Prikupljanje i statistička obrada podataka na primjeru Studentskog centra - Student servis Pula

Lončarić, Nensi

Undergraduate thesis / Završni rad

2019

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Pula / Sveučilište Jurja Dobrile u Puli**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:137:900363

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Image not found or type unknown

Repository / Repozitorij:

Digital Repository Juraj Dobrila University of Pula

zir.nsk.hr

Image not found or type unknown

Sveučilište Jurja Dobrile u Puli
Fakultet ekonomije i turizma
«Dr. Mijo Mirković»

NENSI LONČARIĆ

Prikupljanje i statistička obrada podataka na primjeru Studentskog centra Pula (Student servis)

Završni rad

Pula, 2019.

Sveučilište Jurja Dobrile u Puli
Fakultet ekonomije i turizma
«Dr. Mijo Mirković»

NENSI LONČARIĆ

Prikupljanje i statistička obrada podataka na primjeru Studentskog centra Pula (Student servis)

Završni rad

JMBAG: 0115059611, redovita studentica

Studijski smjer: Management i poduzetništvo

Predmet: Statistika

Znanstveno područje: Društvene znanosti
Znanstveno polje: Ekonomija
Znanstvena grana: Statistika

Mentorica: doc. dr. sc. Katarina Kostelić

Pula, rujan 2019.

IZJAVA O AKADEMSKOJ ČESTITOSTI

Ja, dolje potpisana, Nensi Lončarić, kandidatica za prvostupnicu poslovne ekonomije, smjera Management i poduzetništvo ovime izjavljujem da je ovaj Završni rad rezultat isključivo mojega vlastitog rada, da se temelji na mojim istraživanjima te da se oslanja na objavljenu literaturu kao što to pokazuju korištene bilješke i bibliografija. Izjavljujem da niti jedan dio Završnog rada nije napisan na nedozvoljen način, odnosno da je prepisan iz kojega necitiranog rada, te da ikoji dio rada krši bilo čija autorska prava. Izjavljujem, također, da nijedan dio rada nije iskorišten za koji drugi rad pri bilo kojoj drugoj visokoškolskoj, znanstvenoj ili radnoj ustanovi.

Studentica

Nensi Lončarić

U Puli, 15. rujna, 2019. godine

IZJAVA

o korištenju autorskog djela

Ja, Nensi Lončarić dajem odobrenje Sveučilištu Jurja Dobrile

u Puli, kao nositelju prava iskorištavanja, da moj završni rad pod nazivom Prikupljanje i statistička obrada podataka na primjeru Studentskog centra Pula (Student servis) koristi na način da gore navedeno autorsko djelo, kao cjeloviti tekst trajno objavi u javnoj internetskoj bazi Sveučilišne knjižnice Sveučilišta Jurja Dobrile u Puli te kopira u javnu internetsku bazu završnih radova Nacionalne i sveučilišne knjižnice (stavljanje na raspolaganje javnosti), sve u skladu s Zakonom o autorskom pravu i drugim srodnim pravima i dobrom akademskom praksom, a radi promicanja otvorenoga, slobodnoga pristupa znanstvenim informacijama.

Za korištenje autorskog djela na gore navedeni način ne potražujem naknadu.

U Puli, 15. rujna, 2019. godine

Potpis

_____

Sadržaj

1. Uvod **1**
2. Pojam i uloga statistike **2**
2.1. Statistički skup, populacija i uzorak 2
2.2. Deskriptivna statistika 3
2.3. Inferencijalna statistika 4
3. Statistički podaci **6**
3.1. Vrste podataka 6
3.2. Izvori podataka 9
3.3. Način prikupljanja statističkih podataka 10
3.4. Grupiranje statističkih podataka 11
3.5. Obrada podataka 12
3.6. Tablično i grafičko prikazivanje statističkih podataka 14
3.7. Analiza i vrednovanje dobivenih rezultata 20
4. Prikupljanje i statistička obrada podataka Studentskog servisa Pula **21**
4.1. Informacije o Studentskom centru Pula 21
4.2. Prikupljanje podataka Student servisa Pula 21
4.3. Obrada podataka Student servisa Pula 23
4.4. Grafički prikaz podataka ustupljenih od Student servisa Pula 25
5. Zaključak **34**
Literatura **36**
Popis slika, grafikona i tablica **37**
Sažetak **39**

1. Uvod

Statistika je znanstvena metoda o kvantitativnom razvitku ljudskog društva koja obuhvaća prikupljanje, obradu i prikazivanje brojčanih podataka o masovnim pojavama u vremenu i prostoru. Poznato je da su još stare civilizacije vršile popise stanovništva, poljoprivrednih prinosa i raspoloživih bogatstava svojih država. Prvi poznati popis stanovništva u Europi objavljen je u 11. stoljeću, a prekretnicom u razvoju statistike smatra se 17. stoljeće zbog nastalih potreba država za standardiziranim podacima.

Danas, zahvaljujući tehnološkom napretku i suvremenoj informacijsko komunikacijskoj tehnologiji, omogućeno nam je prikupljanje, obrada i analiza velikog broja podataka. Gotovo svaki aspekt naših života može se prikazati pomoću brojeva, odnosno statističkih podataka. Statistika je ta koja obradom i analizom prikupljenih podataka stvara cjelovitu sliku i daje smisao. Statistika ili pojedini njeni dijelovi danas su sve češće uključeni kao nastavni predmeti u srednjim, višim školama i fakultetima. Razlog tome je spoznaja da su određeni statistički sadržaji, odnosno neka znanja iz statistike nužna za uspješno usvajanje modernih spoznaja drugih nastavnih predmeta, kao i za opću naobrazbu.

Cilj rada je istaknuti važnost statistike kao znanstvene discipline, predstaviti faze statističkog istraživanja te potkrijepiti primjerom prikupljanja i obrade podataka Studentskog servisa Pula. Rad se sastoji od pet međusobno povezanih dijelova.

Nakon prvog, uvodnog dijela u drugome dijelu govori se o važnosti statistike, temeljnim pojmovima poput statističkog skupa, populacije i uzorka te vrstama statističkih metoda.

Treći dio rada detaljno se bavi statističkim podacima počevši od njihove podjele, izvora i načina prikupljanja te grupiranja i obrade pa sve do grafičkog i tabelarnog prikazivanja, analize i vrednovanja dobivenih rezultata.

Četvrti, praktični dio rada, odnosi se na prikaz prikupljanja i obrade podataka Studentskog centra Pula o zaposlenosti studenata tijekom vremenskog razdoblja od tri godine. Tabelarno i grafički prikazani su ustupljeni podaci koji su se u radu statistički obradili i obrazložili.

Zaključno, istaknut će se važnost statistike u svakodnevnom životu i prokomentirati rezultati provedenog statističkog istraživanja Studentskog servisa Pula.

2. Pojam i uloga statistike

Suvremeno poimanje pismenosti podrazumijeva sposobnost uporabe osnovne informacijske tehnologije kao i razlikovanje izvora i kvalitete podataka i informacija te njihovo pravilno tumačenje.[1] Poslovanje poslovnih subjekata, donošenje odluka na mikro i makro razini te upravljanje gospodarstvom jedne zemlje vezano je uz stručno prikupljanje statističkih podataka i temeljem njih izvedenih informacija.

Statistika je znanost koja povezuje masovne i individualne pojave, opća i posebna obilježja, kvalitativni i kvantitativni pristup u proučavanju društveno – ekonomskih kretanja. Stoga je neprihvatljivo pojmu statistike umanjiti značaj stavljajući je na razinu podataka i evidencija. Prema mišljenju mnogih stručnjaka, statistika je znanost koja proučava masovne pojave, metode te postupke za racionalno istraživanje masovnih pojava brojčanim načinom opisivanja. Gospodarska statistika veoma je važna za svaku državu. Predmet izučavanja gospodarske statistike su makroekonomski podaci, a obuhvaća tehnike za njihovo prikupljanje, metode za izračunavanje, tumačenje i upotrebu makroekonomskih indikatora pomoću kojih se mogu donositi utemeljeni zaključci i odluke, izrađivati prognoze gospodarstva države ili regije. Pod pojmom poslovne statistike mislimo na primjenu podataka i informacija u poslovanju, tj. niz metoda za analizu podataka u stvaranju informacija nužnih za donošenje odluka menadžera na svim razinama odlučivanja u okviru menadžmenta. Poslovna statistika definira se kao znanost o metodama koje se koriste za pretvaranje podataka u smislene informacije u poslovnom okruženju sa svrhom stjecanja znanja za uspješnije odlučivanje i prognoziranje u uvjetima neizvjesnosti i rizika. Sve spomenuto podupire tvrdnju o značenju statistike kao znanosti te važnoj ulozi statističkih metoda u ekonomiji i društvu.

2.1. Statistički skup, populacija i uzorak

Osnovni zadatak statistike je proučavanje masovnih pojava koje su mnogobrojne, raznovrsne i složene s različitim djelovanjem i promjenama. Potrebno je njihovoj analizi pristupiti organizirano, po mogućnosti programirano i planski. Masovne pojave predstavljaju skupinu istovrsnih, ali i varijabilnih elemenata koji imaju jedno ili više zajedničkih svojstava te ih nazivamo statističkom masom ili statističkim skupom.

[1]K. Dumičić, et al., *Poslovna statistika*, Zagreb, ELEMENT d.o.o., 2011., str. 2.

Elemente koje karakterizira masovna pojava predmet su analize. Potrebno ih je precizno definirati kako bi se mogli shvatiti kao skup varijabli, odnosno statističkih obilježja, podložni analizi. Statistički skup je skup jedinica (elemenata) nad kojima se ispituje jedno ili više obilježja, odnosno varijabli.[2] Broj jedinica konačnog statističkog skupa označava se s N i predstavlja opseg statističkog skupa, a može biti konačan i beskonačan. Statistički skup je dinamička kategorija koja je cjelovita, homogena, ali i diferencirana zbog statističkih jedinica čije se karakteristike međusobno manje ili više razlikuju.

Važni statistički pojmovi su populacija i uzorak. Populacija ili osnovni skup predstavlja skup podataka jednog obilježja (varijable) vezanih za sve jedinice statističkog skupa. Može biti konačna ili beskonačna, stvarna ili hipotetska te je veličinom jednaka statističkom skupu. Predstavlja opseg populacije, odnosno opseg statističkog skupa i označava se također s N. Obuhvat cjelokupne populacije radi provođenja statističkog istraživanja ponekad je preskupo i/ili nemoguće pa je stoga potrebno primijeniti metodu uzorka. Uzorak je izabrani podskup elemenata populacije, a njegova je veličina označena s n. Veličina uzorka obično je značajno manja od veličine populacije te omogućava brže i jeftinije prikupljanje podataka.[3]

Statistički skupovi i uzorci u svakom statističkom istraživanju moraju biti precizno i potpuno definirani, pojmovno, prostorno i vremenski. Pojmovno definiranje utvrđuje pripadnost svih jedinica skupa s obzirom na pojam, prostorno označava geografski prostor kojem pripadaju, dok se vremenskom definicijom određuje vremenski interval ili trenutak koji veže sve jedinice skupa. Samo potpuno i precizno definirani skupovi podataka mogu poslužiti kao osnova za statističku analizu i zaključivanje.

