

Analiza zaposlenosti mladih u Europskoj uniji korištenjem otkrivanja znanja iz baza podataka

Bagić, Katarina

Master's thesis / Diplomski rad

2020

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://um.nsk.hr/um:nbn:hr:148:785795>

Rights / Prava: [Attribution-NonCommercial-ShareAlike 3.0 Unported/Imenovanje-Nekomercijalno-Dijeli pod istim uvjetima 3.0](#)

Download date / Datum preuzimanja: **2025-01-08**



Repository / Repozitorij:

[REPEFZG - Digital Repository - Faculty of Economics & Business Zagreb](#)



Sveučilište u Zagrebu

Ekonomski fakultet

Diplomski studij Poslovne ekonomije – Menadžerska informatika

**ANALIZA ZAPOSLENOSTI MLADIH U EUROPSKOJ UNIJI
KORIŠTENJEM OTKRIVANJA ZNANJA IZ BAZA
PODATAKA**

Diplomski rad

Katarina Bagić

Zagreb, svibanj 2020.

Sveučilište Zagrebu

Ekonomski fakultet

Diplomski studij Poslovne ekonomije – Menadžerska informatika

**ANALIZA ZAPOSLENOSTI MLADIH U EUROPSKOJ UNIJI
KORIŠTENJEM OTKRIVANJA ZNANJA IZ BAZA
PODATAKA**

**ANALYSIS OF YOUTH EMPLOYMENT IN THE EUROPEAN
UNION BY USING DATABASE KNOWLEDGE**

Diplomski rad

Katarina Bagić, 0067525276

Mentor: Prof. dr. sc. Mirjana Pejić Bach

Zagreb, svibanj 2020.

IZJAVA O AKADEMSKOJ ČESTITOSTI

KATARINA BAGIĆ
Ime i prezime studenta

IZJAVA O AKADEMSKOJ ČESTITOSTI

Izjavljujem i svojim potpisom potvrđujem da je diplomski rad isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu, a što pokazuju korištene bilješke i bibliografija. Izjavljujem da nijedan dio rada nije napisan na nedozvoljen način, odnosno da je prepisan iz necitiranog rada, te da nijedan dio rada ne krši bilo čija autorska prava. Izjavljujem, također, da nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Student:

U Zagrebu, 14. svibnja 2020.

Katarina Bagić
(potpis)

SAŽETAK

Na razini Europske unije prepoznata je važnost ulaganja u obrazovanje mladih kako bi se olakšao prijelaz iz obrazovanja u svijet rada. Provedbom metode klaster analize nad zaposlenim mladim stanovništvom Europske unije, s različitim razinama obrazovanja, ostvarili su se ciljevi ovog rada. Dobiveni podaci grupirani su u četiri različita klastera, za sve tri provedene analize, te su rezultati grafički prikazani. U klasteru A nalaze se zemlje s najvišom razinom zaposlenosti dok se u D klasteru nalaze one zemlje koje najviše zaostaju sa stopom zaposlenosti mladih na europskoj razini. Mladi s visokim stupnjem obrazovanja ujedno su i u najvećem postotku zaposleni. Također, rezultati analize pokazali su da su muškarci više zaposleni od žena obzirom na razine obrazovanja u sve tri kategorije. Usklađenost obrazovnog sustava i ponude poslova na tržištu rada važan su faktor za povećanje zaposlenosti mladih.

Ključne riječi: otkrivanje znanja iz baza podataka, klaster analiza, zaposlenost mladih, tržište rada, obrazovanje

ABSTRACT

At European union level, the importance of investing in youth education to facilitate the transition from education to the labor market has been recognized. By implementing the cluster analysis method on the employed young population of the European Union with different levels of education, the goals of this paper have been achieved. The obtained data were grouped into four different clusters for all three performed analyzes and the results were graphically presented. Cluster A contains the countries with the highest level of employment, while cluster D contains those countries that lag the most behind the youth employment rate at the european level. Young people with a high level of education are at the same time employed in the largest percentage. Also, the results of the analysis showed that men are more employed than women considering all three levels of education. The harmonization of the education system and the supply of jobs on the labour market are an important factor in increasing youth employment.

Key words: Database knowledge, Cluster analysis, youth employment, labor market, education

SADRŽAJ

1. UVOD.....	1
1.1. Predmet i cilj rada.....	1
1.2. Izvori podataka i metode prikupljanja	1
1.3. Sadržaj i struktura rada	2
2. ANALIZA MLADOG STANOVNIŠTVA OBZIROM NA ZAPOSLENOST U EU	3
2.1. Analiza tržišta rada za mlade u zemljama Europske unije.....	3
2.2. Analiza zaposlenosti mladog stanovništva u zemljama Europske unije	12
2.3. NEET skupine na području Europske unije	15
3. OTKRIVANJE ZNANJA U BAZAMA PODATAKA.....	19
3.1. Uvod u otkrivanje znanja iz baza podataka	19
3.2. Područja primjene otkrivanja znanja iz baza podataka.....	20
3.3. Važnost primjene otkrivanja znanja iz baza podataka	22
3.4. Prikaz metoda za otkrivanje znanja iz baza podataka	23
4. ISTRAŽIVANJE PODATAKA O ZAPOSLENOSTI KORIŠTENJEM OTKRIVANJA ZNANJA IZ BAZA PODATAKA.....	26
4.1. Metodologija istraživanja	26
4.2. Rezultati istraživanja.....	28
4.3. Rasprava.....	43
5. ZAKLJUČAK	46
POPIS LITERATURE	47
POPIS SLIKA	51
POPIS GRAFIKONA.....	51
POPIS TABLICA.....	52
PRILOZI.....	53

1. UVOD

1.1. Predmet i cilj rada

Obrazovanje i zaposlenost, a naročito nezaposlenost mladih aktualne su teme koje izazivaju brojne rasprave u javnosti. Svaka uspješna i odgovorna zemlja teži ostvarenju potpune zaposlenosti mladih jer su oni nositelji napretka i žila kucavica društva. Analizom zaposlenosti i stupnja obrazovanja dobivaju se podaci pomoću kojih možemo uspoređivati zemlje, donositi zaključke i mjere za poticanje zapošljavanja te dodatnog educiranja. Kada je riječ o zaposlenosti kod mladih, najčešće se spominje njihova nezaposlenost te je neizostavno spomenuti NEET skupinu čiji je udio u ukupnoj mladoj populaciji u porastu.

Ciljevi rada ostvareni su provođenjem klaster analize nad podacima te grafičkim prikazima rezultata analize kojima su do izražaja došle skupine zemalja u kojima je zaposlenost mladih u opadanju te one u kojima je zaposlenost u porastu. Također, cilj analize bio je uvidjeti u kojoj mjeri razina obrazovanja utječe na samu zaposlenost te ima li razlike u zaposlenosti obzirom na spol.

1.2. Izvori podataka i metode prikupljanja

Teoretski dio rada temelji se na sekundarnom istraživanju. U okviru sekundarnog istraživanja korišteni su različiti izvori podataka kao što su knjige iz područja rudarenja podacima, brojni znanstveni članci domaćih i stranih autora vezanih uz tržište rada i mlade dostupnim u bazama podataka (Hrčak.srce, ProQuest, WoS) te javno objavljenim statističkim podacima. Istraživački dio rada temeljen je na podacima prikupljenima sa web stranice Eurostata (Database) te znanjem usvojenim na kolegiju Otkrivanje znanja u bazama podataka. Provedeni istraživački dio rada ujedno je i vlastiti doprinos radu. Pri izradi analize u istraživanju korištena je metodologija klaster analize te programski alati Excel i Weka.

1.3. Sadržaj i struktura rada

Sadržaj rada podijeljen je na dva dijela: teorijski i istraživački dio. U teorijskome dijelu, u uvodu definiran je predmet i cijevi rada te izvori podataka i metode prikupljanja. Zatim slijedi poglavlje o analizi mladog stanovništva obzirom na zaposlenost u zemljama Europske Unije u kojemu je pomoću znanstvene literature analizirano stanje na tržištu rada te zaposlenost mladih u 28 članica Europske Unije. Također, spomenuta je i NEET skupina obzirom da ne možemo govoriti o zaposlenosti mladih, a da se ne dotaknemo i onih koji niti su zaposleni, niti u formalnom obrazovanju i osposobljavanju. U idućemu poglavlju približen je teorijski dio o otkrivanju znanja u kojemu su navedena neka od važnijih područja primjene kao što su bankarstvo, maloprodaja, telekomunikacije i dr. Nadalje, istaknuta je važnost primjene te metode otkrivanja znanja iz baza podataka. Nakon teorijskog dijela, slijedi istraživački dio u kojemu su se metodom klasteriranja podataka analizirali podaci o zaposlenosti mladih dobne skupine (15-29 godina) obzirom na stupanj obrazovanja i spol. Dobiveni klasteri analizirani su u raspravi istraživanja te je na kraju rada iznesen zaključak.

2. ANALIZA MLADOG STANOVNIŠTVA OBZIROM NA ZAPOSLENOST U EU

Obrazovanje i zaposlenost odnosno nezaposlenost mladih jedno su od važnijih tema današnjice koji se međusobno isprepliću. Europska komisija te čelnici zemalja Europske unije stoga zajednički surađuju na rješavanju tih gorućih društvenih problema ulažući u obrazovanje i osposobljavanje mladih za svijet rada provodeći aktivne politike tržišta rada te donošenjem niza paketa mjera za mlade usvajajući strategiju „Europa 2020“. Perugini i Signorelli (2009) ističu važnost donošenja politika na europskim, regionalnim, nacionalnim i lokalnim razinama kako bi se smanjile regionalne razlike i nezaposlenost kod mladih te kako bi se povećala razina integracije i razina obrazovanja na tržištu mladih.

2.1. Analiza tržišta rada za mlade u zemljama Europske unije

Činjenično je kako su mladi nositelji napretka i konkurentnosti društva stoga Europska unija nastoji povećati tu konkurentnost na globalnoj razini. Prema Bilić i Jukić (2014) u većini europskih zemalja pojam mladih odnosi se na populaciju od 15. do 24. godine no u nekim zemljama članicama kao što je Hrvatska ta dobna granica seže do 29. godine jer se ista razina obrazovanja stječe u različitim godinama što produljuje prelazak mladih iz obrazovanja na tržište rada.

Jedan od problema koji se predviđa u obrazovnom sustavu jest da će u narednim godinama u najrazvijenijim zemljama svijeta koji zapošljavaju oko 65% radne snage, 7,1 milijun radnih mjesta postati nepotrebna jer će ih zamijeniti računala, roboti, automatizacija. Prva ugrožena radna mjesta mogla bi biti za one koji rade administrativne poslove, dok su ugroženi i sektori zdravstva zbog razvoja telemedicine, energetike i financija. Za nova radna mjesta koja će se pojaviti tražit će se kreativnost, nova znanja i vještine, stoga su najmanje ugroženi oni koji rade u STEM području (Nikolić, 2017). Iz toga razloga, nužne su promjene u obrazovanju te prilagođavanje novim potrebama i trendovima koji su sveprisutni kako bi se uskladila ponuda s potražnjom zanimanja.

Europska komisija donijela je strategiju zapošljavanja mladih kojom želi pomoći mladima koji se susreću s različitim izazovima pri prijelazu iz škole na posao, ne samo da pronađu prvo zaposlenje nego i da ostanu na tržištu rada. Realnost je takva da je

mladima koji traže prvo zaposlenje teže naći posao. Najčešće iz razloga što poslovi koji se nude traže uz razinu obrazovanja i određeni radni staž kojeg oni i ne mogu imati obzirom da su se do tada obrazovali. Stoga se većinom zapošljavaju na privremene i honorarne ugovore. Između ostalog u izvješću Europske komisije iz 2018. godine obrazlaže se kako problem zaposlenosti mladih odnosno visoke stope nezaposlenosti leži u nezadovoljavajućim rezultatima obrazovnog sustava i osposobljavanja kao i segmentaciji tržišta rada, malom broju javnih institucija za zapošljavanje te neadekvatnoj brizi o najugroženijima, onima koji se nalaze u NEET skupini.

Analize su pokazale kako je prijelaz iz obrazovanja u zaposlenje najbezbolniji u zemljama koje provode sustav obrazovanja koji je usklađen s potrebama tržišta rada, u kojima je poseban naglasak na mladoj radnoj snazi, gdje se provode aktivne politike zapošljavanja i gdje je sustav socijalnih naknada pravedan. Također, zemlje u kojima su zakoni o radu uređeni te su određene odgovarajuće minimalne plaće i gdje vladaju dobri makroekonomski uvjeti (Tomić 2018 prema Biavaschi i sur., 2012).

Prema izvješću Europske komisije iz 2018. godine, najveći problemi koji su se javili na tržištu rada mladih s kojima su se zemlje Europske unije suočile su: nezaposlenost mladih, segmentacija tržišta rada i loša usklađenost obrazovnog sustava i sustava za osposobljavanje.

1. Nezaposlenost mladih, dugotrajna nezaposlenost i neaktivnost

Velika globalna ekonomska kriza iz 2007./2008. godine i fluktuacije ukupne proizvodnje, dohotka i zaposlenosti ostavili su najviše traga na mladima, pogotovo na onaj dio mladih koji se našao u prijelazu iz obrazovanja u svijet rada. Rezultati su bili sljedeći: naglo je porasla opća stopa nezaposlenosti, a naročito kod mladih, shodno tome vladala je niska stopa zaposlenosti, ponuda poslova na tržištu rada bila je neizvjesna, a i sama kvaliteta radne snage koja se nudila. Mladi koji su se zatekli na tržištu rada, a da prethodno nisu imali radnog iskustva ili su bili u prijelazu iz obrazovanja te na posljertku nisu ni ušli na tržište, postali su ranjiva skupina. Najviše su ostali ugroženi migranti, mladi s poteškoćama u razvoju te oni u NEET skupini. Iako je stopa nezaposlenosti s godinama postupno padala i dalje je ostao veliki udio nezaposlenih te je Europska komisija donijela prijedlog za zemlje članice koji je pomogao u smanjenju stope te je doveo do promjena u obrazovanju i osposobljavanju (EK, 2018).

Dok je četvrta industrijska revolucija (4.0.) donijela nove izazove na tržište rada uvodeći inovacije u digitalizaciji, umjetnu inteligenciju i robotizaciju, ujedno je dovela u pitanje i radna mjesta. Naime, napretkom tehnologije smanjila se potreba za zastarjelim radnim mjestima, dok se povećala potražnja za ljudskim znanjem (ljudskim kapitalom).

Prema Tomić (2016) nedostatak radnog iskustva, neadekvatno obrazovanje i kvalifikacije, ugovori na određeno, otežan i slabo potican prelazak iz škole na posao, glavni su uzroci nezaposlenosti mlade populacije. A prvi poslovi koji mladi i pronađu najčešće nisu dobro plaćeni te nemaju većih prilika za rast i napredovanje. U svome istraživanju autorica ističe kako je nezaposlenost veća u zemljama članicama koje karakterizira niska stopa rasta BDP-a, visok javni dug, niska razina izvoza, visoka razina korupcije te stagnacija u gospodarskim granama kao što su graditeljstvo i poljoprivreda. Na višu stopu nezaposlenosti utjecali su mladi koji žive s roditeljima i čiji ukućani nisu stalno uposleni, koji nisu imali priliku odseliti zbog posjedovanja nekretnine u kojoj stanuju te visoki udio doznaka iz inozemstva.

