince koji su njemu najrelevantniji (odnosno najsličniji). Time student i dalje dobiva prednosti društvenog učenja, učenja od iskustva drugih u okolini, bez toga da predrasudne informacije mute njegov proces odlučivanja. Predstavljena aplikacija je dobila pozitivne ocijene od testnih korisnika te je privukla znatan interes na društvenim mrežama. To pokazuje da studenti imaju potrebu za ovakvim oblikom informiranja o smjerovima, te da vide korist u usporednim iskustvima sličnih alumnija njima samima.

Ovaj primjer nam dokazuje da inovativni sustavi za preporuku mogu iznimno olakšati donošenje odluka u raznim kontekstima, uključujući i obrazovanje. Obrazovne institucije moraju više istraživati kako njihovi studenti biraju predmete i smjerove te im ponuditi najprihvatljivije oblike informiranja koji će im olakšati optimalno donošenje odluke. To će rezultirati u višestruko pozitivnim efektima – studenti će ostvariti veći uspjeh, a obrazovne institucije će optimizirati distribuciju studentske populacije na više ponuđenih specijalizacija.

POPIS LITERATURE

1. Al-Badarenah A. i Alsakran J. (2016.), An automated recommender system for course selection, *International Journal of Advanced Computer Science and Applications* , 7(3), 166-17. http://dx.doi.org/10.14569/IJACSA.2016.070323

2. Aljukhadar, M., Senecal, S. i Daoust, C.-E. (2012.), Using Recommendation Agents to Cope with Information Overload, *International Journal of Electronic Commerce,* 17(2), 41-70. https://doi.org/10.2753/JEC1086-4415170202

3. Ambiel, R. A. M., Hauck-Filho, N., Barros, L. de O., Martins, G. H., Abrahams, L., i De Fruyt, F. (2018.), 18REST: a short RIASEC-interest measure for large-scale educational and vocational assessment, *U Psicologia: Reflexão e Crítica,* 31(1). https://doi.org/10.1186/s41155-018-0086-z

4. Aparicio, D. i Prelec, D. (2018.), Choice Overload in Online Platforms. SSRN 3044096

5. Aryani, F., & Umar, N. (2020), Factors Affecting Z Generation on Selecting Majors in The University: an Indonesian Case, *Journal of Social Studies Education Research,* 11(3), 109-133.

6. Balsamo, M., Lauriola, M., & Saggino, A. (2012.), Personality and College Major Choice: Which Come First? *U Psychology*, 3(5), 399–405. https://doi.org/10.4236/psych.2012.35056

7. Banerjee, A. (1992.) A Simple Model of Herd Behavior, *Quarterly Journal of Economics*, 107(3), 797-817.

8. Caprara, G. V., Schwartz, S., Capanna, C., Vecchione, M., i Barbaranelli, C. (2006.), Personality and politics: values, traits, and political choice, *Political Psychology*, 27, 1-28. https://doi.org/10.1111/j.1467-9221.2006.00447.x

9. Chernev, A., Böckenholt, U. i Goodman, J. (2015.), Choice overload: A conceptual review and meta-analysis, *Journal of Consumer Psychology,* 25(2), 333–358. https://doi.org/10.1016/j.jcps.2014.08.002

10. Chernev A. i Hamilton R. (2009.), Assortment size and option attractiveness in consumer choice among retailers, *Journal of Marketing Research*, 17(2), 41–70. https://doi.org/10.2753/JEC1086-4415170202

11. De Fruyt, F. i Mervielde, I. (1996.), Personality and interests as pre-dictors of educational streaming and achievement, *European Journal of Personality*, 10, 405-425. https://doi.org/10.1002/(SICI)1099-0984(199612)10:5<405::AID-PER255>3.0.CO;2-M

12. Dhar R. i Simonson I. (2003.), The effect of forced choice on choice. *Journal of Marketing Research,* 4, 146–160. https://doi.org/10.1509/jmkr.40.2.146.19229

13. Galotti, K. M. (2007.), Decision structuring in important real-life decisions, *Psychological Science*, 18, 320-325. https://doi.org/10.1111/j.1467-9280.2007.01898.x

14. George G. i Lal A. M. (2019.), Review of ontology-based recommender systems in e-learning, *Computers & Education*, 142. https://doi.org/10.1016/j.compedu.2019.103642

15. Grayot, J. D. (2019.), Dual Process Theories in Behavioral Economics and Neuroeconomics: a Critical Review, *Review of Philosophy and Psychology*, 11(1), 105–136. https://doi.org/10.1007/s13164-019-00446-9

16. Holland, J. L. (1985.), *Making vocational choices: A theory of vocation personalities and work environments*, Englewood Cliffs, NJ: Prentice Hall.