2.2. Deskriptivna statistika

Statistika u najširem smislu bavi se prikupljanjem statističkih podataka prema sustavnom planu prikupljanja, njihovim uređivanjem, tabličnim i grafičkim prikazivanjem te analizom i donošenjem zaključaka. Analiza je jednostavna ukoliko se analizira pojava koja je opisana manjim brojem podataka. Međutim, često se radi o složenim pojavama čije karakteristike nije moguće uočiti bez upotrebe statističkih

[2] V. Bahovec, et al., *Statistika*, Zagreb, ELEMENT d.o.o., 2015., str. 3.
[3] K. Dumičić, et al., op.cit., str. 17

metoda. Sukladno tome, razlikuju se dvije skupine statističkih metoda koje se primjenjuju u različitim područjima djelatnosti, a to su deskriptive i inferencijalne statističke metode. Svaka cjelovita i precizna statistička analiza u pravilu obuhvaća obje skupine metoda. Metode deskriptivne ili opisne statistike uključuju postupke uređivanja i prikazivanja statističkih podataka te izračunavanja deskriptivnih brojčanih pokazatelja. Najčešće se raspolaže s velikim brojem podataka i njihovo uređivanje svodi se na grupiranje, tablično i grafičko prikazivanje. Nakon toga slijedi numerička analiza korištenjem različitih mjera.[4]

Brojčani pokazatelji mogu se razvrstati na sljedeći način:

1) Mjere centralne tendencije, kao što su aritmetička sredina (prosječna vrijednost), geometrijska sredina, harmonijska sredina, medijan, mod (najčešća vrijednost), kvantili, momenti numeričkih nizova
2) Mjere disperzije (pokazatelji raspršenosti), kao što su raspon varijacije, interkvartil, koeficijent kvartilne devijacije, interpercentilni razmak, varijanca, standardna devijacija, koeficijent varijacije, standardizirana varijabla
3) Mjere oblika distribucije, odnosno mjere asimetrije i mjere zaobljenosti kao što su koeficijent asimetrije, Pearsonova i Bowleyjeva mjera asimetrije, koeficijent zaobljenosti
4) Mjere koncentracije koje se dijele na apsolutne mjere koncentracije (koncentracijski omjer i Herfindahlov – Hirschmanov indekes) i relativne mjere koncentracije (Ginijev koeficijent koncentracije).[5]

Grafikoni i brojčani pokazatelji čine samo dio brojnih tehnika deskriptivne statistike, ali je vrlo važno procijeniti koji od njih najbolje odgovara određenoj problematici kako bi statistička analiza pružila što vjerodostojnije rezultate.

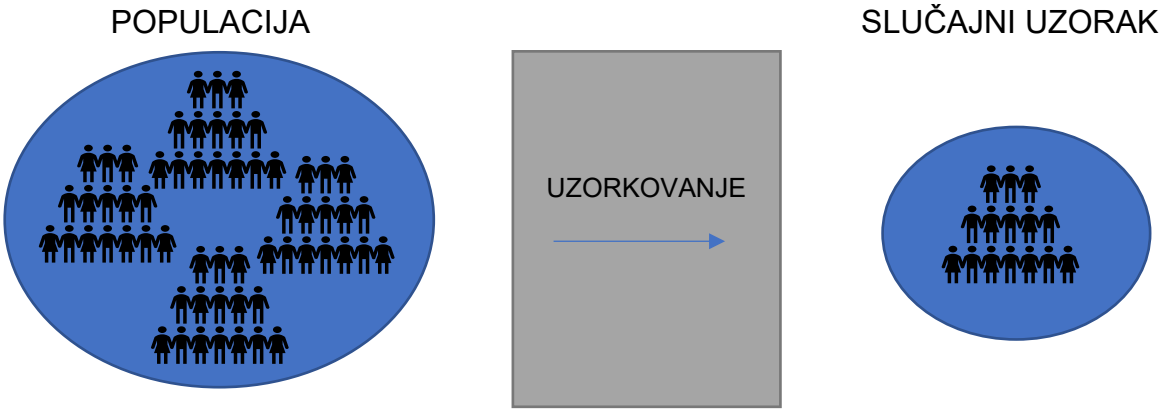
2.3. Inferencijalna statistika

U Oxford Dictionary of Statistics (Dodge, 2003) statistička inferencija definira se kao proces zaključivanja o prirodi nekog sustava na osnovi podataka koji su podložni slučajnim varijacijama. Inferencijalna statistika predstavlja skup metoda statističkog zaključivanja na temelju podataka slučajnog uzorka pri čemu se zaključci uz primjenu teorije vjerojatnosti mogu poopćiti na cijeli skup. Polazeći tako od uzorka podataka

[4] V. Bahovec, et al., op.cit., str. 2.
[5] I. Šošić. *Primijenjena statistika*, Zagreb, Školska knjiga, 2006., str. 53. – 139.

metodama inferencijalne statistike donose se zaključci o cjelini (populaciji) i to procjenjivanjem nepoznatih karakteristika cjeline (populacije) uz određenu razinu pouzdanosti ili testiranjem pretpostavke o tim nepoznatim karakteristikama cjeline (populacije) uz odabranu razinu značajnosti. Zaključci o nepoznatim karakteristikama populacije doneseni na temelju uzorka podataka nemaju apsolutnu sigurnost, stoga se takvi zaključci mogu poopćiti na cijeli skup samo uz određenu razinu pouzdanosti i određenu razinu značajnosti.[6] Dobivene informacije osnova su menadžeru za uspješno poslovno odlučivanje.

Slika 1. Prikaz odnosa populacije i uzorka



Parametar populacije je nepoznat Procjena pomoću uzorka

Izvor: djelo autorice završnog rada prema K. Dumičić, et. al.,*Poslovna statistika*

.

[6] V. Bahovec, et al., op.cit., str. 2.

3. Statistički podaci

Predmet proučavanja statistike kao znanstveno istraživačke discipline su svojstva elemenata statističkih skupova i podskupova. Elementi izučavanja mogu biti subjekti ili objekti. To mogu biti osobe, predmeti, prostorne jedinice ili pojave, odnosno njihova kvalitativna i kvantitativna svojstva. Varijable ili obilježja su svojstva koja se proučavaju, a modaliteti ili vrijednosti koje poprimaju zovu se podaci. Podaci su statistički ako ih ima mnogo, ako variraju te ako su prikupljeni na isti unaprijed planirani način.[7] Podaci su mjerenja vezana uz jednu varijablu koja je predmet statističkog istraživanja i povezuje istraživane elemente. Varijabla će, za svaki element izučavanja primiti određeni oblik ili određenu vrijednost, odnosno podatak. Svrha statistike je ispitivanje varijabilnosti podataka te provođenje prikladne analize. Ovisno o broju varijabli postoji jednodimenzionalna i višedimenzionalna statistička analiza.

3.1. Vrste podataka

Kako bi statističko istraživanje bilo mjerodavno vrlo je važno primijeniti prikladnu statističku metodu za analizu. Odabir metode ovisi o vrsti varijable čiji se podaci i karakteristike žele istražiti. Primjerice, bitno je jesu li podaci kvalitativni pa su računske operacije nad njima nemoguće, ili su pak kvantitativni pa je zbrajanje, množenje i oduzimanje dopušteno. Na osnovi različitih karakteristika i faktora zasniva se više načina podjele statističkih podataka.

1) Kvantitativni i kvalitativni podaci

Podatke koje je adekvatno prikazati pomoću brojeva nazivaju se kvantitativnim podacima. Njihova priroda dopušta primjenu osnovnih računskih operacija, s iznimkom intervalnih podataka koji ne dopuštaju izvođenje dijeljenja. To su podaci mjereni na razinama intervalne i omjerne skale te zahtijevaju navođenje mjerne jedinice. Primjerice, ako je riječ o novčanim vrijednostima, treba navesti novčane jedinice (kune, euri…). Grupiranjem kvantitativnih podataka nastaju numerički nizovi.

Ukoliko je podatke nemoguće prikazati pomoću brojeva koriste se pojmovne ili opisne kategorije (spol, boja očiju, mjesto stanovanja i sl.) te ih nazivamo kvalitativnim

[7] loc. cit.

ili kategorijskim podacima. Kako bi se olakšao unos i obrada takvih podataka, primjenjuju se brojčani ili slovni kodovi, a računske operacije ostaju nedopuštene. Kvalitativni podaci mjereni su nominalnom i redoslijednom skalom, a ukoliko ih je mnogo grupiraju se sukladno modalitetima koji su empirijski opaženi.

2) Podaci s obzirom na mjerne skale

Podaci se također mogu klasificirati s obzirom na razinu metričkih svojstava koja odgovara konkretno primijenjenoj mjernoj skali. Sukladno korištenoj mjernoj skali podaci se imenuju i razvrstavaju kao: 1) nominalni, 2) ordinalni, 3) intervalni i 4) omjerni.[8] Mjerenje je pridruživanje numeričkih i slovnih oznaka jedinicama statističkog skupa ili uzorka prema određenoj mjernoj skali (ljestvici).

Nominalna skala je dana u obliku liste pojmova, naziva, odnosno atributa, koji se nazivaju kategorije ili modaliteti (oblici). Modalitetima se često pridružuju brojčane ili slovne oznake, tj. kodovi (šifre). Ukoliko nominalna varijabla sadrži veliki broj modaliteta primjenjuju se nomenklature, tj. dogovorno utvrđeni popisi modaliteta nominalne varijable. Na primjer, u RH koristi se nomenklatura zanimanja Nacionalna klasifikacija zanimanja–NKZ–2010. Nominalna skala ima najslabija metrička svojstva, ne dozvoljava provođenje aritmetičkih operacija kao niti uspoređivanje.

Redoslijedna skala, odnosno ordinalna ili skala ranga, pridružuje brojeve ili slovne oznake elemenata prema intenzitetu mjerenog svojstva. Primjer redoslijedne varijable su ocjene znanja studenata na ispitu koja obuhvaća modalitete nedovoljan, dovoljan, dobar, vrlo dobar, izvrstan. Za razliku od nominalne skale, redoslijedna dozvoljava uspoređivanje modaliteta redoslijedne varijable.