2. Segmentacija tržišta rada

Segmentacija odnosno raslojavanje je problem koji se javlja na tržištu rada u većini zemalja članica Europske unije. Najčešće se spominje „dualnost tržišta rada“ koje se u slučaju Hrvatske i većine zemalja odnosi na skupine radnika s različitim ugovorima o radu, onima u stalnome zaposlenju – ugovorom na neodređeno vrijeme, i onima privremeno zaposlenima – ugovorom na određeno vrijeme, honorarnim i studentskim poslovima (Brkić, 2015). Kod osoba koje su zaposlene ugovorom na neodređeno podrazumijeva se da su u stalnim i stabilnim radnim odnosima s kvalitetnim radnim uvjetima i visokom razinom zaštite zaposlenja tj. da nisu u strahu od otpuštanja. Dok privremeno zaposleni ne uživaju te povlastice, također najčešće nemaju ni socijalnu zaštitu.

Ono što se javlja kao problem jest porast stope zapošljavanja radnika s ugovorom na određeno vrijeme te istovremeno, smanjenje stope prelaska u rad na neodređeno vrijeme, a najviše se ti rezultati očituju u Poljskoj, Španjolskoj i Francuskoj. Posebice kod mladih koje ulijeva dodatnu dozu nesigurnosti za budućnost, jer mladi traže trajno zaposlenje, a nitko im ne garantira da će im se po isteku ugovora na određeno vrijeme produžiti ugovor (Ledenko, 2017). U svome istraživanju Chung i sur. (2012) došli su

do sličnih zaključaka. Kada je riječ o zaposlenosti, velik broj mladih zaposleni su ugovorima na određeno vrijeme te im je teško pronaći posao ugovoren na neodređeno vrijeme čak i u razdobljima ekonomskog rasta. Tako se izmjenjuju između tri statusa: privremenih poslova, nezaposlenosti i/ili razdoblja neaktivnosti. Čavar (2018) u svome istraživanju navodi glavne razloge povremenog stupanja u radni odnos kod studenata u Hrvatskoj, ponajprije je to želja za zaradom za vrijeme studiranja te želja za ostvarivanjem radnog iskustva iako se pokazalo kako studenti pretežito rade poslove koji nisu povezani sa fakultetom kojeg pohađaju. Također spominje pojavu tzv. masifikacije visokog obrazovanja, koja podrazumijeva veliki broj studenata i njihovu raznolikost, uvjetovanu povećanjem upisnih kvota koje nisu bile u skladu s tržištem rada, a koja se značajno odrazila na zaposlenost studenata, najviše onima iz područja društvenih i humanističkih znanosti. Dok poslodavcima odgovara zapošljavanje radnika na privremeno radi lakšeg otpuštanja ukoliko se uvjeti u poslovanju otežaju ili sigurnijeg zapošljavanja ako je riječ o uvećanom sezonskom obujmu posla. Prema Ledenko (2017) države su te koje potiču poslodavce na zapošljavanje mladih tako u slučaju Hrvatske poslodavci plaćaju manje doprinose na plaću za osobe mlađe od 30 godina čiji je trošak plaće umanjen 17,2% kroz 5 godina, koliko traje korištenje olakšice.

3. Loše funkcioniranje sustava obrazovanja i osposobljavanja

Europska komisija u svome izvješću o zapošljavanju i socijalnom razvoju u Europi iz 2018. godine navodi probleme u obrazovanju mladih kojih će ubrzo prijeći na tržište rada. Najčešće mladi koji su diplomirali nemaju dovoljnu razinu znanja i vještina, a pritom su prošli kroz dugi sustav izobrazbe. Ono što se događa je kada prijeđu iz obrazovanja na tržište rada, nailaze na prepreke pri pronalasku posla za odgovarajuću stručnu spremu. Naime, ponuda poslova koja se nudi nije u skladu s potražnjom, tako mladi najčešće prihvaćaju poslove koji traže nižu razinu znanja i obrazovanja. Isto tako, mora se istaknuti kako visokoobrazovani diplomirani mladi ujedno imaju veću stopu zaposlenosti od mladih sa srednjom ili nižom stručnom spremom. Ranije spomenuta četvrta industrijska revolucija koja sa sobom donosi brze tehnološke promjene koje se stalno unaprjeđuju. Stoga je neophodno prepoznati i provesti reforme u obrazovanju kojima će se mlade obučavati vještinama kako bi bili u koraku s novim napretcima koje donosi tržište rada. Tako je na vladama članica da ulažu u informatička znanja i opismenjavanja mladih, pomoći im u stjecanju tzv. dinamičkih vještina odnosno kako

da se prilagode novim i nepoznatim prilikama koje dolaze, umjesto toga da nespremni uđu na tržište rada. Potaknuti prijedlozima Europske komisije za promjenom u dosadašnjem načinu obrazovanja i osposobljavanja, mnoge zemlje članice, vodeći se Garancijom mladih, poput Hrvatske, Cipra, Estonije, Grčke, Finske, Italije, Španjolske itd. provele su, te još uvijek provode značajne reforme kako bi navedene prijedloge primijenile u praksi. Te reforme potiču na fleksibilnost tržišta rada, koje je prilagodljivo, napose prema mladima koji su u prijelazu te otvara nova radna mjesta s kvalitetnijim radnim uvjetima i socijalnom zaštitom. Potičući uključivost tržišta rada pružanjem potpore mladima smanjuje se segmentacija tržišta rada koja se pokazala da utječe na smanjenje razine nezaposlenosti (EK, 2018).

Na Preporuku Vijeća iz 2013. godine, sve zemlje članice obvezale su se primijeniti **Garanciju za mlade** (eng. *The Youth Guarantee*, dalje u tekstu Garancija za mlade) kojom se želi osigurati mladima starosne dobi do 25 godina, u vremenskom intervalu od četiri mjeseca od završetka formalnog obrazovanja ili ulaska u nezaposlenost, da dobiju kvalitetnu ponudu za:

1. zaposlenje
2. stalno obrazovanje
3. naukovanje (Apprenticeships)
4. stažiranje (Traineeships).

U sklopu ponude za stalno obrazovanje, mladima koji imaju nisku razinu obrazovanja, nudi se stjecanje dodatnih vještina kroz vraćanje mladih u sustav obrazovanja i osposobljavanja kojima će steći viši stupanj obrazovanja i kvalifikacija.

Naukovanjem se stječe radno iskustvo za vrijeme školovanja za koje se dobiva certifikat po završetku te se upisuje u životopis. Najčešće traje tri do četiri godine, tijekom kojih se razvijaju praktične vještine koje povećavaju mogućnost zaposlenja po završetku.


Stožiranje ili pripravništvo traje u prosjeku godinu dana, a koristi mladima jer mogu primijeniti svoja strukovna znanja u praksi, steći traženo radno iskustvo te si olakšati prijelaz na tržište rada, a za to su najčešće i plaćeni. Također, osim mladima, stažiranje pomaže i poslodavcima tako što si osiguravaju mladi ljudski kapital, a po završetku stažiranja mogu zaposliti pojedince koji se istaknu te na tržištu rada ostavljaju pozitivnu sliku o sebi. Međutim, problem koji se javio tijekom pripravništva bila je njegova

zlouporaba. Naime, određeni poslodavci nisu pružali jednaku kvalitetu mladima tako nije bilo učenja odnosno vježbi za polaznike i radni uvjeti nisu bili zadovoljavajući. Stoga je Vijeće na prijedlog Komisije donijelo Okvir kvalitete pripravnštva (QFT) koji se sastoji od 22 elementa kvalitete kojim se želi osigurati visokokvalitetni sadržaj učenja i odgovarajući radni uvjeti, a sve u cilju olakšavanja prijelaza iz obrazovanja u prvi radni odnos i povećanja zaposlenosti (EK, 2018).

Caliendo i Schmidl (2016) naglašavaju kako europske zemlje ulažu napore i novčana sredstva u aktivne politike tržišta rada (eng. ALMPs) kako bi olakšali mladima opstanak na tržištu rada te smanjili nezaposlenost. Tako spominju programe kao što su: obuka za tržište rada, pomoć u traženju posla i nadzor, subvencionirano zapošljavanje te programi javnog zapošljavanja. Provedena su različita istraživanja o učinkovitosti aktivnih programa tržišta rada za mlade gdje je došlo do različitih rezultata. U nekim istraživanjima određeni elementi programa dovode do smanjenja stope nezaposlenosti mladih dok su neki elementi prikazani s beznačajnim ili negativnim učinkom na smanjenje nezaposlenosti. Većina provedenih studija nije uspjela utvrditi dugoročne učinke ovih programa zbog kratkog razdoblja promatranja (do dvije godine). Sugerira se veća usmjerenost na obrazovanje i kvalitetu ponude poslova.

Austrijski model pokazao se kao dobar primjer korištenja aktivnih politika tržišta rada kod mladih. Rezultati su se pokazali ne samo kod smanjenja stope nezaposlenosti već i kod niskih stopa NEET populacije te niskih stopa ranog napuštanja škole. Svoj uspjeh Austrija duguje sustavu naukovanja (engl. Apprenticeships) odnosno Vladi koja je uložila značajna sredstva u aktivne politike tržišta rada za mlade kojima je povećala obuku u javnim naukovanjima te je povećala subvencije naukovanja u privatnim poduzećima. To povećanje je uslijedilo nakon pritužbi poduzeća kako imaju poteškoća pri pronalaženju kandidata. Bitno je reći kako se poduzećima isplati otvarati natječaje za praktikante iz dva razloga. Prvi je taj što su plaće male, odnosno riječ je o jeftinoj radnoj snazi, a drugo osposobljavanjem tih mladih ljudi, poduzeća si stvaraju produktivne radnike, odnosno kvalitetnu radnu snagu. Naukovanje je kombinacija obuke na radnom mjestu u poduzeću (80%) i formalnog obrazovanja u strukovnoj školi (20%). Nakon položenog ispita dobiva se uvjerenje o naukovanju koje je jednako vrijedno kao i svjedodžba o završenoj srednjoj školi. (Dolado, 2015).

Slika 1. Kretanja na tržištu mladih



Izvor: Factsheet: Youth Guarantee & Youth Employment Initiative in Croatia (2019)

Na slici 1. vidljiva su četiri grafa s podacima o tržištu rada mladih (15. - 24. godine) za Hrvatsku i Europsku uniju u intervalu od 2008. do 2017. godine. Ono što je uočljivo na prvi pogled je što Hrvatska u tri od četiri grafa zaostaje za prosjekom Europske Unije iako od 2013. otkada je pristupila zajednici Europske Unije, ima pozitivne trendove. Tako prvi graf lijevo pokazuje kretanje stope NEET populacije (mladi koji nisu u radnom odnosu, obrazovanju ili osposobljavanju) gdje je vidljivo kako se u Europi stopa smanjila s oko 13% u 2012. godini na 11% u 2017. godini dok se u Hrvatskoj s

19% u 2013. godini, kada je ujedno bila i najviša, stopa smanjila na 15,5% u 2017. godini. Na grafu nezaposlenosti mladih, uočljivo je kako su 2013. i u Europskoj Uniji (28%) i u Hrvatskoj (50%) stope nezaposlenosti bile velike, ali 2017. godine stopa nezaposlenosti mladih skoro se upola smanjila, tako stopa u Europskoj zajednici iznosi 18%, a u Hrvatskoj 25%. Na trećem grafu prikazana su kretanja stope zaposlenosti mladih, u Europi možemo primijetiti lagani trend rasta zaposlenosti, tako je 2013. godine stopa iznosila oko 32,5%, dok je 2017. godine porasla na 35%. Na primjeru Hrvatske možemo primijetiti kako je stopa zaposlenosti mladih padala od 2008. do vrhunca u 2013. godini kada je iznosila 15%, a od tada je krenuo trend rasta te je stopa u 2017. iznosila oko 26%. Na posljednjem grafu prikazana je stopa mladih koji su rano napustili obrazovanje i osposobljavanje, tako u Europskoj Uniji možemo vidjeti kako se od 2008. ta stopa postepeno snižavala te je u 2017. iznosila oko 10%, dok gledajući krivulju Hrvatske možemo primijetiti kako je imala zavidno niže stope od Europe, tako je u 2017. godini stopa iznosila svega oko 3%.

Zahvaljujući mjeri Garancija za mlade, život mladih Europljana se poboljšao. Tome u prilog govore brojke gdje je od 2014. više od 3,5 milijuna mladih prijavljeno u program Garancija za mlade, prihvatilo ponudu zaposlenja, kontinuiranog obrazovanja, naukovanja ili pripravništva. Također, Inicijativa za zapošljavanje potpomogla je preko 2,4 milijuna mladih Europljana. Ovakvi rezultati značajni su za kako za mlade tako i za cijelu zajednicu jer su se ovom mjerom otvorile nove prilike za mlade te se poboljšala ekonomska situacija na tržištu rada u Europi što povećava njezinu globalnu konkurentnost. Ove mjere bile su nužne kako bi dovele do strukturnih reformi i inovativnosti u zemljama članicama. Komisija je odlučila i dalje osiguravati jamstva za mlade na nacionalnoj razini, ali se više usmjerila na posebno ugroženu skupinu mladih, onih u NEET statusu prema kojima su javne institucije za zapošljavanje proširile svoje usluge kako bi povećale efikasnost u smanjenju broja tih osoba. Paketom Garancije za mlade uspostavljena je bolja suradnja između politika zapošljavanja, socijalnih politika, obrazovanja i mladih te su sklopljena partnerstva između ustanova koje ih provode i organizacija koje im pružaju podršku (Internetska stranica EU, 2020).

Nakon financijske krize, većina država članica stala je na noge, ekonomije su se oporavile tako je opća nezaposlenost na najnižoj razini u posljednjih deset godina. Također i stopa nezaposlenosti mladih ima stalan trend opadanja, ekonomije rastu ali po sporijim stopama nego ranije, iako su se uvjeti na tržištu popravili i dalje razina

ulaganja nije na razini prije krize. Iz tog razloga od ključne važnosti su nacionalna i javna ulaganja koja su se dosad pokazala kao dobro rješenje jer potiču ekonomski rast, ekonomsku i socijalnu konvergenciju, iako su javna ulaganja u Europskoj uniji spala s 3,4% BDP-a u 2008. na 2,7% u 2016. Ulaganje u ljudski kapital jedno je od najvažnijih javnih ulaganja, koja zahtjeva veća ulaganja po radniku nego ikad prije jer ponuda rada na tržištu iziskuje bolje obrazovanu radnu snagu. U 2015. godini izdaci za ulaganje u obrazovanje u BDP-u iznosili su 4,9%, dok zadnjih godina ono stagnira. Ulaganja u obrazovanje treba ohrabrivati i poticati jer je korist obostrana, kao za pojedince tako i za društvo, a koja će kasnije dovesti do ravnomjernije raspodjele dohotka (Hauptman, 2018).


De Lange i sur. (2013) u provedenim istraživanjima došli su do zaključka kako je ekonomska globalizacija ta koje pozitivno utječe na mlade na tržištu rada. Iz razloga što smanjuje kod pojedinaca vjerojatnost privremene zaposlenosti i nezaposlenosti jer se globalizacijom širi tržište rada i njezina konkurentnost te se otvaraju radna mjesta. Nadalje, tijekom gospodarske recesije, više su ugroženi niže obrazovani mladi od onih s višom stručnom spremom kod privremenih poslova. Poslodavci u takvim vremenima, radi nesigurnosti na tržištu rada, ne zamjenjuju niže obrazovane mlade onima s višom izobrazbom već ih zamjenjuju s novim nisko obrazovanim radnicima.