17. Holland, J. L. (1996.), Exploring careers with a typology what we have learned and some new directions, *American Psychologist*, 51, 397- 406. https://doi.org/10.1037/0003-066X.51.4.397

18. Holland, J. L. (1997.), *Making vocational choices: A theory of vocational personalities and work environments*, 3. izdanje, Odessa, FL: Psychological Assessment Resources

19. Inbar Y., Botti S. i Hanko K. (2011.), Decision speed and choice regret: When haste feels like waste, *Journal of Experimental Social Psychology*, 47, 533–540 https://doi.org/10.1016/j.jesp.2011.01.011

20. Insler M., Rahman A.S. i Smith K. (2021.), Tracking the Herd with a Shotgun — Why Do Peers Influence College Major Selection?, preuzeto 20.08.2021. s https://www.iza.org/publications/dp/14412/tracking-the-herd-with-a-shotgun-why-do-peers-influence-college-major-selection

21. Iyengar, S. S. i Lepper, M. R. (2000.), When choice is demotivating: Can one desire too much of a good thing?, *Journal of Personality and Social Psychology*, 79(6), 995–1006. https://doi.org/10.1037/0022-3514.79.6.995

22. Jomsri P (2018.), FUCL mining technique for book recommender system in library service, *Procedia Manufacturing*, 22, 550-557. https://doi.org/10.1016/j.promfg.2018.03.081

23. Kahneman, D. (2011.), *Thinking, fast and slow*, Farrar, Straus and Giroux.

24. Kahneman, D. i Tversky, A. (1979.), Prospect Theory: An Analysis of Decision under Risk, *Econometrica*, 47(2), 263. https://doi.org/10.2307/1914185

25. Kapeller, J., Schütz, B. i Steinerberger, S. (2012.), The impossibility of rational consumer choice, *Journal of Evolutionary Economics*, 23(1), 39–60. https://doi.org/10.1007/s00191-012-0268-2

26. Kazi, A. S. i Akhlaq, A. (2017.), Factors Affecting Students' Career Choice, *Journal of Research and Reflections in Education*, 2, 187–196. http://www.ue.edu.pk/jrre

27. Lent, R. W., Brown, S. D. i Hackett, G. (2000.), Contextual supports and barriers to career choice: A social cognitive analysis, *Journal of Counseling Psychology*, 47(1), 36–49. https://doi.org/10.1037/0022-0167.47.1.36

28. Li L. H., Hsu R. W. i Lee F. M. (2012.), Review of Recommender Systems and Their Applications, *International Journal of Adv. Information Technology*, 63–87

29. Lynn, N. D. i Emanuel, A. W. R. (2021.), A review on Recommender Systems for course selection in higher education, *U IOP Conference Series: Materials Science and Engineering,* 198(3), 32-39. https://doi.org/10.1088/1757-899x/1098/3/032039

30. Mas-Colell A., Whinston M.D. i Green J.R. (1995.), *Microeconomic theory*, Oxford University Press, New York

31. Moretti, E. (2008.), Social Learning and Peer Effects in Consumption: Evidence from Movie Sales, *Review of Economic Studies*, 78(1): 356-393.