Intervalnom skalom jedinicama statističkog skupa pridružuju se brojevi sukladno intenzitetu mjerenog svojstva. Intervalna skala ima bolja metrička svojstva od prethodno navedenih jer omogućuje rangiranje, utvrđivanje razlika kao i aritmetičke operacije zbrajanja i oduzimanja. Primjeri podataka mjerenih intervalnom skalom su temperatura mjerena u Celzijevim i Fahrenheitovim stupnjevima.[9] Intervalne skale u društvenim istraživanjima mjere stupanj slaganja ili neslaganja osoba s nekim ili nečim, tj. mjeri stavove ispitanika u političkim i nepolitičkim mišljenjima. To su tzv. ljestvice s

[8] K. Dumičić, et al., op.cit., str. 34.
[9] V. Bahovec, et al., op.cit., str. 7.

pozicijama koje obuhvaćaju Likertovu ljestvicu, Thurstonovu ljestvicu, Stapelovu ljestvicu te ljestvicu semantičkih razlika.

Likertova ljestvica mjeri stupanj slaganja ispitanika s određenom pojavom. Ponuđeni modaliteti čijim izborom ispitanik izražava svoje slaganje, odnosno neslaganje su „izrazito se slažem“, „slažem se“, niti se slažem niti se ne slažem“, „ne slažem se“ i „izrazito se ne slažem“. Ljestvica sadrži određene izjave, a od ispitanika se očekuje odabir modaliteta koji je najbliži njegovom stavu za svaku pojedinačnu izjavu. Prema obilježjima, Likertova ljestvica pripada ordinalnoj ljestvici, međutim ispitivači se tijekom obrade, zbog toga što se pozicija „niti se slažem niti se ne slažem“ kodira kao (relativna) nula, što omogućuje aritmetički prikaz ljestvice na intervalnoj skali.

Thurstonova ljestvica ispitaniku nudi niz izjava vezane uz područje istraživanja u obliku gotovih odgovora. Odabire se jedna izjava koja je najbliža mišljenju i stavu ispitivane osobe. Takvo mjerenje podrazumijeva da odabir jedne izjave znači slaganje ispitanika s njom, a neslaganje sa svim ostalim izjavama. Thurstonova ljestvica izvorno je složene konstrukcije i sadrži mnogo tvrdnji koje se kreću iz jedne krajnosti u drugu. Zato je u izvornom obliku bila slabo korištena u poslovne svrhe neovisno o tome što su podaci dobiveni na intervalnoj razini mjerenja pa je omogućena kvalitetnija statistička analiza.

Stapelova ljestvica je specifična po tome što se ocjenjuje tvrdnja tako što se iskaže slaganje, odnosno mjeri (ne)slaganje različitim intenzitetom. Postoji 10 stupnjeva slaganja, tj. ocjena od -5 do +5 što ih ispitanik odabire za svaku izjavu. Prednost je što nema potrebe za smišljanjem proturječnih tvrdnji i jednostavna je za primjenu.

Ljestvica semantičkih razlika je vrlo raširena tehnika u istraživanju stavova, a posebice kod istraživanja dojmova koji potrošači stječu o marki proizvoda, prodavaonici i sl. Vrijednosti ljestvice semantičkih razlika se označuju ili kao 7, 6, 5, 4, 3, 2, 1 ili kao +3, +2, +1, 0, -1, -2, -3. I kod ljestvice semantičkih razlika se izračunavaju srednje vrijednosti, tako da su podaci dobiveni na intervalnoj razini mjerenja.

Omjerna skala jedinicama statističkog skupa pridružuje vrijednosti (brojeve) sukladno intenzitetu mjernog svojstva. Varijabla mjerena omjernom skalom naziva se numerička varijabla. Apsolutna nula predstavlja odsutnost mjerene karakteristike.

Vrijednostima numeričke varijable mjerene na omjernoj skali moguće je provoditi aritmetičke operacije i daju smislene omjere. Stoga omjerna skala, uspoređujući s prethodno navedenima, ima najbolja metrička svojstva.

3) Izvorni i izvedeni podaci

Izvorni podaci su podaci izraženi u mjernim jedinicama promatranog obilježja. (npr. podaci o bruto plaćama zaposlenika u jednom poduzeću izraženi u kunama). Izvedeni podaci nastaju primjenom računskih postupaka na izvornim podacima, (npr. postotci, indeksni brojevi, koeficijenti i dr.).

4) Vremenski i presječni podaci

Ukoliko se statistički podaci odnose na istu pojmovnu i prostornu jedinicu i prikazuju se kroz vrijeme govorimo o vremenskim podacima. Oni čine vremenski niz, odnosno niz kronološki uređenih podataka i mogu se odnosit i na prikupljanje u jednakim vremenskim intervalima ili u određenom trenutku.
S druge strane, ako se podaci odnose na istu pojavu, u istom vremenskom razdoblju, ali na različite prostorne jedinice ili se odnose na objekte govori se o presječnim, transverzalnim ili cross – sectional poslovnim podacima.

3.2. Izvori podataka

Uz svaki analizirani skup podataka osim definicije (pojmovna, prostorna i vremenska) treba navesti i izvor podataka, odnosno ukratko opisati metodologiju prikupljanja. Izvori podataka mogu biti primarni i sekundarni.
Izvorna istraživanja su primarni izvori podataka i ona rezultiraju primarnim podacima. Primarni se podaci prikupljaju na temelju plana promatranja ili eksperimenta, a njihov opseg i struktura ovise o zadacima određenog istraživanja. Primarni izvori podataka mogu biti :

1) Anketna istraživanja
2) Istraživanja pomoću pokusa
3) Kontrolirana neposredna opažanja.[10]

[10] I. Šošić, op. cit., str. 7.

Sekundarni podaci nastaju iz sekundarnih izvora kao rezultat djelatnosti drugih istraživača i specijaliziranih institucija. Mogu biti javni podaci, mogu se dobiti na zahtjev ili kupiti po komercijalnoj cijeni. U sekundarni izvor spada i specifičan izvor podataka, odnosno izvor putem informacijskog sustava Intraneta i Interneta. Sekundarni izvori podataka mogu biti interni i eksterni. Interni izvori poslovnih podataka mogu biti u vidu poslovnih financijskih i knjigovodstvenih izvještaja unutar poduzeća ili eksterni izvori kao npr. publikacije državnih ureda, agencija i znanstvenih institucija, komercijalnih izvora i dr.

Izvori poslovnih i gospodarskih podataka mnogobrojni su u RH. Javljaju se u tiskanom izdanju u vidu sekundarnih publikacija i na internetskim stranicama, nositelju službene statistike, primjerice na stranici Državnog zavoda za statistiku (DZS RH) (http://www.dzs.rh), Hrvatske narodne banke (http://www.hgl.hr), Portal otvorenih podataka Republike Hrvatske (data.gov.hr) i slično.

Neki od korisnih svjetskih izvora podataka dostupnih na internetskim stranicama su EUROSTAT (http://epp.eurostat.ec.europa.eu/portal/page/portal/eurostat/home), International Monetary Fund (http://www.imf.org/eksternal.index.htm), World Trade Organization (WTO), (http://www.wto.org), World bank (https://www.worldbank.org/) i slično.

3.3. Način prikupljanja statističkih podataka

Samo podaci prikupljeni sustavno i planski prema poznatoj istovrsnoj metodologiji, mogu biti međusobno usporedivi. Među načinima prikupljanja statističkih podataka razlikujemo tri istraživačka nacrta (dizajna).

1) Anketa je pisano prikupljanje podataka koje se zasniva na postavljanju pitanja (otvorenog ili zatvorenog tipa) primjenom anketnog upitnika, a odgovori se kasnije obrađuju statističkim metodama ili kvalitativnim pristupom.
2) Kontrolirano opažanje metoda je promatranja i prikupljanja primarnih podataka. Provodi se na način da se ponašanje određenog subjekta/objekta promatra u prirodnom okruženju bez postavljanja pitanja. Promatrač bilježi opažene podatke i ispunjava unaprijed definiran obrazac.
3) Nacrt pokusa (eksperimenta) definira se kao testiranje hipoteze provođenjem postupka pod vrlo kontroliranim uvjetima što ga čini idealnim za proučavanje primarnih podataka. Manipuliranjem određene nezavisne varijable može se mjeriti njegov učinak na zavisnu varijablu. Relativni uzrok i posljedica potvrđuje se

izlaganjem sudionika na određene tretmane. Tri su osnovne skupine eksperimentalnih nacrta: eksperiment s usporednim skupinama, eksperiment s jednom skupinom i eksperiment s rotacijom eksperimentalnih čimbenika.

Eksperiment s usporednim grupama sadrži dvije grupe ispitanika, eksperimentalnu i kontrolnu grupu, gdje pritom nezavisna varijabla na jednu djeluje, a na drugu ne. Grupe moraju biti ekvivalentne po sastavu, veličini, sposobnostima i drugim svojstvima. Provođenjem eksperimenta s jednom skupinom u skupinu se unose eksperimentalni čimbenici nakon čega se uspoređuju nastali učinci. Kod provođenja eksperimenta rotacijom eksperimentalnih čimbenika svaki čimbenik unosi se iz grupe u grupu. Na taj način svaka je grupa naizmjenično i eksperimentalna i kontrolna.

Podaci koji su djelomično prikupljeni metodom telefonske ankete, a djelomično osobnim intervjuom ili metodom pokusa nije poželjno skupno analizirati jer različiti načini prikupljanja statističkih podataka rezultiraju različitom kakvoćom.

Suvremene metode prikupljanja podataka temelje se na uporabi informacijske tehnologije. Informacijska i komunikacijska tehnologija omogućuju prijenos i uporabu svih vrsta informacija te je takva temelj ekonomije i društva 21. stoljeća. Provođenje ankete i prikupljanje anketnih odgovora suvremenim načinom provodi se putem e-maila ili web anketom. To je najjeftiniji način provođenja no usprkos mogućnosti uključivanja velikog broja sudionika, niska je stopa sudjelovanja. Nove informacijske tehnologije uvelike su pojednostavile postupak prikupljanja podataka putem ankete. CATI (engl. Computer Assisted Telephone Interviewing) doprinijelo je učinkovitosti prikupljanja podataka telefonskim anketiranjem. Predstavlja telefonsko anketiranje s istovremenim unosom odgovora ispitanika, uz provjeru potpunosti i ispravnosti unesenih podataka. Internet je u današnje vrijeme „oaza“ podataka o potrošačima diljem svijeta. Podaci o internetskom ponašanju spremaju se kroz niz raznih alata u velike baze podataka s ili bez osobnog pristanka. Neki od izvora podataka su Toolbar, razni paneli, ISP podaci, podaci iz tražilice i slično. Na taj način, poslovni subjekti maksimiziraju uspješnost internetskih kompanija i poslovanja općenito.