Kako bi se uspješno implementirala Garancija za mlade u razdoblju od 2014. do 2020. financijski je bila potpomognuta ulaganjima Europskog socijalnog fonda (ESF) i Inicijativom za zapošljavanje mladih (YEI) te financiranjima iz nacionalnih proračuna. Tome u prilog govore podaci da je Inicijativa za zapošljavanje započela sa proračunom od 6,4 milijarde eura pomoći za posebno ugrožene države članice koje su u 2012. godini imale nezaposlenost veću od 25%, a koja je svoja ulaganja povećala na 8,8 milijardi eura u 2017. godini. Poticanjem zapošljavanja mladih, osobito onih koji nisu u zaposlenju, obrazovanju i osposobljavanju, uvrštavajući ih u državni proračun, izbjegavaju se veći troškovi koji bi ih očekivali u budućnosti. Europski socijalni fond doprinosi pojedincima tako što pomaže s reformama javnih službi za zapošljavanje, obrazovanje i osposobljavanje (Internetska stranica EU, 2020).

2.2. Analiza zaposlenosti mladog stanovništva u zemljama Europske unije

Europska Komisija potiče zemlje članice Europske Unije na zapošljavanje mladih te ih potiče na smanjivanje stope nezaposlenosti, koja se s 24% u 2013. godini smanjila na manje od 15% u 2019. godini. Na idućim grafikonima prikazane su opće stope zaposlenosti mladih, zaposlenost prema zanimanjima i radnom statusu te prema razini obrazovanja i spolu.

Slika 2. Opća stopa zaposlenosti mladih (15-24) u razdoblju (2002.-2018.)



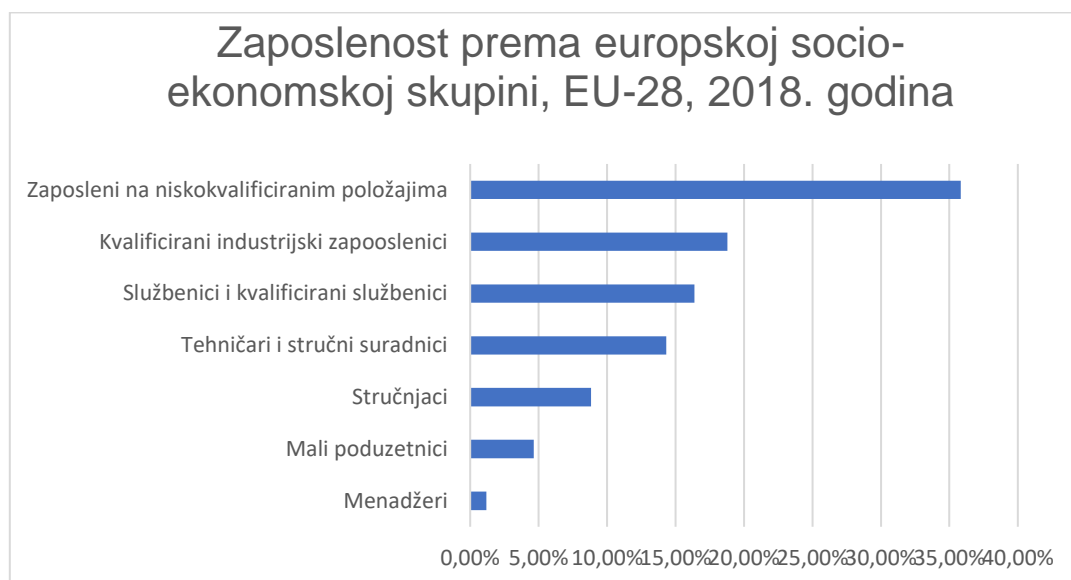
Izvor: Eurostat statistics explained: (mrežni kod podataka: lfsi_emp_a)

Na slici 2. vidljivi su podaci u proteklih 16 godina koji prikazuju trend kretanja stope zaposlenosti mladih na tržištu rada od 15. do 24. godine. Na grafu su usporedno prikazani podaci za Hrvatsku i prosjek zemalja članica Europske unije. Ono što se prvo primjećuje su razlike na tržištu rada Hrvatske i ostalih zemalja Unije odnosno koliko Hrvatska zaostaje za zemljama članicama. Nadalje, na grafu se jasno vidi kako je

nakon 2008. godine od doba ekonomske i financijske krize zaposlenost prosjeka EU - 28 pala sa najviših 37,2% na 32,1% u 2013. godini. Za to vrijeme u Hrvatskoj vidljivo je kako je stopa zaposlenosti mladih često varirala ali je od doba krize nakon 2008. godine drastično počela padati s najviših 28% na 14,9% u 2013. godini. Te godine Hrvatska je pristupila i Europskoj uniji te se slika značajno popravila, tako u 2018. godini možemo vidjeti kako se stopa zaposlenosti kod mladih u Hrvatskoj (25,6%) i EU-28 (35,4%) približila onoj iz 2008. godine prije krize.

Na Eurostatu se mogu pronaći podaci koji uključuju samo zanimanja zaposlenih osoba, ali time se ograničava slika zaposlenih osoba. Iz tog razloga uvedena je šira klasifikacija koja se krije iza kratice ESeG (europske socioekonomske skupine), koja kombinira zanimanje s radnim statusom.

Grafikon 1. Zaposlenost mladih (15-24) prema ESeG




Izvor: izrada autora prema Eurostatu: (mrežni kod podataka: lfsa_esega)

Na grafikonu 1. prikazani su podaci o ukupnim mladim osobama zaposlenima prema europskoj socio-ekonomskoj skupini u dobi od 15. do 24. godine za 2018. godinu. Ako se gledaju pojedinačne kategorije, najviše je onih zaposlenika sa radnim mjestima koja zahtijevaju niske kvalifikacije rada, njih čak 35,8% što bi nam trebalo ukazati na veliki udio mladih s niskom stručnom spremom. Slijede ih zaposleni u industriji, njih 18,8% zaposlenih, zatim službenici, njih 16,4%. Tehničara i stručnih suradnika je 14,3% dok je stručnjaka po zanimanju 8,8%. Malih poduzetnika je 4,7% dok je menadžera po

zanimanju zaposleno njih 1,2% što je i očekivano obzirom da je za promatranje uzeta u obzir dobna skupina do 24. godine.

Grafikon 2. Zaposlenost mladih (15-24) prema razini obrazovanja, 2018.



Izvor: izrada autora prema Eurostat: (mrežni kod podataka: [lfsa_egaed])

Na grafikonu 2. prikazana je prosječna zaposlenost 28 zemalja članica Europske unije kod mladih ljudi u dobi od 15. do 24. godine prema stečenoj razini obrazovanja i prema spolu. Na prvi mah može se uočiti kako je skoro 60% zaposlenih sa srednjom stručnom spremom i to prevladavaju muškarci, a upola manje je zaposlenih sa niskom stručnom spremom gdje također prevladavaju muškarci s 26,6%. Dok je najmanje zaposlenih s visokom stručnom spremom i tu prevladavaju žene s 21%.

Istraživanje Kramarza i Skansa (2014) pokazalo je kako je pronalazak prvog posla nakon završetka obrazovanja povezan sa snažnim roditeljskim vezama. Bolje rečeno, pokazalo se kako će većina niskoobrazovanih mladih osoba svoje prvo zaposlenje započeti u poduzećima gdje im rade roditelji. Čini se kako visokoobrazovani mladi imaju snažnije veze kroz obrazovanje i u društvenom životu od onih manje obrazovanih stoga se pretpostavlja da manje koriste roditeljske veze pri prvom zaposlenju. Također, roditeljima je u cilju da im se djeca čim prije zaposle kako bi mogli biti financijski neovisni od njih. Negativne strane za mlade su što najčešće taj prvi posao nije vezan uz njihovu struku za koju su se educirali te je početna plaća niska. Na drugu stranu pogodnosti su sljedeće: kraća je potraga za prvim poslom te se zapošljavaju u produktivnim i stabilnim poduzećima gdje mogu ostvariti visoku plaću. Također, analiza

je pokazala da poduzeća prihvaćaju mlade koji su niže obrazovani jer ih uspoređuju s njihovim roditeljima koji imaju dugačak radni staž i veće plaće te se oslanjaju da će i njihova djeca polučiti takvu radnu kvalitetu za njihovo poduzeće.

2.3. NEET skupine na području Europske unije

Kako je na početku rada spomenuto, teško je govoriti o zaposlenosti kod mladih, a ne dotaknuti se teme nezaposlenosti mladih te unatoč smanjenu i dalje velikom udjelu mladih osoba u NEET statusu. U 2019. godini 3,3 milijuna mladih i dalje je nezaposleno u Europskoj uniji što znači da je stopa nezaposlenosti mladih poprilično velika usporedivši je s ukupnom stopom nezaposlenosti koja je nešto manja od 7%. Prema izvješću Eurofounda iz 2016. godine, u 2013. godini zabilježena je najviša razina nezaposlenosti mladih u Europskoj uniji sa više od 5,5 milijuna u dobi od 15. do 24. godine.

Prema Eurofoundu (2016) kratica NEET (engl. Not in Employment, Education or Training) označava skupinu mladih ljudi od 15. do 24. godine koji nisu zaposleni niti su u sustavu formalnog obrazovanja i osposobljavanja. Ono što je zajedničko svima u NEET skupini, jest neiskorišteni ljudski kapital kojeg ti mladi posjeduju odnosno imaju manje šanse pri budućem zapošljavanju te su u riziku od društvene isključivosti. Pojam NEET je neizostavna tema u raspravama u Europskoj uniji od 2010. godine, dok se sam pojam pojavljuje još 1990-ih godina u Velikoj Britaniji, kada se raspravljalo o nužnosti ponovnog uključivanja mladih od 16 do 18 godina koji su napustili obrazovanje i nisu prešli na tržište rada. Te 2010. godine najviše je u središtu rasprava bilo riječ o NEET populaciji i to u kontekstu programa Europa 2020 pod inicijativom „Mladi u pokretu“ (eng. „*Youth on the move*“). Pojam NEET se proširio na populaciju od 15 do 24, a kasnije i na one u dobi od 15 do 29 godina.

Jedan od glavnih ciljeva Garancije mladih iz 2013. godine je smanjenje broja mladih u NEET skupini, a također i osigurati dobivanje kvalitetne ponude poslova, nastavka obrazovanja, naukovanja ili pripravništva kako je već ranije spomenuto u roku od četiri mjeseca od završetka formalnog obrazovanja ili ulaska u nezaposlenost.

NEET pokazatelj je alat kojim se želi uzeti u obzir velika ranjivost mladih pri sudjelovanju na tržištu rada te istaknuti opasnost od društvene isključivosti. Pomoću nekoliko pokazatelja moguće je doći do konkretnih izazova i karakteristika, koje bi

pažljivo skrojene političke inicijative mogle učinkovito riješiti. Riječ je o idućim pokazateljima (Eurofound, 2016):

1. **Socio-demografski faktori** - istraživanje je pokazalo kako udio NEET populacije raste s porastom godina, a najveći rizik da postanu dio te populacije imaju mlade žene.
2. **Obrazovni uspjeh** - najveći udio u NEET populaciji čine osobe sa sekundarnom razinom obrazovanja. Međutim, pokazalo se kako s višom razinom obrazovanja, opada rizik od postanka dijelom NEET populacije te je obrazovanje najbolja zaštita od nezaposlenosti i društvene isključenosti.
3. **Registracija pri zavodima za zapošljavanje** (eng. *Public Employment Services – PES*) - pokazalo se kako je više od polovice NEET skupine nezaposleno, dok njih oko 70% bi htjelo raditi, samo 57% NEET osoba registrirano je pri zavodima za zapošljavanje, a preko zavoda se koriste mjere Garancije mladih.
4. **Kompozicija NEET populacije** – više od polovice NEET populacije sastoji se od kratkoročno i dugoročno nezaposlenih.
5. **Varijacije između grupa država** – široke su varijacije između zemalja članica Unije u veličini i kompoziciji NEET populacije. Na primjer, u nordijskim, zapadnim i kontinentalnim zemljama najveći dio te populacije je kratkoročno nezaposlen. U južnim i mediteranskim zemljama najviše je dugoročno nezaposlenih i obeshrabrenih radnika, dok su u istočnim zemljama žene u najvećem riziku postajanja NEET osobama najčešće zbog majčinskih i obiteljskih obveza.

Pojam NEET populacije uključuje različite podskupine različitih karakteristika i potreba. Kako se dobna granica NEET populacije povećala od one izvorne od 16 do 18 godina na one u dobi od 15 do 29 godina, proširila se i heterogenost među populacijom na koju se odnosi. Navedenu populaciju čine i ranjivi i neranjivi mladi kojima je zajedničko to što posjeduju znanja i mogućnosti koja nisu dovoljno iskorištena putem obrazovnog i tržišnog sustava. A riječ je o sljedećih sedam podskupina (Eurofound, 2016):

1. **Ponovno upisani** –odnosi se na one mlade ljude koji će se uskoro ponovno zaposliti, ući u sustav obrazovanja ili osposobljavanja. Nadalje, odnosi se na one mlade koji će u skorije vrijeme započeti/nastaviti s obrazovanjem i

zaposlenjem, te na mlade koji su već zaposleni ili upisani u obrazovanje ili obuku.