32. Nagar, K. i Gandotra, P. (2016.), Exploring Choice Overload, Internet Shopping Anxiety, Variety Seeking and Online Shopping Adoption Relationship: Evidence from Online Fashion Stores, *Global Business Review*, 17(4), 851–869. https://doi.org/10.1177/0972150916645682

33. Oppewal H. i Koelemeijer K. (2005.), More choice is better: Effects of assortment size and composition on assortment evaluation, *International Journal of Research in Marketing*, 22, 45–60. https://doi.org/10.1016/j.ijresmar.2004.03.002

34. Rammstedt, B. i John, O.P. (2007.), Measuring personality in one minute or less: A 10-item short version of the Big Five Inventory in English and German, *Journal of Research in Personality*, 41. https://doi.org/10.1016/j.jrp.2006.02.001

35. Savage L. J. (1972.), *The foundations of statistics*, Dover, New York

36. Tversky, A. i Kahneman, D. (1974.), Judgment under Uncertainty: Heuristics and Biases, *Science*, 185(4157), 1124–1131. https://doi.org/10.1126/science.185.4157.1124

37. Tversky, A. i Kahneman, D. (1981.), The framing of decisions and the psychology of choice. *Science*, 211(4481), 453–458. https://doi.org/10.1126/science.7455683

38. Varian H. R. (1992.), *Microeconomic analysis*, Norton, New York

39. Wakil K., Bakhtyar R., Ali K. i Alaadin K. (2015.), Improving web movie recommender system based on emotions, *International Journal of Advanced Computer Science and Applications* 6(2) 218-226. https://doi.org/10.14569/IJACSA.2015.060232

40. Wang D., Liang Y., Xu D., Feng X i Guan R. (2018.), A content-based recommender system for computer science publications, *Knowledge-Based Systems*, 157, 1-9. https://doi.org/10.1016/j.knosys.2018.05.001

POPIS TABLICA

Tablica 1 Sumarna statistika za prosjek ocjena po smjerovima 23

Tablica 2 Rezultati Games-Howell post-hoc testa 28

Tablica 3 Ocjene privlačnosti smjerova 34

POPIS GRAFIKONA

Grafikon 1 Distribucija ispitanika po spolu 20

Grafikon 2 Distribucija ispitanika po dobi 21

Grafikon 3 Distribucija ispitanika po upisanoj godini 22

Grafikon 4 Stariji studenti po upisanom smjeru 22

Grafikon 5 Q-Q plot ANOVA analize prosječne ocjene 25

Grafikon 6 Grafikon reziduala i vrijednosti Anova test o prosječnim ocjenama 26

Grafikon 7 Motivatori upisa smjera 30

Grafikon 8 Izvori informacija o smjerovima 32

Grafikon 9 Postotak studenata sa odabranim smjerom po godinama studija 36

Grafikon 10 Distribucija alumnija po smjerovima 39

POPIS SLIKA

Slika 1 Dijagram sustava za preporuku 43

Slika 2 Logo aplikacije 52

Slika 3 Site Mapa Stranice 53

Slika 4 Uvodna stranica 54

Slika 5 Stranica Rijeci Autora 55

Slika 6 Stranica sa Najčešćim pitanjima 56

Slika 7 Stranica sa upitnikom (Prvi od 3 seta pitanja) 57

Slika 8 Rezultati iz osobnosti 58

Slika 9 Stranica sa rezultatima o Interesima 60

Slika 10 Kartica Smjer - gornji dio 61

Slika 11 Kartica Smjer - Središnji dio: Upitnik 62

Slika 12 Kartica Smjer - donji dio 63

ŽIVOTOPIS STUDENTA



europass

Borna Nikolić

borna.nikolic@outlook.com | https://www.linkedin.com/in/borna-nikolic/

RADNO ISKUSTVO

01/07/2021 – TRENUTAČNO – Salzburg, Austrija
PRODUCT ENGINEERING GRADUATE – RED BULL

- Izrada dashboarda i ad hoc izvjestavanje u raznim tehnologijama - R (Shiny), BigQuery (Data Studio)
- UX research
- Razvoj web aplikacija

01/06/2019 – 01/12/2019
BUSINESS AND PLATFORM SOLUTIONS INTERN – ATOS IT SOLUTIONS AND SERVICES

- Razvoj ETL procesa (Pentaho Data Integration)
- Poslovna analiza i komunikacija s klijentima
- Odrzavanje web stranica

Zagreb, Hrvatska

OBRAZOVANJE I OSPOSOBLJAVANJE

01/07/2015 – TRENUTAČNO – Zagreb, Hrvatska
INTEGRIRANI PREDIPLOMSKI I DIPLOMSKI STUDIJ POSLOVNA EKONOMIJA – Ekonomski Fakultet u Zagrebu