3.4. Grupiranje statističkih podataka

Grupiranje podataka provodi se prema definiranom statističkom obilježju po načelima: a) iscrpnosti (iscrpan, engl. exhaustive) i b) međusobne isključivosti

(međusobno isključivo, engl. mutually exclusive).[11] Grupiranjem statističkih podataka na osnovi vrste obilježja dobivamo: brojevne grupe i nizove, atributivne grupe i nizove, vremenske grupe i nizove te geografske grupe i nizove. Svaki element pripada jednom i samo jednom podskupu pa se tu radi o disjunktnom rastavu statističkog skupa. Grupiranjem se skup podataka koji se odnose na jedinice statističkog skupa raščlanjuje na podskupove koji se međusobno ne preklapaju. Broj podataka istog modaliteta varijable naziva se frekvencijom. Na taj se način postiže usporedivost frekvencija te se one mogu tumačiti i uspoređivati u daljnjim analizama. Niz frekvencija koji nastaje grupiranjem jedinica po osnovi njihova svojstva u statističkom skupu nazivamo statističkim nizom. Strukturni nizovi, ovisno o vrsti obilježja mogu biti nominalni, redoslijedni ili numerički, dok su vremenski nizovi nastali uređenjem vrijednosti kronološki prema kronološkoj karakteristici. Grupiranje statističkih podataka je složen proces koji ovisi o strukturi masovne pojave i usmjerenosti određenih podataka te mora omogućiti uočavanje karakteristike pojave. Podaci koji su nakon grupiranja uredno prikazani statističkim tablicama daju prvu informaciju o značajkama statističkih podataka, dok vizualnu predodžbu o karakteristikama pojave daje grafički prikaz.

3.5. Obrada podataka

Obrada podataka predstavlja tzv. manipuliranje podacima kako bi se u konačnici dobili upotrebljivi parametri koje je moguće tumačiti. Povijesno gledano, podaci su se obrađivali ručno te je nerijetko dolazilo do pogrešaka i krivih interpretacija dobivenih informacija. Danas postoje tri vrste obrade podataka: ručna, mehanička te elektronička obrada podataka (EOP). Pojava računala i računalnih sustava uvelike je olakšalo obradu i prikaz podataka, omogućilo brže i preciznije rezultate te smanjilo mogućnost ljudske pogreške. Obrada podataka, osim brojčanih izračunavanja, obuhvaća i klasifikaciju podataka te njihovo razmještanje. Sastoji se od tri temeljna koraka; ulaza, obrade i izlaza koji su međusobno povezani i čine ciklus obrade podataka. Operacije obrade podataka uključuju zapisivanje, kopiranje, provjeru, klasificiranje, uređivanje (sortiranje), spajanje, izračunavanje, pretraživanje, sažimanje te prikaz rezultata. Karakteristika elektroničke obrade podataka (EOP-a) je samostalna obrada podataka prema unaprijed zadanom programu (nizu naredbi). Postoje razni

[11] K. Dumičić, et al., op.cit., str. 55

kriteriji koji određuju koji je način elektroničke obrade podataka prikladan za svaki pojedini slučaj. Svaki od tih kriterija poprima jednu od dvije moguće vrijednosti koje su međusobno isključive, te na taj način stvaraju osnovu za odabir najpouzdanijeg načina elektroničke obrade podataka. Tablica u nastavku prikazuje najčešće kriterije za ocjenu EOP-a.

Tablica 1. Kriteriji ocjene načina elektroničke obrade podataka

Kriterij	I način	II način
Broj programa	Jedan	Više
Količina podataka	Mala	Velika
Komunikacije s korisnikom	Posredna	Neposredna
Vrijeme odgovora	Kritično	Nije kritično
Broj procesora	Jedan	Više
Umreženost	Da	Ne
Arhitektura	Monolitna	Razdijeljena
Organizacija	Centralizirana	Decentralizirana
Udaljenost	Mala	Velika
Elektronska povezanost	da	Ne

Izvor: djelo autorice završnog rada prema V. Bosilj Vukšić, M. Pejić Bach, *Poslovna informatika*

Karakteristični predstavnici tradicionalnih načina EOP su: serijska obrada, multiprogramska obrada, interaktivna obrada, simultana obrada, obrada u realnom vremenu, daljinska obrada i distribuirana obrada podataka.[12] Navedene metode su međusobno različite, ali sve predstavljaju učinkovito rješenje obrade podataka čija brzina ovisi o pravilnom odabiru metode te raspoloživim resursima.

Serijska obrada podataka (u žargonu Batch obrada) predstavlja najjednostavniji oblik obrade. Obrada teče onim redoslijedom kako su programi i podaci grupirani na ulaznim jedinicama tako da se u jednom trenutku izvodi samo jedan korisnički program.

[12] V. Bosilj Vukšić, M. Pejić Bach, *Poslovna informatika*, Zagreb, ELEMENT d.o.o., 2015., str. 101.

Multiprogramska obrada podataka razlikuje dvije osnovne obrade podataka. To su multiprogramska obrada s prioritetima i multiprogramska obrada s podjelom vremena. Kod prve, programi najvišeg prioriteta započinju korištenjem procesora sve do potrebe izvođenja ulazno izlazne instrukcije, dok programi nižeg prioriteta mogu koristiti procesor samo ako ga programi višeg prioriteta ne trebaju. Multiprogramska obrada s podjelom vremena omogućava da se brže dobiju rezultati kratkih obrada.

Interaktivna obrada podrazumijeva dijalog između korisnika računala u kojem se izmjenjuju korisnički zahtjevi, kratke obrade i prezentacija rezultata.

Simultana obrada podataka koristi više procesora koji rade neovisno, dijele posao obrade podataka te imaju pristup zajedničkoj memoriji, a sastavni u dio jednog računala. Obrada u realnom vremenu se primjenjuje u informacijskim sustavima kod kojih trenutno stanje baze podataka mora odgovarati stvarnom stanju sustava na koji se odnosi.

3.6. Tablično i grafičko prikazivanje statističkih podataka

Ovisno o zahtjevu kojem su određeni podaci namijenjeni statističke podatke potrebno je odabrati najpogodniju metodu. Najčešći prikazi podataka su brojčani odnosno tabelarni i grafikon. Tabelarno prikazivanje podataka vrlo je često te razlikujemo jednostavne i složene tablice. Jednostavne tablice obično sadrže podatke jednog niza, a složene mogu imati više nizova podataka. U svrhu usporedne statističke kategorije koriste se kombinirane tablice u koje se unose podaci. Kako bi se podaci mogli pratiti, potrebno je da svaka tablica bude označena brojem i naslovom, a u podnožju mora biti naveden izvor podataka.

Tablica 2: Jednostavna tablica na primjeru studenata koji su diplomirali/završili studij 2018. godine prema vrsti visokih učilišta

Vrsta visokog učilišta	Broj studenata koji su diplomirali/završili studij
Visoke škole	1487
Veleučilišta	5141
Stručni studiji	3244
Sveučilišni studiji	22630
Umjetničke akademije	739
Ukupno	33241

Izvor: djelo autorice završnog rada prema podacima Državnog zavoda za statistiku, http://dzs.hr (pristupljeno 10. rujna 2019.)

Tablica 3: Složena tablica na primjeru redovitih i izvanrednih studenata koji su diplomirali/završili studij 2018. godine prema vrsti visokih učilišta

Vrsta visokog učilišta	Redoviti studenati koji su diplomirali/završili studij	Izvanredni studenati koji su diplomirali/završili studij
Visoke škole	642	845
Veleučilišta	2564	2577
Stručni studiji	1441	1803
Sveučilišni studiji	19084	3546
Umjetničke akademije	697	42
Ukupno	24426	8813

Izvor: djelo autorice završnog rada prema podacima Državnog zavoda za statistiku, http://dzs.hr (pristupljeno 10. rujna 2019.)

Tablica 4: Kombinirana tablica na primjeru studenata koji su diplomirali/završili studij prema vrsti visokih učilišta i spolu

Vrsta visokog učilišta	Spol studenata koji su diplomirali/završili studij		Ukupno
	M	Ž	
Visoke škole	801	686	1487
Veleučilišta	2327	2814	5141
Stručni studiji	1225	2019	3244
Sveučilišni studiji	8513	14117	22638
Umjetničke akademije	239	500	739
Ukupno	13105	20136	33241

Izvor: djelo autorice završnog rada prema podacima Državnog zavoda za statistiku, http://dzs.hr (pristupljeno 10. rujna 2019.)

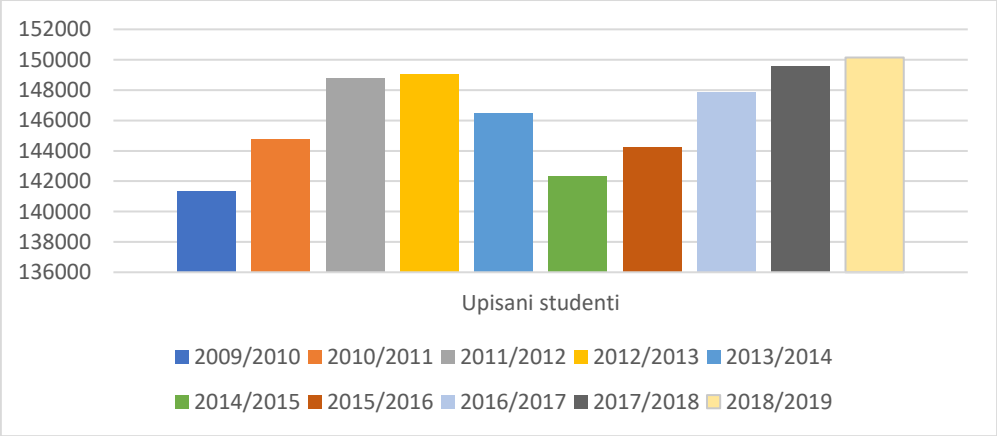
U mnogim službama statistički se podaci najčešće prikazuju statističkim tablicama. Takav način prikaza podataka ima prednosti za one radnike koji imaju sposobnost interpretacije određenih podataka, odnosno statističkog skupa podataka. Međutim, mnogo zainteresiranih osoba koje također sudjeluju u procesu donošenja odluka nisu u mogućnosti podatke prikazane putem statističke tablice pravilno protumačiti i iskoristiti na najpovoljniji način. Zbog toga, da bi se zornije uočile

određene društveno-ekonomske promjene, ali i zbog niza drugih potreba, statistički se podaci prikazuju i grafički, iako se može konstatirati da je takav oblik prikazivanja podataka u upravno-pravnim službama danas sve rjeđi.[13] Statistika se bavi s nekoliko vrsta grafičkih metoda prikazivanja, a grafikone se najčešće dijeli na površinske i linijske. U površinske se grafikone ubrajaju pravokutnici ili stupci, zatim kvadrati, krugovi i strukturni grafikoni koji će biti prikazani u daljnjem tekstu.