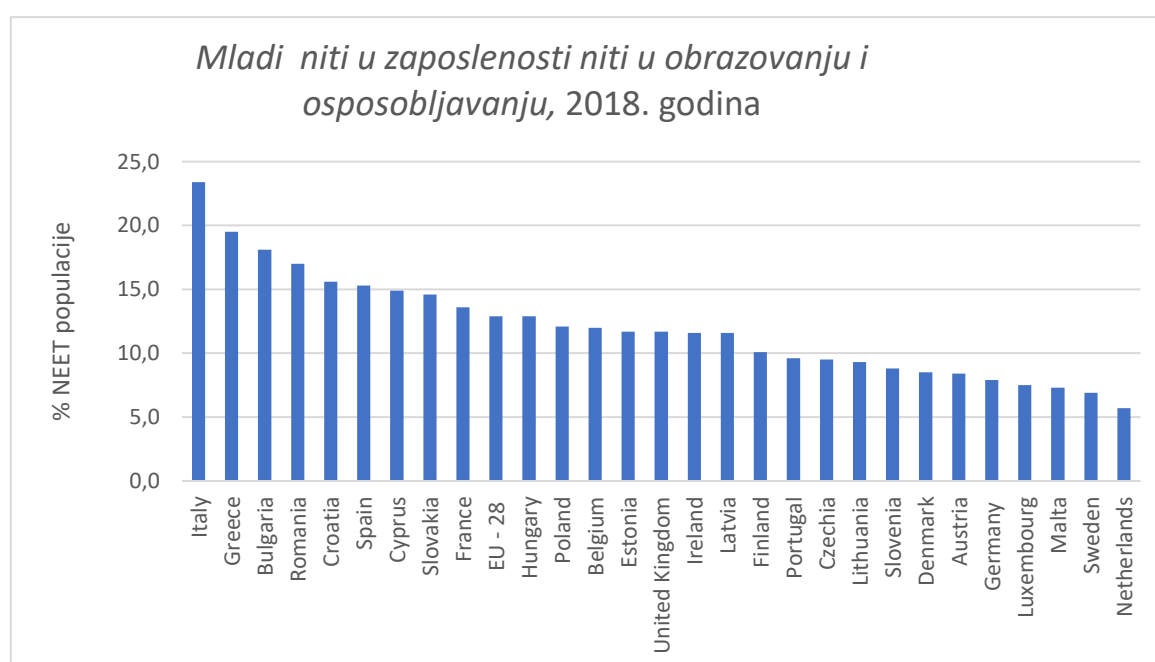
2. **Kratkotrajno nezaposleni** – odnosi se na sve mlade koji su nezaposleni manje od godine dana, a traže zaposlenje i u mogućnosti su započeti s radom unutar dva tjedna. Također, smatra se normalnim kratka prirodna nezaposlenost pri prelasku iz obrazovanja u svijet rada.
3. **Dugotrajno nezaposleni** – odnosi se na osobe koje su nezaposlene duže od godinu dana, a traže zaposlenje i u mogućnosti su započeti s radom unutar dva tjedna. Dugotrajno isključivanje sa tržišta rada može naštetiti zaposlenjima kod mladih, njihovom ljudskom kapitalu te budućnosti.
4. **Nedostupni zbog bolesti ili nesposobnosti** – uključuje osobe koje nisu u mogućnosti tražiti zaposlenje radi bolesti ili nesposobnosti kroz dva tjedna te uključuje osobe koje trebaju veću društvenu podršku jer nisu u mogućnosti započeti sa zaposlenjem radi bolesti ili nesposobnosti.
5. **Nedostupni zbog obiteljskih obaveza** – uključuje osobe koje ne traže zaposlenje ili nisu u mogućnosti započeti s radom radi čuvanja djeteta ili hendikepiranih odraslih osoba ili radi ostalih osobnih ili obiteljskih obaveza. U ovoj podskupini ima i ranjivih i onih manje osjetljivih jer neki od njih nisu aktivirani na tržištu rada zato što si ne mogu novčano priuštiti skrb za dijete ili odraslog člana obitelji, dok drugi svojom voljom odustaju od aktivacije na tržištu rada ili sustava obrazovanja kako bi se posvetili obiteljskim obavezama.
6. **Obeshrabreni radnici** – odnosi se na osobe koje su prestale tražiti posao radi osjećaja da su radne mogućnosti za njih nedostupne. To je uglavnom ranjiva podskupina mladih koje karakterizira veći rizik socijalne isključenosti od ostalih te rizik od doživotnog prekida rada.
7. **Ostale NEET osobe** – riječ je o posebno heterogenoj podskupini koja uključuje različite osobe koje nisu pojasnile razlog stjecanja ovog statusa. Ovo je najranjivija podskupina mladih osoba koje traže zaposlenje, ali nisu u mogućnosti započeti s istim radi razloga koji nisu specificirani ili radi vojne službe ili imaju malu prisutnost u sustavu obrazovanja i na tržištu rada.

Prema Bruno i sur. (2014) veća opasnost od porasta nezaposlenosti jest porast populacije u NEET skupini jer se povećava rizik tzv. izgubljene generacije. Pod terminom „izgubljena generacija“ smatraju se osobe koje su duže vrijeme izvan tržišta

rada te s vremenom gube doticaj s vještinama koje su potrebne na tržištu rada te im se smanjuje mogućnost zapošljavanja. Poslodavci će stoga radije uposliti osobe koje traže posao ali su kraće vrijeme odsutne s tržišta rada.

Bedeniković (2017) u svojem osvrtnu na NEET populaciju ističe kako je bitan zajednički konsenzus država članica pri donošenju aktivnih politika, te kako je bitno momentalno djelovati kada su u pitanju mladi, obrazovanje i nezaposlenost jer su oni nositelji budućeg razvoja i opstanka svake zemlje.

Grafikon 3. Mladi (15-29) niti u zaposlenosti niti u obrazovanju i osposobljavanju, 2018.



Izvor: Izrada autora prema Eurostatu (mrežni kod podataka: edat_lfse_20)

Na grafikonu 3. vidljivi su podaci o udjelu mladih u dobi od 15. do 29. godine u NEET skupini u zemljama članicama Europske unije iz 2018. godine. Vidljive su razlike u stopama, tako su najveće stope u Italiji (23,4%) i Grčkoj (19,5%). Također zemlje koje imaju stope NEET-a iznad prosjeka EU-28 od 12,9% su: Bugarska, Rumunjska, Hrvatska, Španjolska, Cipar, Slovačka i Francuska. Na grafu je vidljivo da Nizozemska ima najnižu stopu NEET populacije (5,7%) što je čak 4 puta manje od Italije.

3. OTKRIVANJE ZNANJA U BAZAMA PODATAKA

U ovome poglavlju teorijski će se približiti proces otkrivanja znanja iz baza podataka (eng. Knowledge discovery in databases), navest će se njezine česte primjene i metode kojima se vrijedni podaci „rudare“ iz velikih količina podataka, za određene svrhe.

3.1. Uvod u otkrivanje znanja iz baza podataka

Napredak tehnologije omogućio je lakše upravljanje i analiziranje podacima te pretvaranje podataka u korisne informacije. Pomoću otkrivanja znanja iz baza podataka poduzeća mogu olakšati svoje poslovanje koristeći na pravi način velike količine podataka koje svakodnevno pohranjuju u svojim bazama. Možda te silne informacije na prvi pogled nemaju svoju svrhu osim nagomilavanja u skladištima podataka (eng. Data warehouse), ali koristeći se tehnologijom Velikih podataka (eng. Big Data) i alatima za rudarenje podataka (eng. Data mining) mogu se otkriti vrijedne informacije koje mogu pomoći poduzećima u napretku različitih segmenata poslovanja, zadržavanju klijenata te donošenju boljih strateških odluka. Najčešće primjene su u sektorima bankarstva, trgovine, telekomunikacija, medicini te u ostalim djelatnostima koja se služe poslovnom inteligencijom (eng. Business Intelligence, BI).

Otkrivanje znanja iz baza podataka podrazumijeva rješavanje zadanog poslovnog „problema“ na način da algoritmi analiziraju podatke koji se već nalaze u bazama podataka. Te tehnike za pronalaženje i analizu podataka iz baza u kojima se nalaze pripadaju tzv. strojnom učenju (eng. Machine learning). Rezultati provedbe analize nad podacima dovode do korisnih podataka ili bolje rečeno saznanja kojima se ostvaruje ekonomska prednost. (Witten i Frank, 2005). Sam proces otkrivanja znanja iz baza podataka je iterativan, što znači da se tijekom procesa moguće vratiti na prethodne korake kako bi se izmijenili postojeći podaci. Proces se sastoji od nekoliko koraka (Pejić Bach i Kerep, 2011):

1. Definicija poslovnog problema
2. Priprema podataka
3. Modeliranje
4. Implementacija

U prvom koraku najvažnije je postaviti problem i to u obliku pitanja kako bi se na kraju procesa mogao saznati odgovor, a to je zadatak menadžera. U drugom koraku

potrebno je dohvatiti tražene podatke pohranjene u skladištima, a najčešće korišteni podaci za analizu su oni iz transakcijskih baza i baza klijenata. Obzirom da je riječ o velikoj količini podataka, najčešće se uzima manja količina podataka, te se izbacuju netipični podaci čije vrijednosti u većoj mjeri odstupaju od uzorka, iz tog razloga potrebno je provesti pripremu podataka. Podatke je potrebno posložiti u tablice na način da se u recima nalaze opažanja, a u stupcima varijable. U trećem koraku potrebno je odrediti metodu kojom će se riješiti poslovni problem, tri su metode rudarenja podataka: klasifikacija, predviđanje i grupiranje o kojima će biti više riječi u poglavlju 3.4. Podaci se ubacuju u neki od ponuđenih alata za rudarenje podataka, od besplatno dostupnih alata ističu se Weka, Rapid Miner, Alpha Miner i Knime, a od alata dostupnih na tržištu ističu se Statistica Data Miner, SAS Enterprise Miner i IBM Intelli Miner. Nakon završenog procesa obrade podataka slijedi posljednji korak implementacije, koji se odnosi na prezentiranje rezultata modeliranja, najčešće u obliku grafikona, kako bi menadžerima bilo olakšano razumijevanje i interpretiranje dobivenih rezultata.

3.2. Područja primjene otkrivanja znanja iz baza podataka

Podaci koje poduzeća i korporacije prikupljaju godinama kroz svoje baze klijenata, transakcija i sl. vrlo su vrijedna imovina čija se vrijednost povećala unaprijeđenjem alata za rudarenje podataka. U uvodnom dijelu istaknuta je široka primjena procesa ekstrakcije znanja iz baza podataka u različitim djelatnostima, a u ovome dijelu rada поближе je pojašnjeno kako se ono može primijeniti u realnom sektoru na primjerima iz svakodnevnog života. Han i sur. (2012) navode u sljedećim primjerima, primjenu metoda za otkrivanje znanja iz baza podataka:

1. Analiza podataka u financijskim institucijama

Poslovne banke i druge financijske institucije poput osiguravajućih društava, investicijskih i novčanih fondova i sl. nude različite usluge svojim klijentima kao što su usluge bankarstva, davanje kredita, različite vrste osiguranja, ulaganja u fondove i ostalo. Prilikom pristupanju ili korištenju navedenih usluga, financijske institucije prikupljaju naše podatke uz privolu, koji se smještaju u skladište podataka te postaju kvalitetan i pouzdan izvor informacija za analizu pomoću tehnika za rudarenje. Neki od primjera su:

analiza kreditne sposobnosti klijenta te predviđanje otplate kredita, razvrstavanje i grupiranje klijenata za provedbu ciljanog marketinga te otkrivanje financijskih prevara. Za banke kao kreditne institucije važno je procijeniti kreditnu sposobnost klijenta te predvidjeti otplatu kredita, a u tome im pomažu navedeni faktori: visina mjesečnih prihoda, razina obrazovanja, mjesto stanovanja, kreditna povijest klijenta, rok otplate kredita, iznosa kredita, omjer duga, omjer mjesečnih rata i mjesečnih primanja i slično. Kako bi se djelatnicima u banci olakšala procjena kreditne sposobnosti klijenata, koriste se metode za rudarenje podataka koje će prepoznati klijente s rizičnim faktorima za otplatu kredita. Nadalje, pomoću metoda klasifikacije i grupiranja mogu se odrediti ciljane skupine nad kojima bi se provodile određene marketinške aktivnosti. Kako bi se banke zaštitile od pranja novca i drugih malverzacija u svome poslovanju, koriste se vizualizacijom podataka, klasifikacijskim alatima i klaster analizom te vanjskim alatima za analizu. Istovremeno prateći transakcijske baze podataka i sumnjiva kretanja novčanih tokova i prijenosa novčanih sredstava.

2. Analiza podataka u maloprodajnoj industriji

Obzirom na velike količine podataka koje se svakodnevno prikupljaju o kupcima, prodaji, prijevozu i potrošnji robe bilo kroz fizičke prodavaonice ili kupovinom putem interneta kroz e-trgovinu, maloprodaja je idealna djelatnost za ekstrakciju korisnih podataka. Korištenjem alata za rudarenje podataka moguće je otkriti ponašanje kupaca, trendove u kupovini, poboljšati zadovoljstvo kupaca, reducirati troškove poslovanja kroz bolju logistiku transporta i distribucije robe. Kroz oglašavanje, prodajne kupone i popuste djeluje se na privlačenje kupaca i povećanje prodaje određenih artikala, a ti podaci se koriste u analizi učinkovitosti prodajnih kampanja kojom se putem asocijativne analize može saznati koji proizvodi će dodatno biti kupljeni skupa s proizvodima na koje se ciljalo prije provedbe kampanje. Također, maloprodajni lanci mogu putem kartica lojalnosti kroz programe vjernosti prikupljati podatke o kupovini u različitim periodima i tako analizirati potrošače i promjene u njihovim navikama kako bi im se mogli prilagoditi, zadržati ih te potencijalno doći do novih kupaca.

3. Analiza podataka u telekomunikacijskoj industriji

Zahvaljujući tehnologiji, telekomunikacijska industrija je vrlo brzo uznapredovala, nudeći svoje usluge i spajajući ljude širom svijeta. Korištenjem pametnih telefona, Interneta, e-pošte i drugim načinima prijenosa podataka, omogućilo se svakodnevno

prometovanje velikim količinama podataka. Zbog enormnih količina podataka koje svakodnevno pristižu, stručnjaci su se odlučili na izgradnju velikih skladišta podataka i korištenje višedimenzionalnih analiza podataka (eng. OLAP) te su primijenili alate kojima bi mogli analizirati trendove te otkrivati znanja u bazama podataka. Rudarenjem tih podataka unaprijedilo se kvalitetnije pružanje dotadašnjih usluga, smanjili su se troškovi poslovanja, omogućeno je analiziranje kupaca i njihovog ponašanja kako bi ih se zadržalo i privuklo nove klijente te na vrijeme prepoznali prijevare. Rudarenje podataka u ovoj industriji odvija se na vrlo sličan način kao i u maloprodaji.

4. Analiza podataka u prirodnim znanostima, inženjeringu i računarstvu

Zahvaljujući naprednoj tehnologiji koja se koristi u različitim znanstvenim područjima uključujući astronomiju, geologiju, kriminalistiku, bioinformatiku i dr. kao što su sofisticirani teleskopi, satelitski senzori i računalne metode za sakupljanje, obradu i prikaz bioloških podataka, podaci se prikupljaju i skladište kao nikad prije. Nekad teško dostupni znanstveni podaci danas su nadohvat ruke za obradu i korištenje. Kada govorimo o znanstvenim podacima najčešće je riječ o nestrukturiranim i polustrukturiranim podacima primjerice u bioinformatici koja zahtjeva sofisticirane metode za rudarenje skupova bioloških podataka.

U inženjerstvu se također prikupljaju velike količine složenih podataka koji najprije iziskuju obradu te skladištenje kako bi se na poslijetku moglo rudariti tim složenim podacima. Danas su sve učestalija rudarenja podataka u društvenim znanostima i studijama kroz vijesti, web stranice, članke, društvene mreže i reklame, kroz koje se dolazi do povratnih informacija od korisnika kako bi se provođenjem analiza moglo ustanoviti stavove korisnika te predvidjeti nadolazeći trendovi. Rudarenje podacima u računarstvu je korisno iz više razloga tako primjerice može pomoći u detektiranju softverskih pogrešaka, u otkrivanju napada na sustav i samu bazu podataka koja u sebi također sadrži velike količine podataka, analizi kvarova računalnih sustava, napada na mrežu i ostalog.

3.3. Važnost primjene otkrivanja znanja iz baza podataka

U prethodnom poglavlju iznesene su neke od učestalih industrija u kojima se često koristi otkrivanje znanje iz baza podataka. Naravno, primjena je puno šira, ali ono što industrije dijele su velike količine nagomilanih podataka u skladištima ili bazama koje u sebi skrivaju vrijedne informacije te sama metodologija. Primjenom rudarenja

podataka u jednoj industriji stječu se određena znanja i iskustva koja se mogu primijeniti i na ostale. Važnost primjene otkrivanja znanja u bazama podataka očituje se u sve brže rastućim bazama podataka u kojima se kriju vrlo vrijedne informacije.

Razvojem poslovanja pojavila se sve veća potreba za korištenjem tehnika rudarenja podataka čija je važnost primjene u detekciji i rješavanju raznovrsnih problema u poslovanju i otkrivanju obrazaca ponašanja. Na primjeru maloprodaje, a tako i u ostalim granama, ova tehnika omogućuje povezivanje kupaca s pružateljima usluga (Indu i Gunmala, 2019). Stoga su poduzeća širom svijeta prepoznala rudarenje podataka kao tehnike kojima će unaprijediti svoje poslovanje odnosno pomoći im u lakšem donošenju poslovnih odluka te će im u konačnici pomoći u ostvarivanju konkurentne prednosti (Kaya Keleş, 2017).