26/02/2020 – 28/06/2020 – Vienna, Austrija
CEEPUS RAZMJENA – WU (Vienna University of Economics and Business)

01/02/2021 – 15/05/2021 – Prague, Češka
CEEPUS RAZMJENA – VSE (University of Business and Economics Prague)

DIGITALNE VJEŠTINE

Analiza podataka i programiranje

R Programing | Microsoft Excel | ETL (Pentaho) | Oracle SQL | Google BigQuery | Machine Learning with R | R Shiny | Basic Python

Uredski alati i upravljanje projektima

Google Suite (Gmail Google Drive Google Docs Google Slide Google Sheets) | Work management tools (Trello Slack) | Microsoft Office

Web dizajn i development

Wordpress - Basic Knowledge | Web Development: HTML 5, CSS, JavaScript | Graphich design in Canva

PRILOZI

5.1 Prilog 1 Anketa o faktorima odluke pri odabiru smjera na Ekonomskom fakultetu u Zagrebu

Anketa o faktorima odluke pri odabiru smjera na Ekonomskom fakultetu u Zagrebu

Poštovani,

Ispred vas se nalazi upitnik koji se provodi u svrhu pisanja mog diplomskog rada na Ekonomskom fakultetu u Zagrebu - "Sustavi preporuke kao alati efikasnijeg donošenja odluka: Primjer aplikacija za odabir smjera na Ekonomskom fakultetu u Zagrebu".

Cilj upitnika je utvrditi motivaciju studenata pri odabiru diplomskog smjera. Ciljna skupina su studenti EFZG-a.
Ispunjavanje je kratko te traje otprilike 2 minute.

Hvala Vam na sudjelovanju!

Srdačan pozdrav,
Borna Nikolić

*Obavezno

Pitanja o osobnim preferencijama

1. Vaša dob: *

2. Spol: *

Označite samo jedan oval.

- ◯ Muški
- ◯ Ženski
- ◯ Ostalo: _____

3. U koju ste godinu studija trenutno upisani? *

Označite samo jedan oval.

- ◯ 1.
- ◯ 2.
- ◯ 3.
- ◯ 4.
- ◯ 5.

4. Koliko imate trenutno nepoloženih kolegija sa prethodnih godina studija: *

5. Je li Vam sadašnji studij bio prvi izbor pri upisu na fakultete? *

Označite samo jedan oval.

- Da
- Ne

6. Koliko ste zadovoljni iskustvom studiranja na preddiplomskom dijelu integriranog studija na Ekonomskom fakultetu u Zagrebu? (predmeti, profesori, gradivo i ostali akademski aspekti) *

Označite samo jedan oval.

	1	2	3	4	5	
Uopće nisam zadovoljan						Jako sam zadovoljan

7. Prosjek ocjena u dosadašnjem studiranju: *

Unesite u obliku broja zaokruženog na dvije decimale (npr. 3.65)

8. Ako ste već upisali smjer navedite koji:

Označite samo jedan oval.

- Analiza i poslovno planiranje
- Ekonomija
- Financije
- Menadžment
- Menadžerska informatika
- Marketing
- Računovodstvo i revizija
- Trgovina
- Turizam

9. Ocijenite koliko su Vam (bili) bitni sljedeći faktori pri odabiru smjera: *

Označite samo jedan oval po retku.

	1 - Nije mi uopće bitno	2	3	4	5 - Jako mi je bitno
Moji interesi se poklapaju sa gradivom smjera	◯	◯	◯	◯	◯
Smjer nije pretjerano zahtjevan	◯	◯	◯	◯	◯
Lakoća pronalaska posla nakon diplome	◯	◯	◯	◯	◯
Mišljenje okoline o smjeru(kolege, obitelj...)	◯	◯	◯	◯	◯
Profesori koji prodaju na smjeru	◯	◯	◯	◯	◯
Generalni imidž smjera (smjer se smatra prestižnim)	◯	◯	◯	◯	◯

10. Znate li već koji smjer želite upisati? (preskočite ako ste već upisali smjer)

Označite samo jedan oval.