1) Grafički prikaz kvalitativnih podataka

Za prikazivanje kvalitativnih podataka najčešće se koriste uspravni i položeni stupci. Grafikon stupaca može poprimiti različite oblike, položaj stupaca može biti uspravan i položen, a nizova podataka koji se prikazuju stupcima na jednom grafikonu može biti jedan, dva ili više. Pritom, jednostavni stupci prikazuju jedan niz podataka, usporedni prikazuju više njih dok strukturni predočavaju strukturne pojave. Također, stupci mogu prikazivati apsolutne i relativne frekvencije. U nastavku, bit će prikazani kroz primjere neki od primjenjivih grafikona za prikaz kvalitativnih podataka.

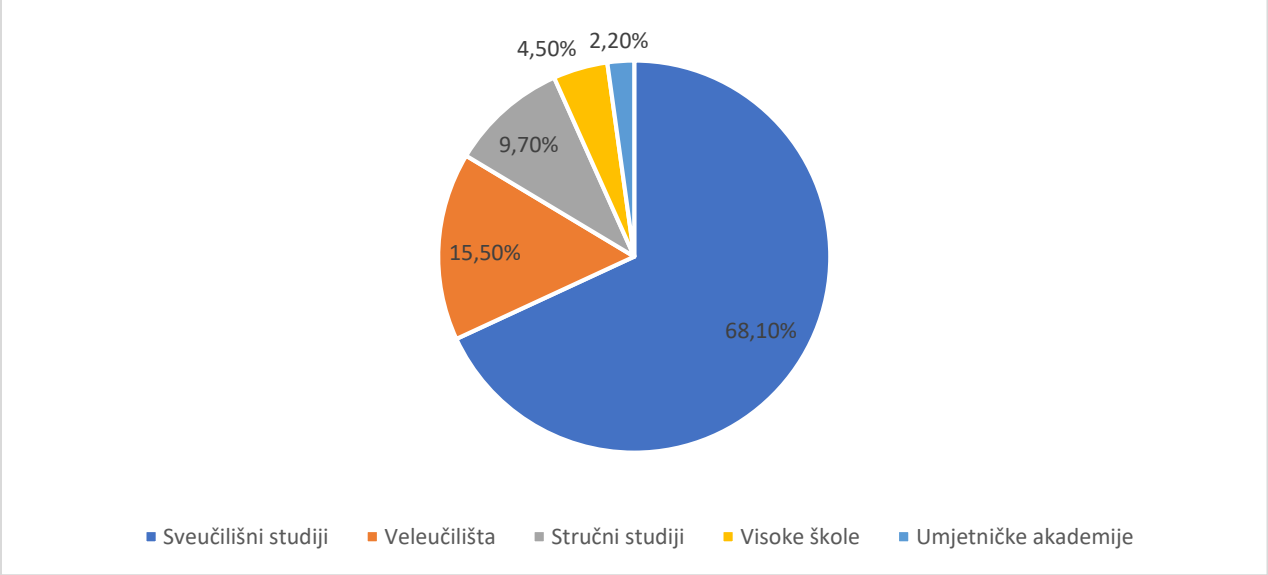
Grafikon 1. Jednostavni stupčasti grafikon na primjeru upisanih studenata na stručne i sveučilišne studije u RH u zimskom semestru prema akademskim godinama za razdoblje od 2009. do 2018. godine



Izvor: djelo autorice završnog rada prema podacima Državnog zavoda za statistiku, http://dzs.hr (pristupljeno 10. rujna 2019.)

[13] J. Žužul et.al., *Statistika u informacijskom društvu*, Zagreb, Europski centar za napredna i sustavna istraživanja ECNSI, 2008., str. 33

Grafikon 2. Strukturni grafikon na primjeru studenata koji su diplomirali/završili studij na visokim učilištima prema vrsti visokih učilišta u 2018. godini



Izvor: djelo autorice završnog rada prema podacima Državnog zavoda za statistiku, http://dzs.hr (pristupljeno 10. rujna 2019.)

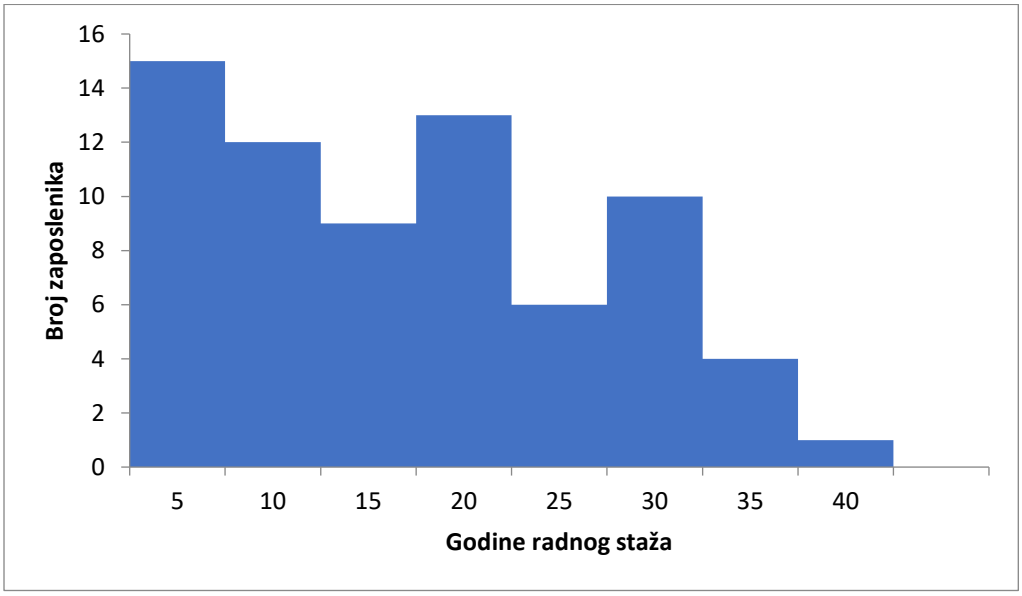
2) Grafički prikaz kvantitativnih podataka

Numerički se podaci mogu vizualizirati redanjem vrijednosti numeričke varijable od najmanje prema najvećoj (negrupirani numerički niz) ili formiranjem distribucije frekvencija.[14] Numerički nizovi podataka prikazuju se površinskim grafikonom histogramom ili linijskim grafikonom poligonom frekvencija pritom koristeći apsolutne ili relativne frekvencije. Histogram je stupčasti grafikon, sastavljen je od uspravnih spojenih stupaca čija širina odgovara širini razreda grupiranih podataka, a visina korigiranim frekvencijama grupiranih podataka. Tako da je površina stupaca iznad pojedinih razreda proporcionalna pripadajućim frekvencijama, odnosno relativnim frekvencijama. Svaki podatak doprinosu u histogramu n-ti dio površine, odnosno 1/n ukupne površine, gdje n predstavlja ukupan broj podataka. Drugim riječima, stupac i-tog razreda histograma čini $\frac{100f_i}{n}\%$ površine cijelog histograma, dok i-ti stupac čini $\frac{f_i}{n}$ ukupne površine. Poligon frekvencija je linijski grafikon koji prikazuje distribuciju frekvencija koje je potrebno korigirati ukoliko su razredi nejednakih širina. Ako se na

[14]K. Dumičić, et al., op. cit.., str 65

apscisu pravokutnoga koordinatnog sustava u ravnini nanesu vrijednosti rubova (granica) razreda i zatim iznad svakog razreda ucrta pravokutnik visine jednake odgovarajućoj frekvenciji (relativnoj frekvenciji) toga razreda, dobiva se tzv. histogram frekvencija danog niza statističkih podataka koji, dakako, ovisi o izvedenom grupiranju podataka. Ako se, pak, na apscisu nanesu sredine razreda, a kao pripadne ordinate uzmu odgovarajuće frekvencije (relativne frekvencije), dobiva se poligon frekvencija danog niza statističkih podataka uz provedeno grupiranje podataka u razrede.[15]

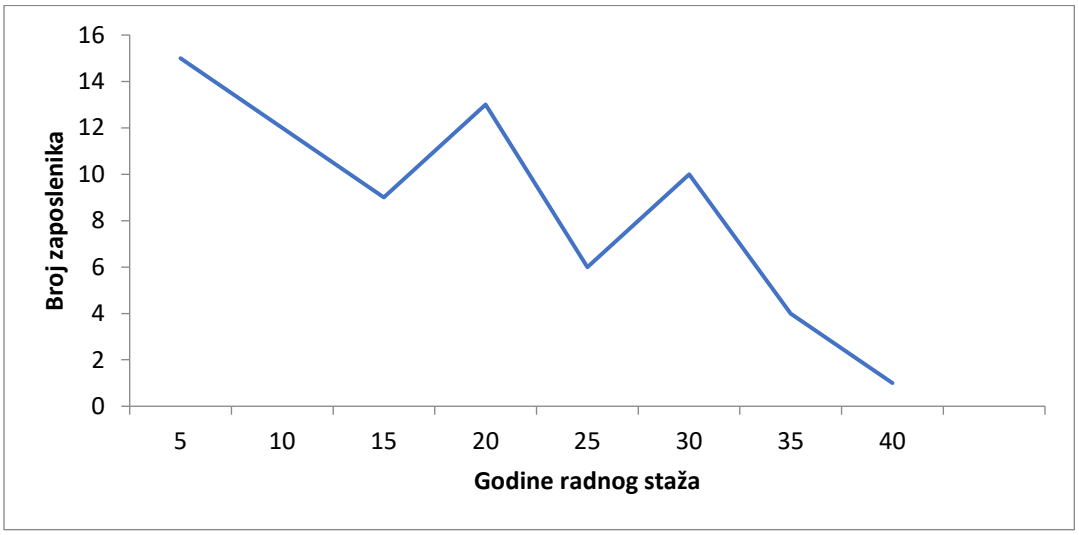
Grafikon 3. Histogram frekvencija na primjeru radnog staža zaposlenika u poduzeću „XY“



Izvor: djelo autorice završnog rada

[15] Ž. Pauše, *Uvod u matematičku statistiku,* Zagreb, Školska knjiga, 1993., str. 26.-27.