Proučavanjem 14 istraživačkih članaka analizirala su se 33 algoritma za rudarenje podataka u periodu od 2010. do 2017. godine koja su se primijenila u specifičnim područjima u poslovnome svijetu. Riječ je o metodama klasifikacije, otkrivanja te metodama za predviđanje vrijednosti koje su pokazale izrazitu važnost, kako u otkrivanju financijskih prijevara, otkrivanju napada na sustave tako i u upravljanju odnosima s kupcima (eng. Customer Relationship Management, CRM) i predviđanju bankrota (Lin. i sur. 2017).

3.4. Prikaz metoda za otkrivanje znanja iz baza podataka

Proces otkrivanja znanja iz baza podataka je složen postupak koji se temelji na znanjima iz statistike, matematike, umjetne inteligencije (eng. Artificial Intelligence), podacima iz baza podataka i vizualizaciji. Rudarenje podataka možemo podijeliti u tri skupine metoda: metode za klasifikaciju, predviđanje vrijednosti i otkrivanje podataka (Pejić Bach, 2005 prema Berry et. al., 2000).

1. Metode za klasifikaciju podataka

Prema Hanu i sur. (2012) riječ je o metodama kojima se žele predvidjeti događaji, konkretno hoće li se ili neće dogoditi. Klasifikacijskim metodama želi se predvidjeti klasa objekta tj. pronaći model koji će pomoću zavisnih ulaznih atributa predvidjeti vrijednost izlaznog (klasnog) atributa (eng. class). Najčešće korištene klasifikacijske metode su: stablo odlučivanja, klasifikacijska pravila, neuronske mreže, Bayesov klasifikator, metoda k-najbližih susjeda.

Stabla odlučivanja su jedna od češće korištenih klasifikacijska metoda kod kojih je specifično što se model dijagrama tijekom prikazuje u obliku stabla kod kojeg svaki čvor predstavlja test atributa, svaka grana označava ishod tog testa dok lišće stabla predstavlja klasu. Najviši čvor u dijagramu je korijenski čvor. Stabla odluke mogu se pretvoriti u klasifikacijska pravila (Han i sur., 2012). Klasifikacijske metode najčešće se koriste u bankama i osiguravajućim kućama kod predviđanja rizika prevare ili češće rizika naplate.

2. Metode za predviđanje vrijednosti

Za predviđanje numeričkih vrijednosti od statističkih metodologija najčešće se koristi regresijska analiza iako postoje i druge metode kao što su neuronske mreže i metode vremenskih serija. Kada se predviđa događaj s numeričkim ishodom vrijednosti, a da su pritom korišteni i numerički atributi, primjerice buduća potrošnja plina u nekom razdoblju, najidealnije rješenje za analizu je upravo linearna regresija (Han i sur., 2012).

3. Metode za otkrivanje podataka

Posljednja od tri glavne skupine metoda za rudarenje podataka obuhvaća metode klaster analize i asocijativna pravila koje otkrivaju homogene skupine podataka.

Klaster analiza je metoda segmentiranja pomoću koje podatke dijelimo u više homogenih skupina (eng. cluster, dalje u tekstu klaster) na način da su podaci u svakome klasteru međusobno slični, dok se svaki klaster pojedinačno mora razlikovati od ostalih (Zaki i Meira Jr., 2014). Klaster analiza za razliku od drugih multivarijantnih tehnika, varijable ne procjenjuje empirijski, umjesto toga koristi varijable koje je odredio sam istraživač. Cilj klaster analize je smještanje objekata sličnih svojstva u klastere s time da su objekti u jednom klasteru međusobno sličniji od objekata u drugim klasterima. Kako bismo ostvarili ciljeve ove analize potrebno je odgovoriti na tri temeljna pitanja: kako mjeriti sličnost između objekata, kako formirati klastere te kako utvrditi konačan broj klastera. Za mjerenje sličnosti ili različitosti objekata koriste se mjera udaljenosti poput Euklidske, Manhattana i Minkowskog. Klaster analiza koristi se za opis taksonomije, pojednostavljivanje podataka i identifikacija odnosa između objekata. Taksonomija razvrstava podatke u prirodne skupine na temelju sličnosti i razlika taksonomskih jedinica. Pojednostavljivanje podataka se odvija tako da podatke ne promatramo kao zasebno kao jedinstvene već kao skupinu sa sličnim svojstvima. Identifikacijom odnosa između objekata u klasteru se mogu pronaći objekti čiji odnos

nije moguće odrediti zasebnim promatranjem već se taj sakriven odnos može utvrditi klaster analizom. Na početku analize ne možemo znati konačan broj klastera, niti koji objekt pripada kojem klasteru. Postoji više tehnika za provođenje klaster analize. Dvije najpoznatije su hijerarhijske i nehijerarhijske (Hair et al., 2010). U istraživačkome dijelu ovoga rada korišten je nehijerarhijski algoritam k-srednjih vrijednosti (eng. Simple k-means algoritam) kod kojeg je unaprijed utvrđen broj klastera korištenjem sljedeće formule:

Slika 3. Formula za određivanje broja klastera

$$k \approx \sqrt{\frac{n}{2}}$$

gdje k označava broj klastera, a n broj opažanja. Tehnika k-srednjih vrijednosti ima za cilj podjelu n opažanja u k-klastera u kojima svako promatranje pripada klasteru s najbližom sredinom. K-means klasteriranje jedan je od najjednostavnijih nenadgledanih (eng. unsupervised) algoritama učenja koji rješavaju dobro poznate probleme klastera. Postupak se sastoji od nekoliko koraka. Prvenstveno treba odrediti k točke kao centroide za sve klastera. Sljedeći korak je povezati svaki podatak s najbližim centroidom. Nadalje, izračunavaju se novi položaji k centroida. Koraci se ponavljaju sve dok se centroidi više ne prestanu pomicati, tada je određivanje grupa završeno (Sharma, 2012). Nakon što se utvrdio konačan broj klastera i provela sama analiza smještanja objekata u homogene skupine, u posljednjoj fazi slijedi njihova interpretacija. Široku primjenu klaster analize nalazimo u identificiranju tržišnih segmenata, odnosno određivanju skupina potrošača sa sličnim preferencijama i obrascima ponašanjima.

Druga najpoznatija metoda grupiranja je analiza tržišne košarice kojom se želi otkriti kolika je vjerojatnost da će kupci prilikom jedne kupovine osim proizvoda kojeg žele, odlučiti se i za druge, njima povezane proizvode. Osim u maloprodaji ova analiza je primjenjiva i u drugim područjima kao što su bankarstvo, telekomunikacije i dr. Za provedbu ove analize koristi se metoda asocijativnih pravila. Najčešće se primjenjuje algoritam a priori pomoću kojeg se stvaraju pravila koja imaju svoju značajnost, pouzdanost i korelaciju (Pejić Bach i Kerep, 2011).

4. ISTRAŽIVANJE PODATAKA O ZAPOSLENOSTI KORIŠTENJEM OTKRIVANJA ZNANJA IZ BAZA PODATAKA

U ovome poglavlju provedena je Klaster analiza nad podacima te je opisan alat kojim su postignuti željeni rezultati. Nakon rezultata analize, raspravljalo se o prvotnim ciljevima koji su zadani prije same analize te su na kraju izneseni zaključci.

4.1. Metodologija istraživanja

U istraživačkome dijelu rada analizirana je zaposlenost mladih osoba u dobnoj skupini od 15 do 29 godina prema stupnju obrazovanja i spolu, u zemljama Europske unije. Podaci su preuzeti iz baze podataka Eurostata (Database), a obrađeni su u softverskom programu Weka.

Weka (eng. Waikato Environment For Knowledge Analysis) je alat osmišljen za rudarenje podataka (eng. Data mining), koji je za razliku od ostalih alata za rudarenje, otvorenog koda tj. dostupan je svim korisnicima Interneta. Temelji se na Java programskom jeziku. Weka ima jednostavna sučelja za korištenje te u sebi sadrži brojne algoritme za strojno učenje. Riječ je o sljedeća četiri sučelja za obradu podataka: Explorer, Experimenter, KnowledgeFlow i Simple CLI. Najčešće korišteno sučelje je Explorer u kojemu na jednostavan način učitavamo skupove podatke, pripremamo podatke, primjenjujemo algoritme strojnog učenja i vizualizaciju nad njima kako bi na lakši način došli do željenih rezultata. (Jović i sur., 2014).

Za potrebe ovog rada korištena je metodologija klaster analize koja je već ranije pobliže objašnjena. Korištena je iz razloga što je ovaj rad imao za cilj utvrditi mogu li se pojedine zemlje svrstati u homogene skupine obzirom na njihova slična obilježja, a za takvo grupiranje podataka, specifična je upravo klaster analiza. Klaster analizom zaposlenosti mladih među zemljama Europske unije dobiju se podaci, odnosno formiraju se klasteri kojima možemo uspoređivati zemlje i donositi zaključke. Cilj provedbe klaster analize je doći do saznanja koje su to skupine zemalja u kojima je zaposlenost mladih rastuća odnosno koje zemlje imaju niske stope zaposlenosti obzirom na sve tri razine obrazovanja. Nadalje, htjelo se utvrditi u kojoj mjeri razina obrazovanja utječe na samu zaposlenost te ima li razlike u zaposlenosti obzirom na spol.

Radi jednostavnije analize podataka i preglednosti, u istraživanju su korišteni setovi podataka od tri atributa. Tako su dobivene tri klaster analize obzirom na razinu obrazovanja koji mladi posjeduju.

U Tablici 1. navedeno je deset atributa korištenih za provedbu analize. Osim popisa atributa, moguće je vidjeti i njihov opis te format i pripadajuće modalitete.

Tablica 1. Atributi i formati atributa baze podataka

Naziv atributa	Opis atributa	Format atributa	Modaliteti atributa (nominalni)	Najmanja i najveća vrijednost numeričkih atributa
Zemlja	Zemlje EU	Nominalni	Belgija, Bugarska, Češka, Danska, Njemačka, Estonija, Irska, Grčka, Španjolska, Francuska, Hrvatska, Italija, Cipar, Litva, Latvija, Luksemburg, Mađarska, Malta, Nizozemska, Austrija, Poljska, Portugal, Rumunjska, Slovenija, Slovačka, Finska, Švedska, Ujedinjeno Kraljevstvo	/
Svi_nisko	Svi niskoobrazovani pojedinci	Numerički		Min 5 i max 7,3
M_nisko	Niskoobrazovani muškarci	Numerički		Min 5.4 i max 8.8
Ž_nisko	Niskoobrazovane žene	Numerički		Min 3.5 i max 5.6
Svi_srednje	Svi srednjeobrazovani pojedinci	Numerički		Min 32.4 i max 5.1
M_srednje	Srednjeobrazovani muškarci	Numerički		Min 35.5 i max 77.9
Ž_srednje	Srednjeobrazovane žene	Numerički		Min 25.9 i max 74.6

Svi_visoko	Svi visokobrazovani pojedici	Numerički		Min 48 i max 90.3
M_visoko	Visokoobrazovani muškarci	Numerički		Min 47.1 i max 93.7
Ž_visoko	Visokobrazovane žene	Numerički		Min 48.6 i max 89.7

Izvor: autorsko istraživanje

4.2. Rezultati istraživanja

Istraživački dio rada obuhvaća tri klaster analize zaposlenosti prema razini obrazovanja i spolu mladog stanovništva. Prva analiza bazirana je na zaposlenim mladima s niskom razinom obrazovanja, druga na zaposlenim mladima sa srednjom razinom obrazovanja, a treća na zaposlenim mladima s visokom razinom obrazovanja. Prema Eurostatu klasifikacija obrazovanja dijeli se na tri (ISCED) razine:

1. Manje od osnovnog, osnovno i niže srednje obrazovanje (ED 0-2)
2. Srednjoškolsko i obrazovanje nakon srednje škole koje nije ni više niti visoko obrazovanje (ED 3-4)
3. Više i visoko obrazovanje (ED 5-8).

Nakon što su se podaci obradili u Microsoft Office Excel-u, u softverski alat Weka učitani su podaci u .csv formatu u kartici Preprocess. Kao što je vidljivo na slici 4. odabrana je metoda klaster analize i algoritam Simple k-means kako bi se izvršilo grupiranje podataka u četiri klastera, čiji je broj prethodno dobiven korištenjem formule. Nakon što su izignorirani nepotrebni atributi za analizu, rezultati prve klaster analize prikazani su u prozoru Cluster output. Vidljivo je da vrijednost jednog od pokazatelja uspješnosti (Within cluster sum of squared errors) iznosi 0,46, a čim je niža vrijednost, povoljnija je i klaster analiza. Termin Clustered Instances na slici 5. pokazuje nam dobiveni broj klastera u analizu i pripadajući broj opažanja. Nakon provedene analize, na slici 6. prikazana su opažanja po klasterima kroz 2D prikaz koristeći opciju Visualize Cluster assignments. Dobiveni podaci spremljeni su u .arff formatu, te nakon što su opet učitani u Preprocess panelu, prikazana je nova rubrika „Cluster“ gdje se na slici 7. primjećuje broj zemalja u klasterima, dok atribut „Zemlja“ zorno prikazuje koja zemlja pripada kojem klasteru.

Slika 4. Prikaz klaster analize u Weki

The screenshot displays the Weka Explorer interface with the 'Cluster' tab selected. The 'Clusterer' dropdown is set to 'SimpleKMeans' with the command: `-init 0 -max-candidates 100 -periodic-pruning 10000 -min-density 2.0 -t1 -1.25 -t2 -1.0 -N 4 -A "weka.core.E`. The 'Cluster mode' section has 'Use training set' selected, 'Store clusters for visualization' checked, and 'Ignore attributes' set to '(Num) z_visoko'. The 'Clusterer output' pane shows the following text:

```
Scheme:      weka.clusterers.SimpleKMeans -init 0 -max-ca
Relation:    csv obrazovanje eu
Instances:   28
Attributes:  10
              svi_nisko
              m_nisko
              z_nisko

Ignored:
              ZEMLJA
              svi_srednje
              m_srednje
              z_srednje
              svi_visoko
              m_visoko
              z_visoko

Test mode:   evaluate on training data

=== Clustering model (full training set) ===

kMeans
=====

Number of iterations: 6
Within cluster sum of squared errors: 0.45843726815581615

Initial starting points (random):
```

The 'Result list' shows a single entry: '17:00:21 - SimpleKMeans'.

Izvor: autorsko istraživanje

Slika 5. Prikaz rezultata klaster analize

```

Cluster 0: 15,19.1,10.4
Cluster 1: 12.7,14.5,10.8
Cluster 2: 15,19.4,9.8
Cluster 3: 22.1,25.6,18.1

Missing values globally replaced with mean/mode

Final cluster centroids:

Attribute      Full Data      Cluster#
                (28.0)        (8.0)         1         2         3
=====
svi_nisko     23.1393        27.4          8.45      15.1111   48.4
m_nisko       26.5714        30.8625       11.1      19.0111   51.88
z_nisko       19.0964        23.225        5.5167    10.6778   43.94

Time taken to build model (full training data) : 0.01 seconds


=== Model and evaluation on training set ===

Clustered Instances

0      8 ( 29%)
1      6 ( 21%)
2      9 ( 32%)
3      5 ( 18%)
    
```


Izvor: autorsko istraživanje

Slika 6. Prikaz opažanja po klasterima u 2D prikazu



Izvor: autorsko istraživanje

Slika 7. Prikaz novog atributa Cluster



Izvor: autorsko istraživanje

1. Klaster analiza zaposlenih pojedinaca s niskom razinom obrazovanja i prema spolu

Tablica 2. prikazuje podatke temeljem kojih je izrađena klaster analiza zemalja prema zaposlenosti obzirom na nisku stručnu spremu, pri čemu su korišteni podaci o zaposlenosti svih mladih stanovnika Europske unije (15-29 godina) prema spolu i niskoj razini obrazovanja. Korišteni su podaci iz 2018. godine. Grafikon 4. prikazuje navedene podatke.