◯ Da
◯ Ne

11. Ocijenite koliko koristite (ili ste koristili) sljedeće izvore za informirat se o smjerovima na EFZG-u: *

Označite samo jedan oval po retku.

	1 - Ne koristim ih uopće	2	3	4	5 - Koristim ih neprestano
Direktno od fakulteta (web stranica, organizirani događaji...)					
Profesori koji mi predaju					
Stariji studenti koje osobno poznajem					
Ostali studenti (npr. na društvenim mrežama...)					
Vlastito istraživanje na temelju podataka iz prethodnih godina					

Ocjena privlačnosti smjerova

U završnom dijelu ove ankete morate ocijeniti privlačnost određenih smjerova nevezano za vlastite preferencije (gledajte koliko bi on trebao biti privlačan studentskoj populaciji po objektivnim faktorima: zapošljivost nakon studija, kvaliteta profesora i kolegija itd.). U drugom pitanju za svaki smjer trebate još samo odgovoriti koliku prosječnu ocjenu privlačnosti mislite da su dali ostali ispitanici za to prethodno pitanje.

12. Koliko je privlačan smjer Analiza i poslovno planiranje? *

Označite samo jedan oval.

	1	2	3	4	5	6	7	8	9	10	
U potpunosti neprivlačan											Iznimno privlačan

13. Koliku mislite da su ostali studenti dali prosječnu ocjenu na prethodno pitanje? (smjer APP) *

Označite samo jedan oval.

1	2	3	4	5	6	7	8	9	10

14. Koliko je privlačan smjer Ekonomija? *

Označite samo jedan oval.

	1	2	3	4	5	6	7	8	9	10	
U potpunosti neprivlačan	◯	◯	◯	◯	◯	◯	◯	◯	◯	◯	Iznimno privlačan

15. Koliku mislite da su ostali studenti dali prosječnu ocjenu na prethodno pitanje? (smjer Ekonomija) *

Označite samo jedan oval.

1	2	3	4	5	6	7	8	9	10
◯	◯	◯	◯	◯	◯	◯	◯	◯	◯

16. Koliko je privlačan smjer Financije? *

Označite samo jedan oval.

	1	2	3	4	5	6	7	8	9	10	
U potpunosti neprivlačan	◯	◯	◯	◯	◯	◯	◯	◯	◯	◯	Iznimno privlačan

17. Koliku mislite da su ostali studenti dali prosječnu ocjenu na prethodno pitanje? (smjer Financije) *

Označite samo jedan oval.

1	2	3	4	5	6	7	8	9	10
◯	◯	◯	◯	◯	◯	◯	◯	◯	◯

18. Koliko je privlačan smjer Menadžment? *

Označite samo jedan oval.

	1	2	3	4	5	6	7	8	9	10	
U potpunosti neprivlačan	◯	◯	◯	◯	◯	◯	◯	◯	◯	◯	Iznimno privlačan

19. Koliku mislite da su ostali studenti dali prosječnu ocjenu na prethodno pitanje? (smjer Menadžment) *

Označite samo jedan oval.

1	2	3	4	5	6	7	8	9	10
◯	◯	◯	◯	◯	◯	◯	◯	◯	◯

20. Koliko je privlačan smjer Menadžerska Informatika? *

Označite samo jedan oval.

	1	2	3	4	5	6	7	8	9	10	
U potpunosti neprivlačan	◯	◯	◯	◯	◯	◯	◯	◯	◯	◯	Iznimno privlačan

21. Koliku mislite da su ostali studenti dali prosječnu ocjenu na prethodno pitanje? (smjer Menadžerska informatika) *

Označite samo jedan oval.

1	2	3	4	5	6	7	8	9	10
◯	◯	◯	◯	◯	◯	◯	◯	◯	◯

22. Koliko je privlačan smjer Marketing? *

Označite samo jedan oval.

	1	2	3	4	5	6	7	8	9	10	
U potpunosti neprivlačan	◯	◯	◯	◯	◯	◯	◯	◯	◯	◯	Iznimno privlačan

23. Koliku mislite da su ostali studenti dali prosječnu ocjenu na prethodno pitanje? (smjer Marketing) *

Označite samo jedan oval.