Grafikon 4. Poligon frekvencija na primjeru radnog staža zaposlenika u poduzeću „XY“

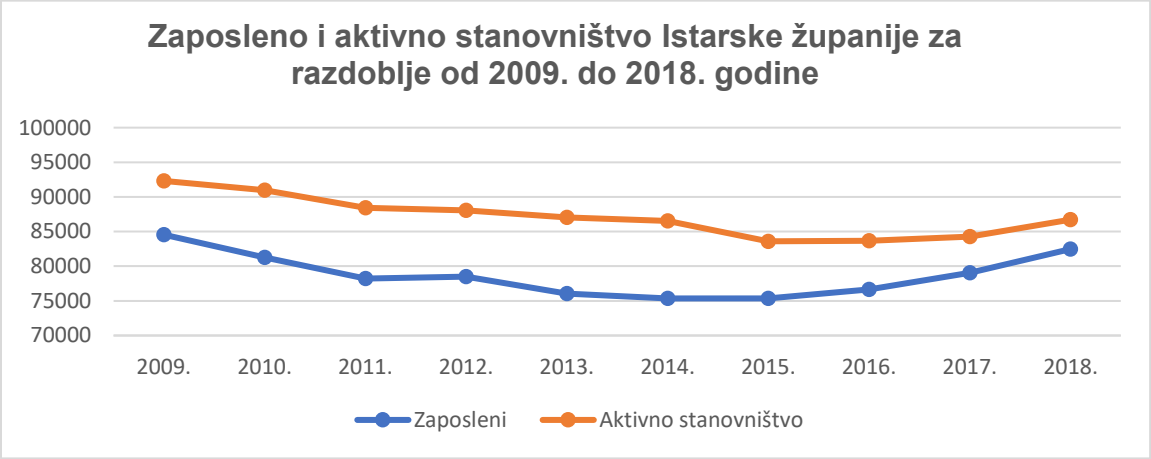


Izvor: djelo autorice završnog rada

3) Grafički prikaz vremenskih nizova

Vremenski nizovi prikaz su dinamike pojava u promatranim vremenskim točkama ili intervalima. Kod trenutačnog vremenskog niza u trenutku se mjere vrijednosti pojave, dok se kod intervalnog vremenskog niza frekvencije dobivaju postepenim zbrajanjem unutar intervala određene vremenske jedinice. Trenutačni vremenski niz prikazuje se linijskim grafikonom, a intervalni se uz linijskim prikazuje i jednostavnim stupčastim grafikonom.

Grafikon 5: Linijski grafikon više skupina podataka (poligon frekvencija) na primjeru ukupno zaposlenih u Istarskoj županiji prema administrativnim izvorima prema stanju 31. ožujka 2019. godine



Izvor: djelo autorice završnog rada prema podacima Državnog zavoda za statistiku http://dzs.hr (pristupljeno: 10. rujna 2019.)

3.7. Analiza i vrednovanje dobivenih rezultata

Podaci prikupljeni statističkim istraživanjem obrađuju se radi jednostavnije uporabe i preglednosti. Izračunati parametri predstavljaju rezultate. Proizvedenim rezultatima se, u skladu s okvirom kvalitete i očekivanja, provjerava kvaliteta koja može uključivati sljedeće radnje: usporedbu dobivenih statističkih rezultata s očekivanima, usporedba s relevantnim podacima te sa statističkim rezultatima iz prethodnih istraživanja, pronalaženje nedosljednosti i slično. Sljedeći korak je detaljna analiza i tumačenje, kao i sastavljanje internih izvješća koji prethode stjecanju odobrenja za objavljivanje dobivenih statističkih rezultata. Nadalje, potrebno je osigurati zaštitu i povjerljivost podataka, kao i primijeniti tehniku sprječavanja neovlaštenog pristupa.

Kako bi se dobiveni rezultati mogli vrednovati, odnosno kako bi se mogla ocijeniti njihova kvaliteta, potrebne su povratne informacije korisnika, prijedlozi zaposlenika te sve ostale potencijalno korisne informacije koje će poslužiti ocjenjivaču. Inputi za vrednovanje analiziraju se te uključuju u izvješće o kvaliteti kako bi se uvidjeli potencijalni problemi tijekom provedbe statističkog istraživanja te preporučile izmjene. Temeljem izvješća, odgovorne osobe se sastaju te sastavljaju akcijski plan za poboljšanje koji treba uključivati vrednovanje proizvodnog procesa kao i prijedloge njegova poboljšanja.

4. Prikupljanje i statistička obrada podataka Studentskog servisa Pula

4.1. Informacije o Studentskom centru Pula

Studentski centar Pula osnovan je 1. srpnja 2007. godine kao samostalna ustanova, a od 1. siječnja 2008. godine djeluje kao sastavnica Sveučilišta Jurja Dobrile u Puli. Nastojanja Studentskog centra Pula usmjerena su na povećanje smještajnih kapaciteta te osiguravanje dodatnih sadržaja kao potporu za aktivnosti i potrebe studenata. Aktivnosti s područja svih djelatnosti Studentskog centra Pula - prehrane, smještaja i zapošljavanja, usmjerene su na kontinuirano doprinošenje razvoju studentskog standarda, a time i šire akademske zajednice.

U sklopu Studentskog centra Pula djeluje i Student servis koji studentima i učenicima završnih razreda srednjih škola (građani RH ili građani EU s prebivalištem u RH), omogućava privremeno i povremeno zapošljavanje. Studenti zaposlenjem preko Student servisa ostvaruju svoja prva poslovna iskustva, upoznaju se sa zahtjevima tržišta rada, a za svoj rad ostvaruju zaradu. S druge strane, poslodavci angažiranjem studenata posredstvom Student servisa zapošljavaju mladu radnu snagu sukladno karakteristikama i preferencijama koje navode prilikom oglašavanja posla.

Studentski centar Pula, kao i Student servis Pula vode evidencije o poslovanju prikupljajući različite podatke. Prikupljene podatke grupiraju, obrađuju te analiziraju kako bi pratili trendove u poslovanju te postavili temelje za daljnje poslovanje. U nastavku rada usredotočit će se na djelovanje Studentskog servisa Pula, navest će se podaci koje prikupljaju te kako ih obrađuju. Dobiveni podaci od strane Studentskog servisa Pula prikazat će se grafički i tabelarno te protumačiti trendovi kretanja poslovanja temeljem perioda od tri godine, za koji su podaci ustupljeni (od 1. siječnja 2016. do 31. prosinca 2018. godine).

4.2. Prikupljanje podataka Student servisa Pula

Kako bi Student servis mogao pratiti vlastito poslovanje te radnu aktivnost studenata i ponudu poslova studentima od strane poduzeća, mora voditi statistiku tijekom poslovanja. Da bi evidencija bila moguća potrebni su podaci koje prikuplja kako

od strane studenata, tako i od strane poslodavaca. U nastavku su tabelarno prikazani podaci koje Student servisu prikuplja prilikom registracije korisnika.

Tablica 5. Kategorije podataka koje prikuplja Student servis Pula

Podaci studenata	Podaci poslodavaca
Ime i prezime	Naziv pravnog subjekta
Spol	OIB
OIB	Adresa
Datum rođenja	Kontakt
Adresa	
IBAN (informacije o bankovnom računu)	
Osobni kontakt	

Izvor: djelo autorice završnog rada temeljem podataka SS Pula

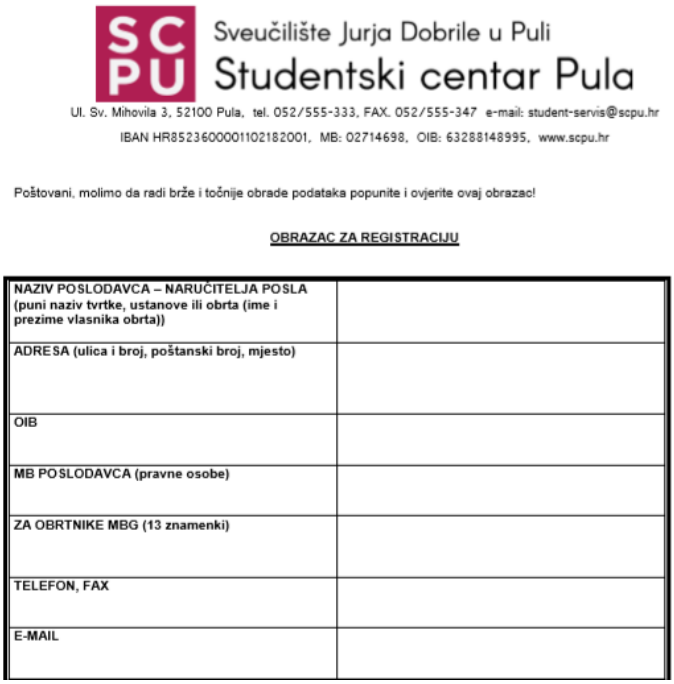
Prema vrsti podataka, prikupljeni podaci su kvalitativni, odnosno kategorički, mjereni na nominalnoj ljestvici te se nad njima ne obavljaju računske operacije, za takve podatke moguće je samo utvrditi najčešće vrijednosti (mod). Student servis ih prikuplja radi vlastite evidencije korisnika njihovih usluga te su ti podaci zaštićeni Zakonom o zaštiti osobnih podataka.

GDPR je uredba Europskog parlamenta i Vijeća iz 2016. godine o zaštiti prava pojedinca u vezi s obradom i slobodom korištenja osobnih podataka. Organizacijama GDPR pomaže da se obrada osobnih i ostalih kategorija podataka obavlja na sigurniji i kvalitetniji način te ih štiti od zlouporabe. GDPR sadrži prava ispitanika te obveze organizacije u prikupljanju i obradi podataka. Osnovno pravo ispitanika je da se osobni podaci ne smiju prikupljati bez ispitanikove privole tj. pisanog pristanka da se određeni osobni podaci prikupljaju, obrađuju i čuvaju u određene svrhe. Organizacija, u ovom slučaju Student servis Pula, koja prikuplja, čuva i obrađuje osobne podatke, ima niz obveza i to: upravljanja privolama, sigurne obrade i čuvanja osobnih podataka, obavještavanja nadzornog tijela i ispitanika u slučaju incidenta (gubitak, krađa, neovlašteni pristup podacima i sl.) te obvezu imenovanja službenika za zaštitu osobnih podataka.

Podaci o studentima prikupljaju se pri osobnom dolasku studenata u poslovnicu Student servisa Pula gdje ispunjavaju obrazac o osobnim podacima. Podaci o poslodavcima prikupljaju se također pri osobnom dolasku poslodavaca ili putem online

obrazaca koji su dostupni na mrežnoj stranici Studentskog centra Pula. U nastavku je prikazan prethodno navedeni obrazac.