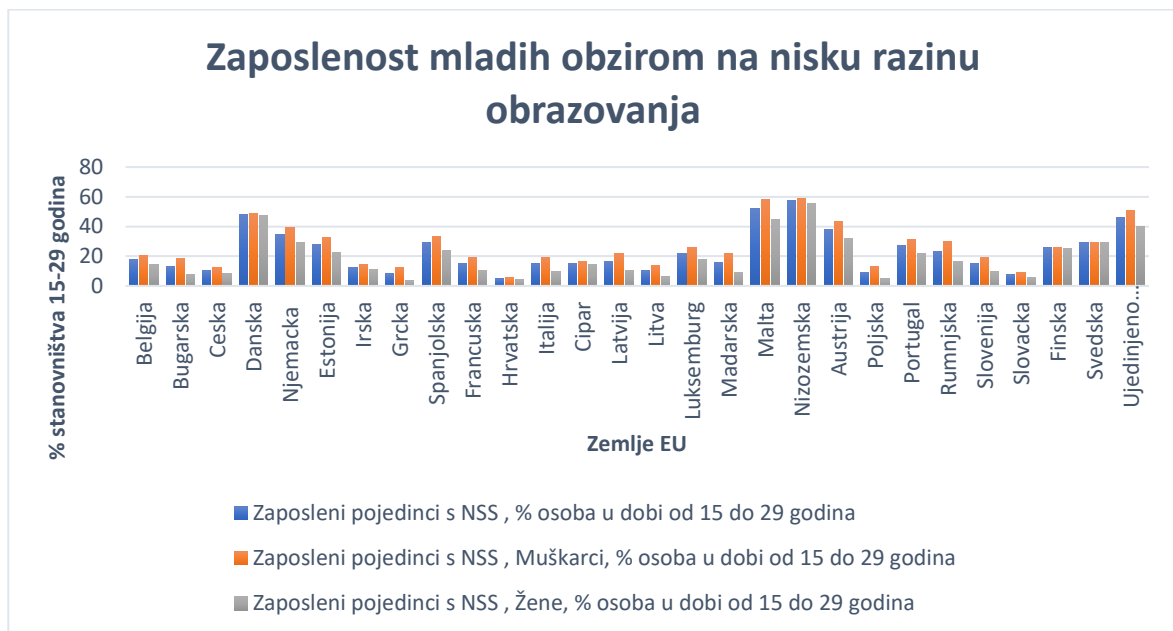
Tablica 2. Korišteni podaci za klaster analizu svih pojedinaca te pojedinaca prema spolu (2018. godina)

Zemlje Europske Unije	Zaposleni pojedinci s NSS, % osoba u dobi od 15 do 29 godina	Zaposleni pojedinci s NSS, Muškarci, % osoba u dobi od 15 do 29 godina	Zaposleni pojedinci s NSS, Žene, % osoba u dobi od 15 do 29 godina
Belgija	18	21	14
Bugarska	13	18	8
Češka	10	12	8
Danska	48	49	48
Njemačka	35	39	29
Estonija	28	33	23
Irska	13	15	11

Grčka	8	13	4
Španjolska	29	34	24
Francuska	15	19	10
Hrvatska	5	5	5
Italija	15	19	10
Cipar	15	16	14
Latvija	17	22	10
Litva	10	14	6
Luksemburg	22	26	18
Mađarska	16	22	9
Malta	52	58	45
Nizozemska	57	59	56
Austrija	38	43	32
Poljska	9	13	5
Portugal	27	31	22
Rumunjska	23	30	17
Slovenija	15	19	10
Slovačka	8	9	6
Finska	26	26	25
Švedska	29	29	29
Ujedinjeno Kraljevstvo	46	51	40

Izvor: autorsko istraživanje

Grafikon 4. Udio mladih obzirom na nisku razinu obrazovanja, svi i prema spolu, % stanovništva 15-29 godina



Izvor: autorsko istraživanje

Tablica 3. sadrži prosječne vrijednosti zaposlenosti mladih prema niskoj razini obrazovanja i spolu po klasterima temeljem podataka iz 2018. godine. U Klasteru A najveći je prosječan udio stanovnika s obzirom na zaposlenost niskoobrazovanih mladih za sve promatrane skupine (svi pojedinci – 48%, muškarci – 52% i žene – 44%). Klaster B sljedeći je obzirom na prosječan udio stanovnika s obzirom na zaposlenost niskoobrazovanih mladih za sve promatrane skupine (svi stanovnici – 28%, muškarci – 31% i žene – 23%). Klaster C treći je po redu obzirom na prosječan udio stanovnika s obzirom na zaposlenost niskoobrazovanih mladih za sve promatrane skupine (svi stanovnici – 15%, muškarci – 19% i žene – 11%). Na začelju je Klaster D obzirom na prosječan udio stanovnika obzirom na zaposlenost niskobrazovanih mladih za sve promatrane skupine (svi stanovnici – 8%, muškarci – 11% i žene – 6%).

Može se primijetiti kako je u svim klasterima udio muškaraca koji su zaposleni s niskom stručnom spremom nešto veći od udjela ukupnog mladog stanovništva te udjela žena. Dok je udio žena koje su zaposlene s niskom stručnom spremom nešto manji od udjela ukupnog mladog stanovništva. Grafikon 5. prikazuje navedene podatke.

Tablica 3. Prosječne vrijednosti zaposlenosti mladih s niskim obrazovanjem po klasterima (2018.-ta godina)

PROMATRANE SKUPINE	KLASTER A	KLASTER B	KLASTER C	KLASTER D
Pojedinci koji imaju nisko obrazovanje, % osoba od 15 do 29 godine	48	28	15	8
Pojedinci koji imaju nisko obrazovanje, Muškarci, % osoba od 15 do 29 godine	52	31	19	11
Pojedinci koji imaju nisko obrazovanje, Žene, % osoba od 15 do 29 godine	44	23	11	6

Izvor: autorsko istraživanje

Grafikon 5. Klasteri zemalja s obzirom na zaposlenost mladih s niskim obrazovanjem i prema spolu – prosječan udio stanovništva 15-29 godina (2018. godina)



Izvor: autorsko istraživanje

Tablica 4. sadrži podatke o pripadnosti pojedine zemlje klasteru s obzirom na zaposlenost mladih s niskom stručnom spremom i prema spolu u 2018.-toj godini. U klasteru A nalaze se zemlje koje su vodeće prema zaposlenosti mladih s niskom razinom obrazovanja za obje spolne skupine, u klasteru B nalaze se zemlje koje su u drugoj skupini, u klasteru C zemlje koje su u trećoj skupini, a u klasteru D nalaze se zemlje koje zaostaju.

Tablica 4. Pripadnost pojedine zemlje klasteru s obzirom na zaposlenost mladih obzirom na nisku razinu obrazovanja i prema spolu (2018.-ta godina)

Zemlja	Klaster
Danska	A
Malta	A
Nizozemska	A
Austrija	A
Ujedinjeno Kraljevstvo	A
Njemačka	B
Estonija	B
Španjolska	B
Luksemburg	B
Portugal	B
Rumunjska	B
Finska	B
Švedska	B
Belgija	C

Bugarska	C
Irska	C
Francuska	C
Italija	C
Cipar	C
Latvija	C
Mađarska	C
Slovenija	C
Češka	D
Grčka	D
Hrvatska	D
Litva	D
Poljska	D
Slovačka	D

Izvor: autorsko istraživanje

2. Klaster analiza zaposlenih pojedinaca sa srednjom razinom obrazovanja i prema spolu

Tablica 5. prikazuje podatke temeljem kojih je izrađena klaster analiza zemalja prema zaposlenosti obzirom na srednju stručnu spremu, pri čemu su korišteni podaci o zaposlenosti svih mladih stanovnika Europske unije (15-29 godina) prema spolu i srednjoj razini obrazovanja. Korišteni su podaci iz 2018. godine. Grafikon 6. prikazuje navedene podatke.


Tablica 5. Korišteni podaci za klaster analizu svih pojedinaca te pojedinaca prema spolu (2018. godina)

Zemlje Europske Unije	Zaposleni pojedinci sa SSS, % osoba u dobi od 15 do 29 godina	Zaposleni pojedinci sa SSS, Muškarci, % osoba u dobi od 15 do 29 godina	Zaposleni pojedinci sa SSS, Žene, % osoba u dobi od 15 do 29 godina
Belgija	48	54	41
Bugarska	48	55	40
Češka	65	76	51
Danska	73	74	71
Njemačka	73	74	71
Estonija	69	78	59
Irska	61	64	57
Grčka	32	38	26
Španjolska	34	36	32
Francuska	49	54	44
Hrvatska	51	60	41

Italija	40	47	33
Cipar	54	58	49
Latvija	63	70	56
Litva	58	64	51
Luksemburg	58	60	56
Mađarska	59	67	50
Malta	64	64	64
Nizozemska	75	76	75
Austrija	71	75	66
Poljska	63	73	49
Portugal	51	55	45
Rumunjska	51	58	42
Slovenija	64	69	58
Slovačka	64	75	50
Finska	67	71	64
Švedska	75	77	72
Ujedinjeno Kraljevstvo	64	68	60

Izvor: autorsko istraživanje

Grafikon 6. Udio mladih obzirom na srednju razinu obrazovanja, svi i prema spolu, % stanovništva 15-29 godina



Izvor: autorsko istraživanje

Tablica 6. sadrži prosječne vrijednosti zaposlenosti mladih prema srednjoj razini obrazovanja i spolu po klasterima temeljem podataka iz 2018. godine. U Klasteru A najveći je prosječan udio stanovnika s obzirom na zaposlenost srednjeobrazovanih mladih za sve promatrane skupine (svi pojedinci – 72%, muškarci – 75% i žene – 68%).

Klaster B sljedeći je obzirom na prosječan udio stanovnika s obzirom na zaposlenost srednjeobrazovanih mladih za sve promatrane skupine (svi stanovnici – 62%, muškarci – 68% i žene – 55%). Klaster C treći je po redu obzirom na prosječan udio stanovnika obzirom na zaposlenost srednjeobrazovanih mladih za sve promatrane skupine (svi stanovnici – 50%, muškarci – 56% i žene – 43%). Na začelju je Klaster D obzirom na prosječan udio stanovnika s obzirom na zaposlenost srednjeobrazovanih mladih za sve promatrane skupine (svi stanovnici – 35%, muškarci – 40% i žene – 30%).

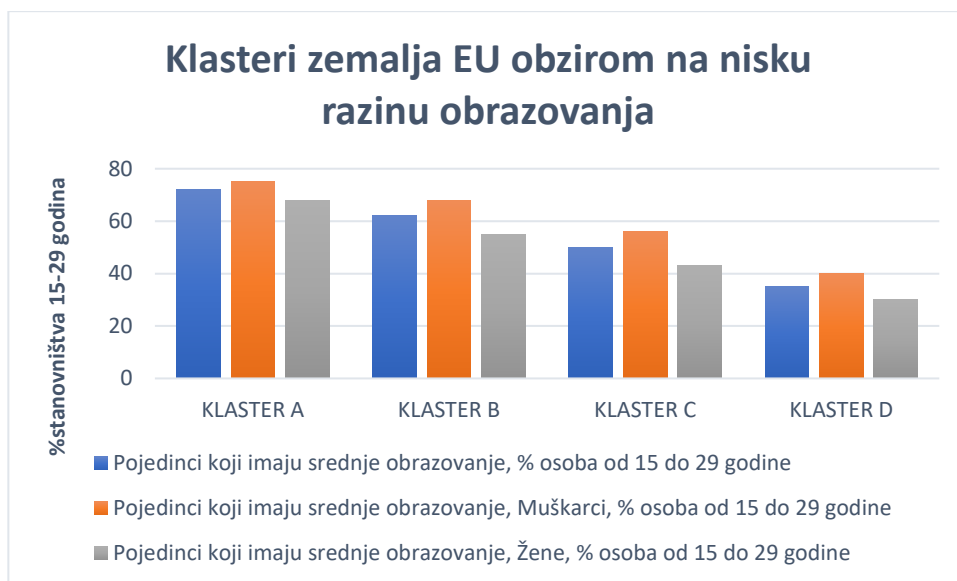
Može se primijetiti kako je u svim klasterima udio muškaraca koji su zaposleni sa srednjom stručnom spremom nešto veći od udjela ukupnog mladog stanovništva i veći udio od žena dok je udio žena koje su zaposlene sa srednjom stručnom spremom nešto manji od udjela ukupnog mladog stanovništva. Grafikon 7. prikazuje navedene podatke.

Tablica 6. Prosječne vrijednosti zaposlenosti mladih sa srednjom razinom obrazovanja po klasterima (2018.-ta godina)

PROMATRANE SKUPINE	KLASTER A	KLASTER B	KLASTER C	KLASTER D
Pojedinci koji imaju srednje obrazovanje, % osoba od 15 do 29 godine	72	62	50	35
Pojedinci koji imaju srednje obrazovanje, Muškarci, % osoba od 15 do 29 godine	75	68	56	40
Pojedinci koji imaju srednje obrazovanje, Žene, % osoba od 15 do 29 godine	68	55	43	30

Izvor: autorsko istraživanje

Grafikon 7. Klasteri zemalja s obzirom na zaposlenost mladih sa srednjom razinom obrazovanja i prema spolu – prosječan udio stanovništva 15-29 godina (2018. godina)



Izvor: autorsko istraživanje

Tablica 7. sadrži podatke o pripadnosti pojedine zemlje klasteru obzirom na zaposlenost mladih sa srednjom stručnom spremom i prema spolu u 2018. godini. U klasteru A nalaze se zemlje koje su vodeće prema zaposlenosti sa srednjom razinom obrazovanja za obje spolne skupine, u klasteru B nalaze se zemlje koje su u drugoj skupini, u klasteru C zemlje koje su u trećoj skupini, a u klasteru D nalaze se zemlje koje zaostaju.

Tablica 7. Pripadnost pojedine zemlje klasteru prema zaposlenosti mladih obzirom na srednju razinu obrazovanja i prema spolu (2018.-ta godina)

Zemlja	Klaster
Danska	A
Njemačka	A
Estonija	A
Nizozemska	A
Austrija	A
Finska	A
Švedska	B
Češka	B
Irska	B
Latvija	B
Litva	B
Luksemburg	B
Mađarska	B
Malta	B

Poljska	B
Slovenija	B
Slovačka	B
Ujedinjeno Kraljevstvo	B
Belgija	C
Bugarska	C
Francuska	C
Hrvatska	C
Cipar	C
Portugal	C
Rumunjska	C
Grčka	D
Španjolska	D
Italija	D

Izvor: autorsko istraživanje

3. Klaster analiza zaposlenih pojedinaca s visokom razinom obrazovanja i prema spolu

Tablica 8. prikazuje podatke temeljem kojih je izrađena klaster analiza zemalja prema zaposlenosti s visokom stručnom spremom, pri čemu su korišteni podaci o zaposlenosti svih mladih stanovnika Europske unije (15-29 godina) prema spolu i visokoj razini obrazovanja. Korišteni su podaci iz 2018.-te godine. Grafikon 8. prikazuje navedene podatke.