1	2	3	4	5	6	7	8	9	10
◯	◯	◯	◯	◯	◯	◯	◯	◯	◯

24. Koliko je privlačan smjer Računovodstvo i revizija? *

Označite samo jedan oval.

	1	2	3	4	5	6	7	8	9	10	
U potpunosti neprivlačan											Iznimno privlačan

25. Koliku mislite da su ostali studenti dali prosječnu ocjenu na prethodno pitanje? (smjer RiR) *

Označite samo jedan oval.

1	2	3	4	5	6	7	8	9	10

26. Koliko je privlačan smjer Trgovina? *

Označite samo jedan oval.

	1	2	3	4	5	6	7	8	9	10	
U potpunosti neprivlačan											Iznimno privlačan

27. Koliku mislite da su ostali studenti dali prosječnu ocjenu na prethodno pitanje? (smjer Trgovina) *

Označite samo jedan oval.

1	2	3	4	5	6	7	8	9	10

28. Koliko je privlačan smjer Turizam? *

Označite samo jedan oval.

	1	2	3	4	5	6	7	8	9	10	
U potpunosti neprivlačan											Iznimno privlačan

29. Koliku mislite da su ostali studenti dali prosječnu ocjenu na prethodno pitanje? (smjer Turizam) *

Označite samo jedan oval.

1	2	3	4	5	6	7	8	9	10
⬭	⬭	⬭	⬭	⬭	⬭	⬭	⬭	⬭	⬭

Google nije izradio niti podržava ovaj sadržaj.

Google Obrasci

5.2 Prilog 2 Aplikacija za preporuku smjera na Ekonomskom fakultetu u Zagrebu (Alumni baza)

Aplikacija za preporuku smjera na Ekonomskom fakultetu u Zagrebu

Poštovani,

Ispred Vas se nalazi upitnik kojemu je cilj prikupiti podatke za izradu aplikacije EFZGsmjer. Aplikacije se izrađuje u sklopu pisanja diplomskog rada na Ekonomskom Fakultetu u Zagrebu. Ciljana populacija su alumniji fakulteta.

EFZGsmjer će služiti budućim studentima koji nisu sigurni koji diplomski smjer upisati tako da im daje preporuku smjera na temelju toga što su ostali pojedinci slični njima upisali.

Kako bi aplikacija što uspješnije radila, pojedince će se uspoređivati po osobnosti, interesima te akademskim sklonostima. Dodatno u ovu anketu je ukomponirano istraživanje o zadovoljstvu diplomskim studijem Katedre za Informatiku Ekonomskog Fakulteta u Zagrebu, tako da će se rezultati ovog upitnika koristiti i za analizu i unaprjeđenje nastavnog procesa.

Vaše sudjelovanje je u potpunosti anonimno i ispunjavanje traje između 5 i 10 minuta.

Hvala Vam unaprijed na sudjelovanju!

Za sve dodatne informacije možete mi se obratiti na:
bnikolic@net.efzg.hr

Srdačan pozdrav,
Borna Nikolić

*Obavezno

Privole

Podnošenjem ove ankete dajem privolu za korištenje danih podataka u svrhu izrade aplikacije u sklopu diplomskog rada autora te analize kvalitete diplomskih studija na katedri za Informatiku Ekonomskog fakulteta u Zagrebu.

Anketa je u potpunosti anonimna i dobrovoljna. Svi odgovori dani u anketi su strogo povjerljivi i koristiti će se isključivo u svrhe navedene u privoli, te neće biti prosljeđivane trećim stranama.

Prilikom prikupljanja, obrade i čuvanja prikupljenih podataka poštivat će se najbolje prakse i pravni akti vezani uz zaštitu podataka.

Svjestan sam da ovu privolu mogu povući u bilo kojem trenutku slanjem poruke na mail bnikolic@net.efzg.hr.

1. Molim Vas da označite tvrdnje s kojima se slažete. *

Odaberite sve točne odgovore.

☐ Dajem svoju suglasnost za iznad navedenu privolu.