Slika 2. Obrazac za registraciju poslodavaca



Sveučilište Jurja Dobrile u Puli
Studentski centar Pula

Ul. Sv. Mihovila 3, 52100 Pula, tel. 052/555-333, FAX. 052/555-347 e-mail: student-servis@scpu.hr
IBAN HR8523600001102182001, MB: 02714698, OIB: 63288148995, www.scpu.hr

Poštovani, molimo da radi brže i točnije obrade podataka popunite i ovjerite ovaj obrazac!

OBRAZAC ZA REGISTRACIJU

NAZIV POSLODAVCA – NARUČITELJA POSLA (puni naziv tvrtke, ustanove ili obrta (ime i prezime vlasnika obrta))	
ADRESA (ulica i broj, poštanski broj, mjesto)	
OIB	
MB POSLODAVCA (pravne osobe)	
ZA OBRTNIKE MBG (13 znamenki)	
TELEFON, FAX	
E-MAIL	

Izvor: preuzeto sa stranice http://scpu.hr (pristupljeno 1.rujna 2019.)

Uz prikazani obrazac, na internetskoj stranici Studentskog centra Pula postoji mogućnost predaje oglasa poslova poslodavaca online putem. Ispunjavajući upitnik prilikom predaje oglasa, uz ranije navedene podatke, poslodavci prilažu i podatke o vrsti posla, mjestu posla, minimalnoj i maksimalnoj predviđenoj cijeni sata, putnom trošku, potrebnom broju studenata, periodu rada te radnom vremenu.

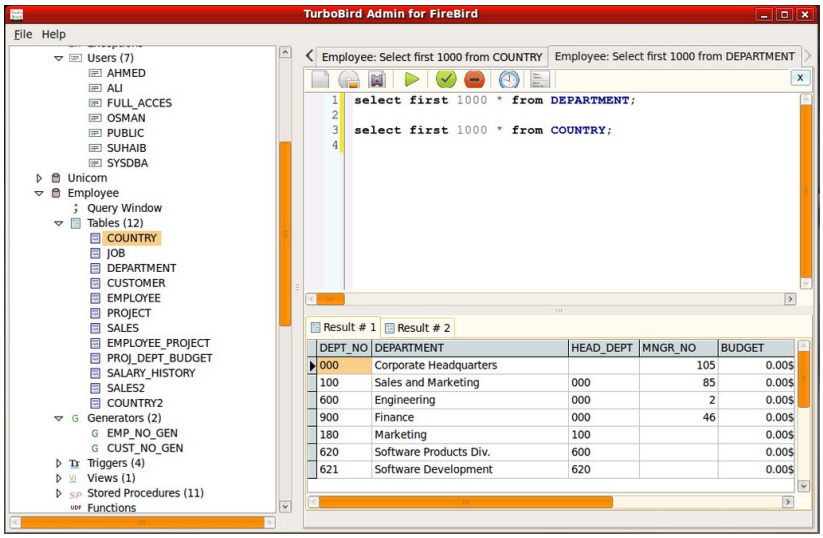
4.3. Obrada podataka Student servisa Pula

Studentski centar Pula, a time i Student servis koristi informatički program poduzeća Konto d.o.o. u sklopu kojeg imaju mogućnost analizirati prikupljene podatke. Osnovna djelatnost Konta d.o.o. je projektiranje, razvoj i održavanje informacijskih sustava. Poduzeće svojim klijentima nudi kompletna poslovna rješenja kao i aplikacije za pojedinačne poslovne procese. Student servis Pula sve prethodno navedene podatke prikupljene od studenata i poslodavaca unosi u informatički program poduzeća Konto d.o.o. kojim se podaci grupiraju i obrađuju kako bi poslužili kasnijoj analizi. Karakteristike informatičkog programa su sljedeće:

- platforma programa su Windows poslužitelji 2008/2012 i Windows 7/8 radne stanice
- podaci se spremaju u relacijsku bazu FireBird (ex InterBase) koja je besplatna (open source)
- podaci se zapisuju u transakcijama
- vode se podaci o korisnicima programa, o datumu i vremenu unosa nove ili izmjene stare stavke
- prate se zahtjevi obrade podataka
- korisnicima su mogućnosti pregleda i uređivanja definirane ovlastima
- podaci se eksportiraju u Excel tablice
- izvješće o obradi podataka snima se u TXT i RTF formatu, zatim se sprema u PDF formatu te se direktno iz programa šalje e-mailom klijentu koji koristi informatički program

Slijedi prikaz Firebird sustava za upravljanje relacijskim bazama koji koristi poduzeće Konto d.o.o. u programskim proizvodima. Relacijska baza podataka poseban je tip baze podataka u kojoj se organizacija podataka zasniva na relacijskom modelu, odnosno podaci se organiziraju u skup relacija između kojih se definira određena veza.

Slika 3. Firebird sustav za upravljanje relacijskim bazama podataka



Izvor: preuzeto sa http://firebirdsql.org (pristupljeno 01.09.2019.)

KONTO d.o.o. kao jedna od vodećih domaćih IT poduzeća specijaliziranih za razvoj računovodstvenog softvera, poštujući uredbu GDPR-a, polaže veliku pažnju u sigurnost programskih rješenja i podataka koje ti programi obrađuju. Svojim programskim rješenjima uveli su prava pristupa na način da je pristup određenim kategorijama podataka ograničen kao i određenim funkcionalnostima aplikacija. Na taj način, vodi se briga o najvišoj razini sigurnosti i zaštite podataka, dodjeljivanju prava korištenja i praćenja određenih aktivnosti nad podacima, do postupaka omogućavanja izrade sigurnosne kopije podataka. Tehnički je omogućena redovita sigurnosna zaštita podataka pa se u slučaju njihova gubitka može vratiti barem dio. Preventivne mjere poduzimaju se kako bi se spriječili incidenti, kao i mjere za lakši oporavak i utvrđivanje odgovornosti u slučaju nastanka incidenta.

4.4. Grafički prikaz podataka ustupljenih od Student servisa Pula

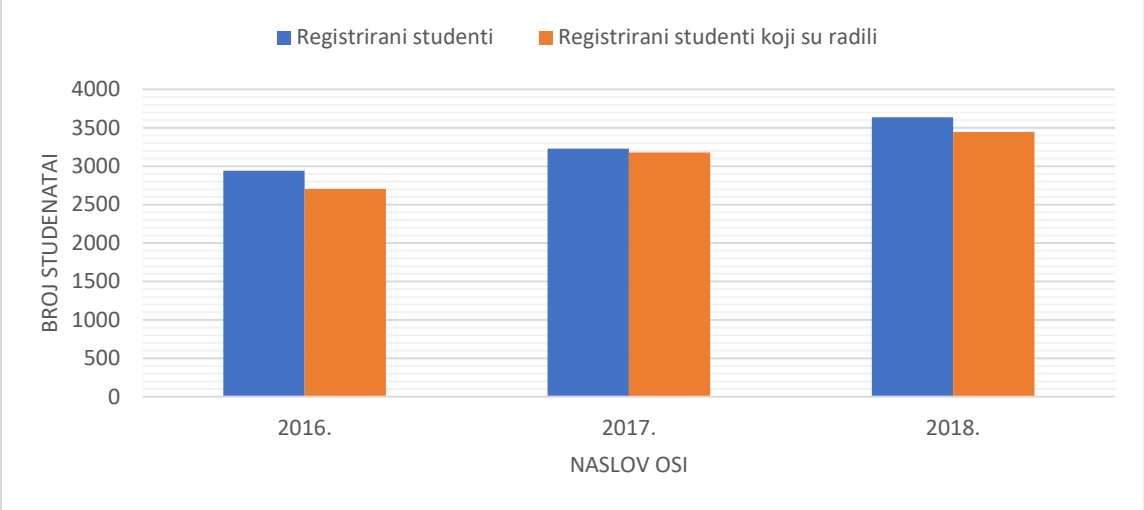
Koristeći podatke koji su, za potrebe završnog rada, ustupljeni od Student servisa Pula, u nastavku bit će obrađena te grafički i tabelarno prikazana statistička analiza ostvarenih rezultata u poslovanju.

Tablica 6. Učlanjeni studenti i učlanjeni studenti koji su radili posredstvom Student servisa Pula u razdoblju od 1. siječnja 2016. godine do 31. prosinca 2018. godine

Godina	Broj učlanjenih studenata	Broj učlanjenih studenata koji su radili putem SS Pula
2016.	2942	2702
2017.	3227	3179
2018.	3638	3446

Izvor: djelo autorice završnog rada temeljem podataka SS Pula

Grafikon 6. Kretanje učlanjenih studenata i učlanjenih studenata koji su radili posredstvom Student servisa Pula u razdoblju od 1. siječnja 2016. godine do 31. prosinca 2018. godine.



Izvor: djelo autorice završnog rada temeljem podataka SS Pula

Iz Tablice 6. i Grafikona 6. vidljivo je kako se broj studenata koji su radili posredstvom Student servisa Pula povećao od 2016. do kraja 2018. godine. Za svaku pojedinu godinu razlika između broja učlanjenih studenata koji su obavljali studentski posao te učlanjenih studenata koji su bili radno neaktivni nije bila velika. Najmanja je razlika 2017.godine kada samo 1,5% registriranih studenata nije stupilo u radni odnos.

Tablica 7. Verižni indeksi učlanjenih studenata u periodu od 1. siječnja 2016. do 31. prosinca 2018. godine

Godina	Broj studenata (y_t)	Verižni indeks (V_t)
2016.	2942	-
2017.	3227	109,69
2018.	3638	112,74

Izvor: djelo autorice završnog rada temeljem podataka SS Pula

Prethodno prikazana tablica prikazuje broj registriranih studenata te na temelju tih apsolutnih vrijednosti izračunati verižni indeksi. Verižni indeksi potrebni su kako bi se izračunala geometrijska sredina putem koje se izračunava prosječna stopa promjene. Prosječna stopa promjene stopa je koja pokazuje prosječnu promjenu vrijednosti pojave, odnosno povećanje ili smanjenje, iskazano u postocima. U ovom primjeru

izračunava se prosječna stopa promjene broja učlanjenih studenata u Student servis Pula.

$$\bar{s} = \left(\sqrt[n-1]{\frac{y_n}{y_1}} - 1 \right) * 100 = = (G - 1) * 100$$

Gdje je:

$\bar{s} - prosječna\ stopa\ promjene$

$y_n - posljednja\ vrijednost\ vremenskog\ niza$

$y_1 - prva\ vrijednost\ vremenskog\ niza$

$G - geometrijska\ sredina$

$n - broj\ članova\ vremenskog\ niza$

$$\bar{s} = \left(\sqrt[3-1]{\frac{3638}{2942}} - 1 \right) * 100$$

$$\bar{s} = 11{,}20\ \%$$

U promatranom razdoblju od 1. siječnja 2016. do 31. prosinca 2018. godine, prosječna stopa registriranih studenata u Studentskom servisu Pula prosječno se godišnje povećala za 11,20 %.