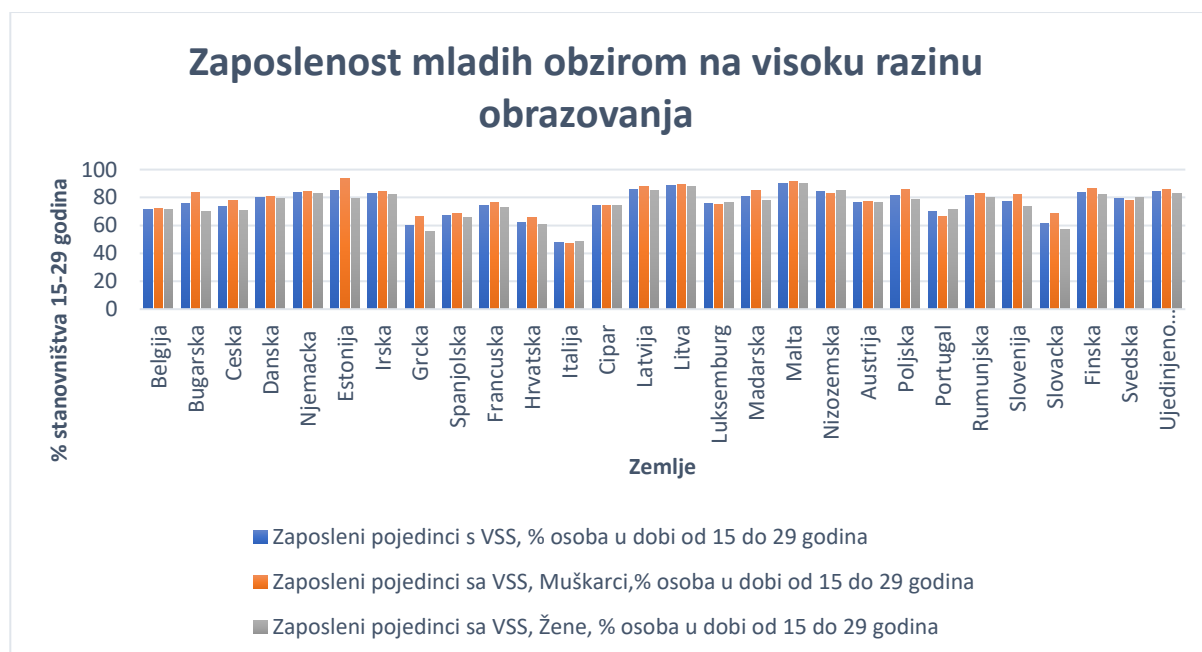
Tablica 8. Korišteni podaci za klaster analizu svih pojedinaca sa srednjom stručnom spremom i pojedinaca prema spolu (2018. godina)

Zemlje Europske Unije	Zaposleni pojedinci s VSS, % osoba u dobi od 15 do 29 godina	Zaposleni pojedinci sa VSS, Muškarci, % osoba u dobi od 15 do 29 godina	Zaposleni pojedinci sa VSS, Žene, % osoba u dobi od 15 do 29 godina
Belgija	72	72	71
Bugarska	76	84	70
Češka	74	78	71
Danska	80	81	79
Njemačka	84	85	83
Estonija	85	94	80
Irska	83	84	82
Grčka	60	67	56
Španjolska	67	69	66
Francuska	74	76	73

Hrvatska	62	66	60
Italija	48	47	49
Cipar	74	74	74
Latvija	86	88	85
Litva	89	89	88
Luksemburg	76	75	76
Mađarska	81	85	78
Malta	90	91	90
Nizozemska	84	83	85
Austrija	77	77	76
Poljska	81	85	79
Portugal	70	66	72
Rumunjska	81	83	80
Slovenija	77	82	74
Slovačka	62	69	57
Finska	84	87	82
Švedska	79	78	80
Ujedinjeno Kraljevstvo	84	86	83

Izvor: autorsko istraživanje

Grafikon 8. Udio mladih obzirom na visoku razinu obrazovanja, svi i prema spolu, % stanovništva 15-29 godina



Izvor: autorsko istraživanje

Tablica 9. sadrži prosječne vrijednosti zaposlenosti mladih prema visokoj razini obrazovanja i spolu po klasterima temeljem podataka iz 2018. godine. U Klasteru A najveći je prosječan udio stanovnika obzirom na zaposlenost visokoobrazovanih mladih

za sve promatrane skupine (svi pojedinci – 84%, muškarci – 87% i žene – 83%). Klaster B sljedeći je po prosječnom udjelu stanovnika obzirom na zaposlenost visokoobrazovanih mladih za sve promatrane skupine (svi stanovnici – 76%, muškarci – 78% i žene – 75%). Klaster C treći je po redu po prosječnom udjelu stanovnika obzirom na zaposlenost visokoobrazovanih mladih za sve promatrane skupine (svi stanovnici – 69%, muškarci – 69% i žene – 70%). Na začelju je Klaster D po prosječnom udjelu stanovnika obzirom na zaposlenost visokoobrazovanih mladih za sve promatrane skupine (svi stanovnici – 58%, muškarci – 62% i žene – 55%).

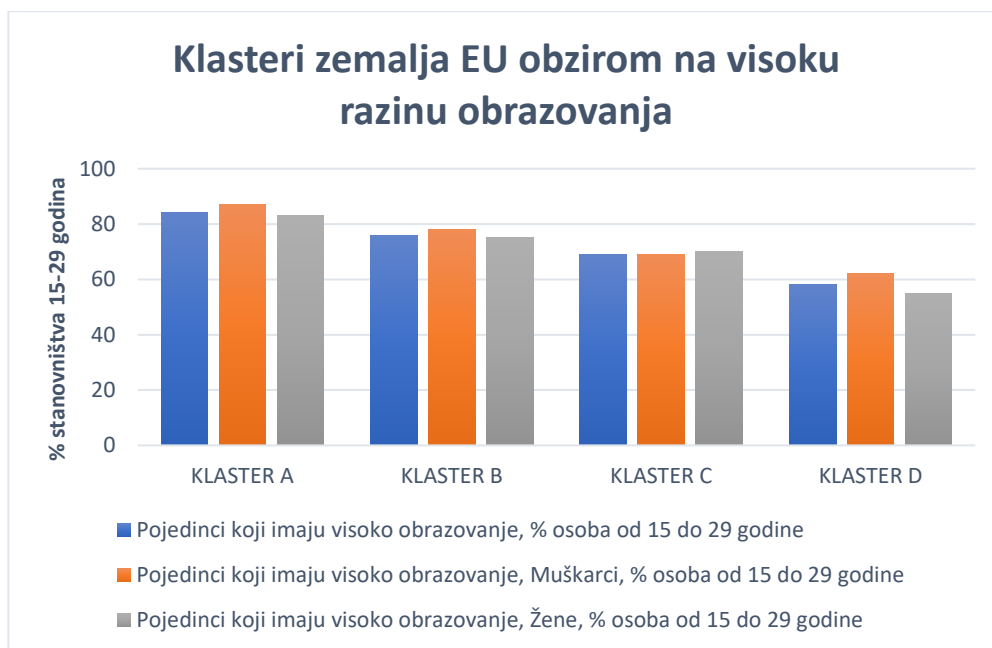
Može se primijetiti kako je u svim klasterima udio muškaraca koji su zaposleni s visokom stručnom spremom nešto veći od udjela ukupnog mladog stanovništva te udjela žena dok je udio žena koje su zaposlene s visokom stručnom spremom nešto manji od udjela ukupnog mladog stanovništva. Grafikon 9. prikazuje navedene podatke.

Tablica 9. Prosječne vrijednosti zaposlenosti mladih s visokom razinom obrazovanja po klasterima (2018.-ta godina)

PROMATRANE SKUPINE	KLASTER A	KLASTER B	KLASTER C	KLASTER D
Pojedinci koji imaju visoko obrazovanje, % osoba od 15 do 29 godine	84	76	69	58
Pojedinci koji imaju visoko obrazovanje, Muškarci, % osoba od 15 do 29 godine	87	78	69	62
Pojedinci koji imaju visoko obrazovanje, Žene, % osoba od 15 do 29 godine	83	75	70	55

Izvor: autorsko istraživanje

Grafikon 9. Klasteri zemalja s obzirom na zaposlenost mladih s visokom razinom obrazovanja i prema spolu – prosječan udio stanovništva 15-29 godina (2018.-ta godina)



Izvor: autorsko istraživanje

Tablica 10. sadrži podatke o pripadnosti pojedine zemlje klasteru obzirom na zaposlenost mladih s visokom stručnom spremom i prema spolu u 2018. godini. U klasteru A nalaze se zemlje koje su vodeće prema zaposlenosti s visokom razinom obrazovanja za obje spolne skupine, u klasteru B nalaze se zemlje koje su u drugoj skupini, u klasteru C zemlje koje su u trećoj skupini, a u klasteru D nalaze se zemlje koje zaostaju.

Tablica 10. Pripadnost pojedine zemlje klasteru s obzirom na zaposlenost mladih obzirom na visoku razinu obrazovanja i prema spolu (2018.-ta godina)

Zemlja	Klaster
Njemačka	A
Estonija	A
Irska	A
Latvija	A
Litva	A
Mađarska	A
Malta	A
Nizozemska	A
Poljska	A
Rumunjska	A
Finska	A

Ujedinjeno Kraljevstvo	A
Bugarska	B
Češka	B
Danska	B
Francuska	B
Cipar	B
Luksemburg	B
Austrija	B
Slovenija	B
Švedska	B
Belgija	C
Španjolska	C
Portugal	C
Grčka	D
Hrvatska	D
Italija	D
Slovačka	D

Izvor: autorsko istraživanje

4.3. Rasprava

Cilj provedbe klaster analize nad podacima bilo je saznati mogu li se zemlje Europske unije grupirati obzirom na zaposlenost mladih, u kojoj mjeri razina obrazovanja utječe na zaposlenost te ima li razlike u zaposlenosti obzirom na spol.

Nakon tri provedene analize zemlje su grupirane u četiri klastera prema sličnim razinama zaposlenosti i istoj razini obrazovanja. Tako u sve tri analize zemlje koje pripadaju A klasteru imaju najveće razine zaposlenosti, dok zemlje grupirane u D klasteru zaostaju s rezultatima za ostalim zemljama. Razina obrazovanja se pokazala kao relevantna pri zapošljavanju kod mladih ljudi budući da je u svih 28 zemalja članica najviše mladih zaposleno upravo sa visokom stručnom spremom. Nešto manji udio zaposlenih odnosi se na mlade sa srednjom stručnom spremom, dok su najmanje stope zaposlenosti zabilježene u skoro svim zemljama članicama kod mladih sa niskom stručnom spremom. Također, možemo vidjeti i na grafičkim prikazima kako su muškarci uglavnom u većoj stopi zaposleni od žena i u poslovima s niskom i sa srednjom razinom obrazovanja, dok u poslovima koji traže visoko kvalificirane zaposlenike, žene u malom postotku zaostaju za muškarcima.

U prvoj klaster analizi vidljiva je niska opća zaposlenost kod mladih osoba u većini zemalja članica, jedino se u A klasteru (Danska, Malta, Nizozemska, Austrija i Ujedinjeno Kraljevstvo) ističu pojedine zemlje sa donekle zavidnijim stopama zaposlenosti mladih s niskom stručnom spremom, prosjek im je 48%, dok se u klasteru D (Češka, Grčka, Hrvatska, Litva, Poljska i Slovačka) nalaze zemlje s najnižim stopama zaposlenosti mladih koja je u prosjeku 8% za oba spola. Vidljiva je velika oscilacija između klastera A i D.

U drugoj klaster analizi vidljiva je veća stopa zaposlenih mladih sa srednjom stručnom spremom, tako se u A klasteru (Danska, Njemačka, Estonija, Nizozemska, Austrija i Finska) nalazi i veći broj zemalja čiji je prosjek opće zaposlenosti 72%. Najmanje zemalja je obuhvaćeno u D klasteru (Grčka, Španjolska, Italija) koji ujedno najviše zaostaje za ostalim klasterima sa stopom zaposlenosti od 35% za oba spola, iako zaostaje u manjoj razini nego u prvom slučaju klaster analize.

U trećoj klaster analizi primjećuje se bolja slika od slučaja u prve dvije klaster analize. Tako u A klasteru (Njemačka, Estonija, Irska, Latvija, Litva, Mađarska, Malta, Nizozemska, Poljska, Rumunjska, Finska i Ujedinjeno Kraljevstvo) nailazimo na povećani broj zemalja koji imaju visoke stope zaposlenosti mladih s visokom stručnom spremom u prosjeku 84%, što se i očekuje, da visokoobrazovani mladi su ujedno i najtraženiji na tržištu rada. U D klasteru (Hrvatska, Grčka, Italija, Slovačka) nalazi se manji broj zemalja čija opća zaposlenost kod mladih iznosi u prosjeku za oba spola 58%.

Može se zaključiti kako mladi u zemljama s najvišim stopama zaposlenosti rade na poslovima za koje su educirani, odnosno usklađena je ponuda s potražnjom poslova.

Promatrajući zemlje u klasterima, vidljivo je kako se jedino Nizozemska ponavlja u A klasteru u sve tri provedene klaster analize. Što ju izdvaja kao zemlju s visokim udjelom zaposlenosti mladih bez obzira na razinu obrazovanja, možemo reći kako je to zemlja koja je prepoznala ljudski potencijal kod mladih osoba te svojim aktivnim politikama ulaže u obrazovanje, a na tržištu vlada dobar odnos ponude i potražnje poslova.

Uz Nizozemsku zemlje koje se ponavljaju u A klasteru barem u dvije od tri analize su: Danska, Malta, Austrija, Njemačka, Finska, Estonija i Ujedinjeno Kraljevstvo. Također je riječ o razvijenim zemljama koje su usvojile prijedloge Europske komisije o Garanciji mladih te pružile dodatnu izobrazbu mladima i uspostavile kvalitetnu ponudu poslova koju su mladi i prepoznali. Tako je Ujedinjeno Kraljevstvo povećalo sudjelovanje u

obrazovanju za sve mlade od 16 do 19 godina, pružajući im kroz svoje programe stjecanje radnog iskustva, najviše kroz naukovanje. Također Vlada je dala subvencije za plaće kako bi potakla mlade na rad. Njemačka je primjer zemlje koja je ulagala u stručno osposobljavanje mladih s niskom stručnom spremom kako bi se prekvalificirali te ulaže u formalno obrazovanje mladih, stoga i ne čude visoki udjeli u srednjem (73%) i visokom (84%) obrazovanju.

Sa druge strane vidimo zemlje koje zaostaju za ostalim zemljama, tako se Grčka nalazi u D klasteru kroz sve tri analize, dok se u dvije od tri analize u D klasteru još nalaze i Italija, Hrvatska i Slovačka. Problem niske zaposlenosti mladih sa srednjom i visokom stručnom spremom u Italiji je velik broj ugovora na određeno među mladima i privremeni poslovi koji se pretežno nude mladima, a također i spori prelazak iz obrazovanja u zaposlenje. U Grčkoj je isto tako izražena velika nezaposlenost kod mladih, odnosno niska razina zaposlenosti za sve razine obrazovanja, kao posljedica lošeg funkcioniranja tržišta rada i neusklađenosti vještina što se odražava na sve dobne skupine, a najviše na dobnoj skupini 15-29 godina kod mladih sa niskom i visokom stručnom spremom.