Obrazac za prikupljanje podataka potrebnih za izradu aplikacije

Naredna 3 seta pitanja su vezana za Vašu osobnost i karijerne interese te koliko su Vam se sviđali određeni predmeti sa preddiplomskog dijela studija.

10-BFI upitnik osobnosti

Narednih 10 pitanja služi za procjenu Vaše osobnosti po Big Five osobinama - Otvorenost, Savjesnost, Ekstroverzija, Slaganje i Neuroticizam.

Za više informacija u ovu temu pogledajte:
Rammstedt, B. & John, O.P. (2007): Measuring personality in one minute or less: A 10-item short version of the Big Five Inventory in English and German. Journal of Research in Personality, 41.

2. Smatram se osobom koja je... *

Označite samo jedan oval po retku.

	1 - U potpunosti se NE slažem	2	3	4	5 - U potpunosti se slažem
...rezervirana					
... uglavnom povjerljiva					
... ima tendenciju biti lijena					
... opuštena, dobro podnosi stres					
... ima nekoliko umjetničkih interesa					
... otvorena, društvena					
... ima tendenciju pronalaziti mane kod drugih					
... detaljna u obavljanju svojih obaveza					
... lako postane nervozna					
... kreativna, posjeduje aktivnu imaginaciju					

18REST upitnik karijernih interesa

Narednih 18 tvrdnji je vezano uz Vaše interese (naročito karijerne) na temelju Hollandovih kodova.

Upitnik je prilagođen za ekonomski fakultet, a više o tipologiji možete pročitati na:
https://prc.springeropen.com/articles/10.1186/s41155-018-0086-z

3. Ja volim... *

Označite samo jedan oval po retku.

	1 - U potpunosti se NE slažem	2	3	4	5 - U potpunosti se slažem
... raditi sa računalima, novim tehnologijama					
... održavati programe/alate potrebne za obavljanje posla					
... računati, rješavati matematičke probleme					
... čitati znanstvene radove i knjige					
... raditi analize i eksperimente					
... objašnjavati društvene pojave (poput ponašanja potrošača)					
... sudjelovati u dizajniranju proizvoda/servisa					
... prezentirati ispred publike					
... imati slobodne ruke da budem kreativan na poslu					
... pružati socijalne (društveno korisne) servise svojoj zajednici					
... davati smjernice pojedincima za poboljšanje njihovog blagostanja					
... biti dostupan za pomoći ljudima					
... raditi na strateškim pitanjima u poduzeću					

pitanjima u poduzeću					
... upravljati ciljevima i performansama radnih timova					
... pregovarati sa kupcima					
... nadgledati usklađenost sa pravilima/zakonima					
... analizirati makroekonomska pitanja/scenarije					
... upravljati važnim dokumentima i datotekama					

Ocjene zanimljivosti predmeta sa preddiplomskog dijela studija

Završni dio vezan za aplikaciju je Vaša ocjena koliko su Vam se neki predmeti sa preddiplomske razine studija osobno dopali.

Ukoliko niste imali neki od navedenih predmeta (niti predmet sa sličnim nazivom) ostavite ocjenu 3.

4. Ocijenite koliko su Vam bili zanimljivi naredni kolegiji: *

Označite samo jedan oval po retku.

	1	2	3	4	5
Informatika	◯	◯	◯	◯	◯
Osnove ekonomije	◯	◯	◯	◯	◯
Gospodarstvo Hrvatske	◯	◯	◯	◯	◯
Statistika	◯	◯	◯	◯	◯
Trgovačko pravo	◯	◯	◯	◯	◯
Poduzetništvo	◯	◯	◯	◯	◯
Organizacija	◯	◯	◯	◯	◯
Poslovne financije	◯	◯	◯	◯	◯
Računovodstvo	◯	◯	◯	◯	◯
Financijske institucije i tržišta	◯	◯	◯	◯	◯
Javne financije	◯	◯	◯	◯	◯
Međunarodno poslovanje	◯	◯	◯	◯	◯
Osnove marketinga	◯	◯	◯	◯	◯
Turizam	◯	◯	◯	◯	◯
Poslovni informacijski sustavi	◯	◯	◯	◯	◯

Istraživanje o zadovoljstvu sa završenim diplomskim studijem

Ostatak ankete su pitanja vezana za Vaše trenutno zaposlenje i utjecaj Vašeg studijskog smjera na sadašnju karijeru. Rezultati ovog dijela ankete će se koristiti u poboljšanju kvalitete studij na Ekonomskom fakultetu u Zagrebu te će se sumarna statistika prikazivati kao rezultat studentima unutar same aplikacije za preporuku smjera.

5. Prosječna ocjena za vrijeme diplomskog studija: *

Označite samo jedan oval.

- 2,0-2,4
- 2,5-2,9
- 3,0-3,4
- 3,5-3,9
- 4,0-4,4
- 4,5-5,0

6. Koliko mjeseci nakon završetka studija ste dobili prvi prvi posao? *

Označite samo jedan oval.

- 0-3
- 4-7
- 8-11
- više od 12

Sljedeća 3 pitanja su opcionalna, ali bi dala vrijedne uvide za same studente jer su pokazatelj za kakve poslove se jednog dana mogu kandidirati. :)

7. Vaša trenutna pozicija:

_____

8. Vaš trenutni poslodavac:

_____

9. Koliko ste zadovoljni svojim trenutnim poslom?

Označite samo jedan oval.

- 1 - Jako sam nezadovoljan
- 2
- 3
- 4
- 5 - Jako sam zadovoljan

10. Koliko se slažete sa narednim tvrdnjama? *

Označite samo jedan oval po retku.

	1 - U potpunosti se NE slažem	2	3	4	5 - U potpunosti se slažem
Studijski smjer mi je dao potrebna stručna znanja za poslove na kojima sam bio zaposlen					
Studijski smjer je ispunio moja očekivanja koja sam imao na početku (prilikom upisa na smjer)					
Nastavnici se odnose prema studentima s razumijevanjem i poštovanjem					
Nastavnici imaju stručne kvalitete za kolegije koje predaju					
Studijski smjer usmjeren je na znanje primjenjivo u praksi					
Na studijskom smjeru postoji dovoljno praktičnog rada					

11. Kada biste ponovno birali, biste li upisali Vaš smjer? *

Označite samo jedan oval.

- Da
- Ne

12. Biste li drugima savjetovali da upišu ovaj smjer? *

Označite samo jedan oval.

- Da
- Ne

13. Koju biste ukupnu ocjenu dodijelili Vašem smjeru? *

Označite samo jedan oval.

- 1
- 2
- 3
- 4
- 5

14. Koji smjer ste završili na diplomskom studiju? *

Označite samo jedan oval.

- Analiza i poslovno planiranje
- Ekonomija
- Financije
- Menadžment
- Menadžerska informatika
- Marketing
- Računovodstvo i revizija
- Trgovina
- Turizam

Alumni mreža smjera Menadžerska informatika

Pošto ste alumni smjera Menadžerska informatika imamo jedno dodatno pitanje za Vas. Katedra za Informatiku želi pokrenuti vlastitu Mrežu Alumnia, gdje bi se moglo raditi na sinergiji između obrazovanja i industrije kroz razne networking evente i projekte. Ukoliko ste zainteresirani ispunite naredna 3 pitanja te će Vas se staviti u posebnu bazu. Ako ne želite sudjelovati samo preskočite naredna pitanja i Privolu :)

15. Ime:

16. Prezime:

17. Aktualna e-mail adresa:

Privole

Podnošenjem ove ankete dajem privolu za korištenje danih osobnih podataka u svrhu pokretanja mreže Alumnija smjera.

Prilikom prikupljanja, obrade i čuvanja prikupljenih podataka poštivat će se najbolje prakse i pravni akti vezani uz zaštitu podataka. Vaši podaci neće biti prosljeđivani trećim stranama te će se koristiti samo u svrhu navedenu u ovoj privoli.

Svjestan sam da ovu privolu mogu povući u bilo kojem trenutku slanjem poruke na mail bnikolic@net.efzg.hr ili mspremic@net.efzg.hr.

18. Molim Vas da označite tvrdnje s kojima se slažete.

Odaberite sve točne odgovore.

- [ ] Dajem svoju suglasnost za iznad navedenu privolu.

Google nije izradio niti podržava ovaj sadržaj.

Google Obrasci