5. ZAKLJUČAK

Istraživanja korištena u radu pokazala su razloge niske stope zaposlenosti odnosno visoke stope nezaposlenosti mladih, a to su najčešće: nezadovoljavajući rezultati obrazovnog sustava i osposobljavanja, segmentacija tržišta rada te nedovoljna briga o najranjivijim mladima, onima koji se nalaze u NEET skupini. Također pokazalo se kako zemlje u kojima vlada usklađenost obrazovnog sustava s potrebama tržišta rada olakšavaju mladima tranziciju iz obrazovanja u zaposlenje. Stoga se usvajanjem Garancije mladih htjelo pomoći svim mladima, a naročito onima u NEET skupini kako bi im se osigurao nastavak obrazovanja, dobivanje kvalitetne ponude poslova te pružilo dodatno radno iskustvo kroz sustav naukovanja ili pripravništva. Usvajanjem ovih poticajnih mjera, zemlje članice stvorile su nove prilike kako za mlade, tako i za rast i razvoj svojih ekonomija čija slika se pozitivno odražava na cijelu Europu i njezinu konkurentnost na globalnom tržištu.

U radu su također pojašnjene tri metode za otkrivanje znanja iz baza podataka: klasifikacijske, metode za predviđanje i metode za otkrivanje podataka te njihove učestale primjene u sektorima bankarstva, maloprodaje, telekomunikacije i prirodnim znanostima. U istraživačkom dijelu radu korištena je metoda klaster analize, za grupiranje zemalja Europske unije, sličnih numeričkih svojstava obzirom na dob, zaposlenost i razinu obrazovanja, u klasteru. Metodologijom klaster analize htjelo se saznati mogu li se zemlje Europske unije grupirati obzirom na zaposlenost mladih, u kojoj mjeri razina obrazovanja utječe na zaposlenost te ima li razlike u zaposlenosti prema spolu. Nakon tri provedene analize zemlje su grupirane u četiri klastera prema sličnim razinama zaposlenosti i istoj razini obrazovanja. Analize su pokazale kako je najviše mladih zaposleno upravo sa visokom stručnom spremom, zatim ih slijede mladi sa srednjom stručnom spremom dok su najmanje zaposleni mladi sa niskom stručnom spremom, u većini zemalja Europske unije. Muškarci su pretežno više zaposleni od žena i u poslovima s niskom i sa srednjom razinom obrazovanja, dok u poslovima koji traže visoko kvalificirane zaposlenike, žene u malom postotku zaostaju za muškarcima. Na kraju istraživanja zemljama koje se nalaze u D klasteru te zaostaju za drugima po razini zaposlenosti mladih daljnje preporuke su sljedeće: omogućiti lakši prijelaz iz obrazovanja do zaposlenja te uspostaviti institucije koje će više podupirati sam proces. Te po uzoru na austrijski model poticati poslodavce na osposobljavanje mladih i njihovo educiranje kroz sustav naukovanja ili pripravništva.

POPIS LITERATURE

Knjige i znanstveni članci:

1. Bedeniković, I. (2017) (Ne)zaposlenost mladih i NEET populacija u Hrvatskoj. *Mali Levijatan* [online], 4 (1), str. 75-90. Dostupno u: Hrčak.srce.hr [20.03.2020.]
2. Bilić, N. i Jukić, M. (2014). Nezaposlenost mladih–ekonomski, politički i socijalni problem s dalekosežnim posljedicama za cjelokupno društvo. *Pravni vjesnik: časopis za pravne i društvene znanosti Pravnog fakulteta Sveučilišta JJ Strossmayera u Osijeku*, 30(2), str. 485-505.
3. Brkić, M. 2015. Labour market duality and the impact of prolonged recession on employment in Croatia. *Croatian Economic Survey*, 17(1), str. 5-45.
4. Bruno, G. S., Marelli, E. & Signorelli, M. (2014) The rise of NEET and youth unemployment in EU regions after the crisis. *Comparative Economic Studies*, 56 (4), str. 592-615.
5. Caliendo, M. & Schmidl, R. (2016) Youth Unemployment and Active Labor Market Policies in Europe. *IZA Journal of Labor Policy* [online], 5 (1). Dostupno na: <http://ftp.iza.org> [20.03.2020.]
6. Chung, H., Bekker, S. & Houwing, H. (2012) Young people and the post-recession labour market in the context of Europe 2020. *European Review of Labour and Research*, 18 (3), str. 301-317. [25.03.2020.]
7. Čavar, I. (2018) Student employment: Characteristics and effects of its use in Croatia. *Interdisciplinary Description of Complex Systems: INDECS* [online], 16 (1), str. 60-70. Dostupno u Hrčak.srce.hr. [12.03.2020.]
8. Dolado, Juan J. (2015) (ed.) *No Country for Young People?: Youth Labour Market Problems in Europe*. London: CEPR Press [online]. Dostupno u: VoxEU.org [12.03.2020.]
9. Han, J., Kamber, M. & Pei, J. (2012) *Data mining: Concepts and techniques*, 3rd.ed, Waltham: Morgan Kaufmann Publishers.
10. Hauptman, M. (2018) Importance of public investment for economic growth in the European Union. *Public Sector Economics* [online], 42 (2). Dostupno u: Hrčak.srce.hr [25.03.2020.]
11. Jović, A., Brkić, K. & Bogunović, N. (2014) An overview of free software tools for general data mining. U: Biljanović, P. (ur.) *Proceedings of MIPRO 2014*. [online]. Dostupno u: Research gate [09.05.2020.]

12. Kaya Keles, M. (2017) An overview: the impact of data mining applications on various sectors. *Tehnički glasnik* [online], 11 (3). Dostupno u: Hrčak.srce.hr. [01.05.2020.]
13. Kramarz, F. & Nordstrom Skans, O. (2014) When Strong Ties are Strong: Networks and Youth Labour Market Entry. *The Review of Economic Studies* [online], 81 (3). Dostupno u: Jstor [20.03.2020.]
14. Lange, M., Gesthuizen, M. i Wolbers, M. (2014) Youth labour market integration across Europe: The impact of cyclical, structural, and institutional characteristics. *European Societies* [online], 16 (2). Dostupno u Research gate [12.03.2020.]
15. Ledenko, A. (2017) Mjere za poticanje zapošljavanja mladih. *Pravnik: časopis za pravna i društvena pitanja* [online], 51 (101), str. 105-128. Dostupno u: Hrčak.srce. [20.03.2020.]
16. Lin, W.-C., Ke, S.-W., & Tsai, C.-F. (2017) Top 10 Data Mining Techniques in Business Applications: A Brief Survey. *Kybernetes*. Dostupno u: Emerald insights [28.04.2020.]
17. Nikolić, G. (2017) Industrija i obrazovanje. *Andragoški glasnik* [online], 21 (1-2) 36, str. 37-48. Dostupno u: Hrčak.srce.
18. Pejić Bach, M. (2005) Rudarenje podataka u bankarstvu. Stručni rad. *Zbornik Ekonomskog fakulteta u Zagrebu*, 3 (1), str. 181.-193.
19. Pejić-Bach, M., & Kerep, I. (2011) *Weka - alat za otkrivanje znanja iz baza podataka*. Zagreb: Ekonomski fakultet Sveučilišta, Katedra za informatiku.
20. Sharma, N., Bajpai, A., & Litoriya, R. (2012) Comparison the various clustering algorithms of weka tools. *International Journal of Emerging Technology and Advanced Engineering* [online], 2 (5).
Dostupno na: https://ijetae.com/files/Volume2Issue5/IJETAE_0512_13.pdf
[20.04.2020.]
21. Signorelli, M., Perugini, C. (2010) Youth labour market performance in European regions. *Economic Change and Restructuring* [online], 43 (2). Dostupno u: ProQuest [20.03.2020.]
22. Tomić, I. (2016) What drives youth unemployment in Europe?: Economic vs. non-economic determinants. *International Labour Review* [online], 157 (3). Dostupno u: WoS. [20.03.2020.]
23. Tomić, I., Botrić, V. & Žilić, I. (2018) Analiza stanja i preporuke za razvoj daljnjih aktivnosti za osobe u NEET statusu. Uspostava sustava praćenja NEET osoba.

Projektna studija (projektna studija). Zagreb: *Ekonomski institut* [online].
Dostupno na: <https://www.eizg.hr/> [20.03.2020.]

24. Witten, I., H., Frank, E. & Hall, M., A. (2005) *Data Mining: Practical Machine Learning*. 2nd ed. Amsterdam: Elsevier.
25. Zaki, M., J., Meira, JR., W. (2014) *Data Mining and Analysis: fundamental concepts and algorithms*. 1st published, New York: Cambridge University Press.

Internetski izvori:

1. Eurofound (2016) Exploring the diversity of NEETs [online]. Publications Office of the European Union, Luxembourg. Dostupno na:
<https://www.eurofound.europa.eu/publications/report/2016/labour-market-social-policies/exploring-the-diversity-of-neets> [12.03.2020.]
2. Europska Komisija (2018) Study on the Youth Guarantee in light of changes in the world of work [online]. Youth Guarantee: Intervention Models, Sustainability and Relevance. Luxembourg: Publications Office of the European Union [online].
Dostupno na:
<https://ec.europa.eu/social/BlobServlet?docId=20689&langId=en> [21.03.2020.]
3. Eurostat (2018) Statistika NEET skupine prema spolu, godinama i obrazovanju [online]. Dostupno na:
http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=yth_empl_160&lang=en [20.04.2020.]
4. Eurostat (2018) Statistika zaposlenosti mladih prema spolu, godinama i obrazovanju [online]. Dostupno na:
http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=yth_empl_010&lang=en [20.04.2020.]
5. Eurostat (2018) Zaposlenost i aktivnost prema spolu i dobi - godišnji podaci [online]. Dostupno na: <http://appsso.eurostat.ec.europa.eu/> [30.03.2020.]
6. Eurostat (2018) Zaposlenost prema dobi i europskoj socio-ekonomskoj skupini [online]. Dostupno na:
http://appsso.eurostat.ec.europa.eu/nui/show.do?wai=true&dataset=lfsa_esega [30.03.2020.]
7. Factsheet (2018) Youth Guarantee & Youth Employment Initiative in Croatia [online]. Dostupno na:

https://ec.europa.eu/social/main.jsp?advSearchKey=YGYEI&mode=advancedSubmit&catId=1307&doc_submit=&policyArea=0&policyAreaSub=0&country=0&year=0 [09.05.2020.]

8. Službena web stranica Europske unije (2020) Employment, Social Affairs & Inclusion: Youth employment [online]. Dostupno na:
<https://ec.europa.eu/social/main.jsp?catId=1079&langId=en> [09.05.2020.]

POPIS SLIKA

Slika 1. Kretanja na tržištu mladih.....	9
Slika 2. Opća stopa zaposlenosti mladih (15-24) u razdoblju (2002.-2018.).....	12
Slika 3. Formula za određivanje broja klastera	25
Slika 4. Prikaz klaster analize u Weki	29
Slika 5. Prikaz rezultata klaster analize.....	30
Slika 6. Prikaz opažanja po klasterima u 2D prikazu	30
Slika 7. Prikaz novog atributa Cluster.....	31

POPIS GRAFIKONA

Grafikon 1. Zaposlenost mladih (15-24) prema ESeG.....	13
Grafikon 2. Zaposlenost mladih (15-24) prema razini obrazovanja, 2018.....	14
Grafikon 3. Mladi (15-29) niti u zaposlenosti niti u obrazovanju i osposobljavanju, 2018.....	18
Grafikon 4. Udio mladih obzirom na nisku razinu obrazovanja, svi i prema spolu, % stanovništva 15-29 godina.....	32
Grafikon 5. Klasteri zemalja s obzirom na zaposlenost mladih s niskim obrazovanjem i prema spolu – prosječan udio stanovništva 15-29 godina (2018. godina).....	34
Grafikon 6. Udio mladih obzirom na srednju razinu obrazovanja, svi i prema spolu, % stanovništva 15-29 godina.....	36
Grafikon 7. Klasteri zemalja s obzirom na zaposlenost mladih sa srednjom razinom obrazovanja i prema spolu – prosječan udio stanovništva 15-29 godina (2018. godina).....	38
Grafikon 8. Udio mladih obzirom na visoku razinu obrazovanja, svi i prema spolu, % stanovništva 15-29 godina.....	40
Grafikon 9. Klasteri zemalja s obzirom na zaposlenost mladih s visokom razinom obrazovanja i prema spolu – prosječan udio stanovništva 15-29 godina (2018.-ta godina).....	42

POPIS TABLICA

Tablica 1. Atributi i formati atributa baze podataka	27
Tablica 2. Korišteni podaci za klaster analizu svih pojedinaca te pojedinaca prema spolu (2018. godina)	31
Tablica 3. Prosječne vrijednosti zaposlenosti mladih s niskim obrazovanjem po klasterima (2018.-ta godina)	33
Tablica 4. Pripadnost pojedine zemlje klasteru s obzirom na zaposlenost mladih obzirom na nisku razinu obrazovanja i prema spolu (2018.-ta godina)	34
Tablica 5. Korišteni podaci za klaster analizu svih pojedinaca te pojedinaca prema spolu (2018. godina)	35
Tablica 6. Prosječne vrijednosti zaposlenosti mladih sa srednjom razinom obrazovanja po klasterima (2018.-ta godina)	37
Tablica 7. Pripadnost pojedine zemlje klasteru s obzirom na zaposlenost mladih obzirom na srednju razinu obrazovanja i prema spolu (2018.-ta godina)	38
Tablica 8. Korišteni podaci za klaster analizu svih pojedinaca sa srednjom stručnom spremom i pojedinaca prema spolu (2018. godina)	39
Tablica 9. Prosječne vrijednosti zaposlenosti mladih s visokom razinom obrazovanja po klasterima (2018.-ta godina)	41
Tablica 10. Pripadnost pojedine zemlje klasteru s obzirom na zaposlenost mladih obzirom na visoku razinu obrazovanja i prema spolu (2018.-ta godina)	42

PRILOZI

Životopis studenta

OSOBNE INFORMACIJE

Ime i prezime: Katarina Bagić

Datum i mjesto rođenja: 25. listopada 1995., Zagreb, Hrvatska

E-mail: kbagic@net.efzg.hr

ŠKOLOVANJE I USAVRŠAVANJE

- studeni 2018.- danas Magistra ekonomije (mag.oec.)

Ekonomski fakultet u Zagrebu, smjer: Menadžerska informatika

- veljača 2019. -ožujak 2019. Online tečaj: Proračunske tablice – napredna razina

Sveučilišni računarski centar (Srce), (Excel 2010, E418)

- listopad 2014. – listopad 2018. Sveučilišna Prvostupnica ekonomije (univ. bacc.oec.)

Ekonomski fakultet u Zagrebu, smjer: Poslovna ekonomija

- rujan 2010. – lipanj 2014.

Nadbiskupska klasična gimnazija s pravom javnosti u Zagrebu

STRANI JEZICI

- Materinski jezik / hrvatski
- Strani jezici/ engleski (samostalni korisnik)

OSOBNE VJEŠTINE I AKTIVNOSTI

- Poslovne vještine – odgovornost, ustrajnost i organiziranost (vještine stečene u prodaji, administraciji i ugostiteljstvu), težim osobnom i profesionalnom usavršavanju
- Organizacijske vještine – rad u timu (10 osoba), delegiranje obaveza i zadataka
- Digitalne vještine - MS Office, osnovno znanje u MySQL-u, Bizagi Process Modeler-u i Weki

Vozačka dozvola B kategorija