Pomoću utvrđene prosječne stope promjene moguće je prognozirati, uz pretpostavku da će se promatrana pojava i u idućem razdoblju kretati prema utvrđenom trendu. U tom se slučaju prognozira pomoću sljedećeg izraza:[16]

$$\hat{y}_{n+\tau} = y_n * G^{\tau}$$

Gdje je:

$\hat{y}_{n+\tau} - procijenjena\ vrijednost\ niza\ u\ vremenu\ n + \tau$

[16] K. Dumičić, et al., op.cit., str. 403

$\tau - broj\ razdoblja\ nakon\ posljednjeg\ za\ koje\ se\ provodi\ prognoza$

Nadalje, prikazano je predviđanje potrebnog vremenskog perioda kako bi se količina registriranih studenata u Studentskom servisu Pula udvostručila.

$$G^{\tau} = \frac{\hat{Y}_{n+\tau}}{y_n}$$

$$1{,}11^{\tau} = \frac{7276}{3638}$$

$$1{,}11^{\tau} = 2/^{log}$$

$$\tau = 6{,}64 \approx 6.5\ god$$

Prema prethodnom izračunu, pod pretpostavkom da na količinu registriranih studenata utječu svi čimbenici koji su utjecali u periodu od 2016. do 2018. godine te da se pojava nastavi kretati istim smjerom i istim intenzitetom, predviđa se kako je potrebno otprilike 6,5 godina da bi se broj registriranih studenata u Studentskom servisu Pula udvostručio.

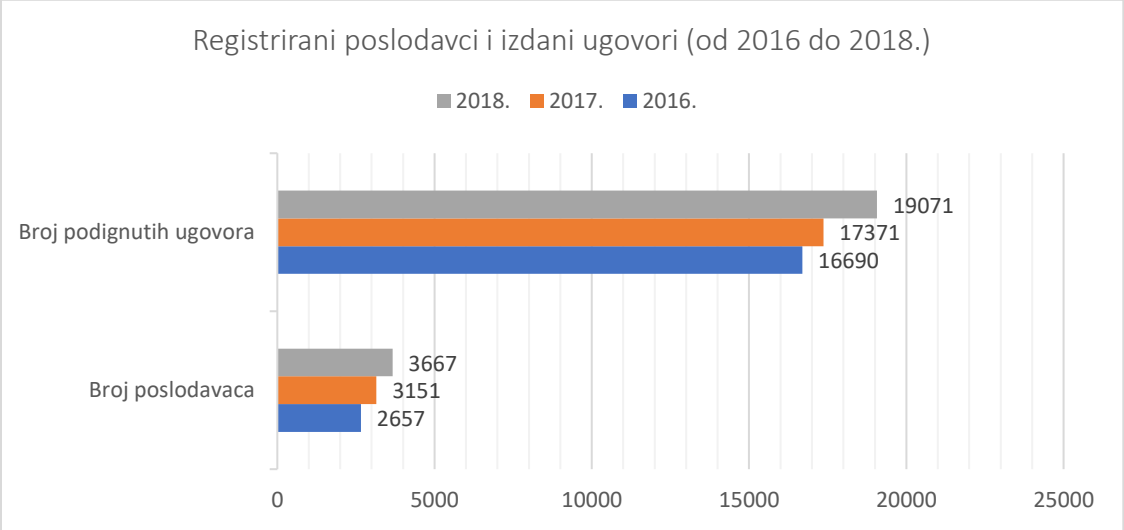
Tablica 8: Registrirani poslodavci i izdani ugovori u Student servisu Pula u razdoblju od 1. siječnja 2016. do 31. prosinca 2018.

Godina	Broj poslodavaca	Broj ugovora
2016.	2657	16690
2017.	3151	17371
2018.	3667	19071

Izvor: djelo autorice završnog rada temeljem podataka SS Pula

Prethodna tablica prikazuje količinu registriranih poslodavaca i izdanih ugovora Studentskog servis Pula za razdoblje od tri godine. Sljedećim grafikonom prikazano je kretanje količine poslodavaca i ugovora u promatranom razdoblju.

Grafikon 7. Kretanje registriranih poslodavaca i izdanih ugovora u Student servisu Pula u razdoblju od 1. siječnja 2016. do 31. prosinca 2018.



Izvor: djelo autorice završnog rada temeljem podataka SS Pula

Iz Tablice 8. i Grafikona 7. vidljivo je kako se u razdoblju od 1. siječnja 2016. do 31. prosinca 2018. godine usporedno povećavao broj registriranih poslodavaca koji svoje radnike potražuju posredstvom Studentskog servisa Pula kao i broj podignutih ugovora. Broj podignutih ugovora, kao i broj poslodavaca ne znači nužno da su svi ti ugovori obrađeni, kao i da su svi registrirani poslodavci pronašli radnike putem Studentskog servisa Pula. Mali broj ugovora na godišnjoj razini ostaje nerealiziran jer je student odustao od obavljanja posla. Prema informacijama dobivenih usmenim putem od Studentskog servisa Pula, u prosjeku pedesetak ugovora na godišnjoj razini bude storniran. U svrhu prikaza odnosa broja podignutih ugovora i broja registriranih poslodavaca koriste se relativni brojevi koordinacije. Relativni brojevi koordinacije (RBK) nastaju dijeljenjem koordinirajućih veličina (veličina koje se uspoređuju). Dani su izrazom:[17]

$$R_i = \frac{v_i}{B_i}, \qquad i = 1,2, \dots, k$$

Gdje je:

$R_i - relativni\ broj\ koordinacije$

[17] I. Šošić, op. cit., str. 27

$v_i - veličina\ pojave\ koja\ se\ uspoređuje$

$B_i - vrijednosti\ pojave\ s\ kojom\ se\ uspoređuje\ pojava\ u\ brojniku$

$$R_{1\ (2016.)} = \frac{16690}{2657} = 6{,}28$$

$$R_{2(2017.)} = \frac{17371}{3151} = 5{,}51$$

$$R_{3(2018.)} = \frac{19071}{3667} = 5{,}20$$

Tablica 9: Relativni brojevi koordinacije (RBK) izdanih ugovora i registriranih poslodavaca u Student servisu Pula za razdoblje od 1. siječnja 2016. do 31. prosinca 2018. godine

Godina (i)	Broj ugovora (v_i)	Broj poslodavaca (B_i)	Relativni broj koordinacije (R_i)
1. 2016.	16690	2657	6,28
2. 2017.	17371	3151	5,51
3. 2018.	19071	3667	5,20

Izvor: djelo autorice završnog rada temeljem podataka SS Pula

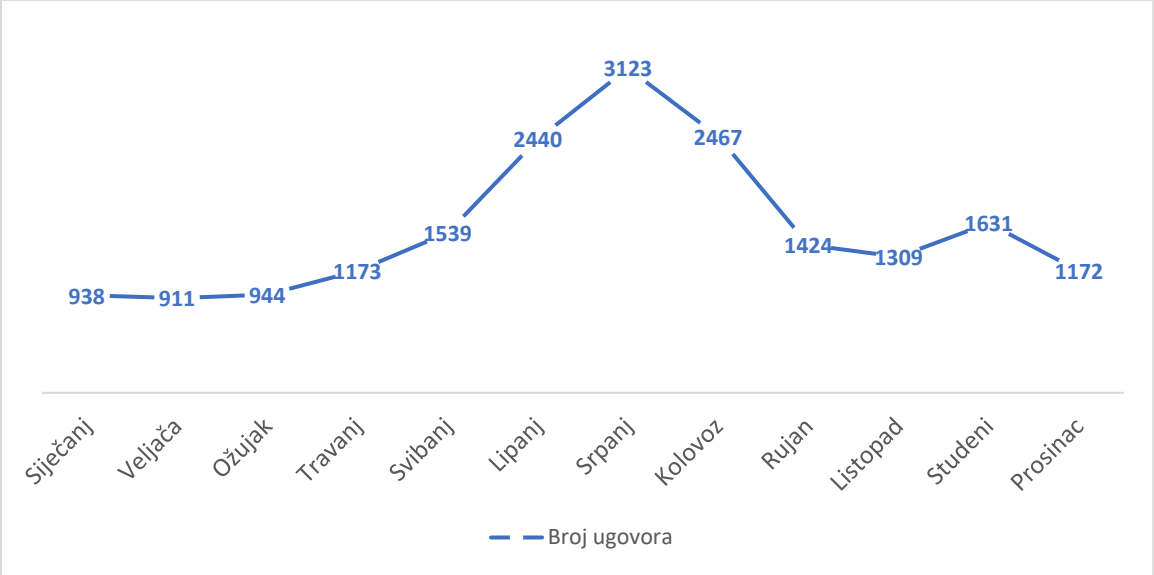
Posredstvom Studentskog servisa Pula u 2016. godini podignuto je prosječno 6,28 ugovora po poslodavcu. U 2017. godini prosječan broj podignutih ugovora po poslodavcu iznosio je 5,51, dok je u 2018. godini prosječno iznosio 5,20 ugovora po poslodavcu.

Tablica 10. Izdani studentski ugovori Studentskog servisa Pula prema mjesecima za razdoblje 2018. godine

Siječanj	Veljača	Ožujak	Travanj	Svibanj	Lipanj
938	911	944	1173	1539	2440
Srpanj	Kolovoz	Rujan	Listopad	Studeni	Prosinac
3123	2467	1424	1309	1631	1172

Izvor: djelo autorice završnog rada temeljem podataka SS Pula

Grafikon 8: Kretanje izdanih studentskih ugovora Studentskog servisa Pula prema mjesecima za razdoblje 2018. godine



Izvor: djelo autorice završnog rada temeljem podataka SS Pula

Promjene koje nastaju pod utjecajem sezone, mjere se posebnom grupom indeksa koji se nazivaju sezonski indeksi. Grubi sezonski indeksi računaju se na način da originalne vrijednost podijelimo s aritmetičkom sredinom te pomnožimo sa 100 prema formuli:

$$\overline{x} = \frac{\sum x_i}{N}$$

$$I = \frac{x_i}{\overline{x}} * 100$$

Gdje je:

$\overline{x} - aritmetička\ sredina$

$x_i - pojedinačna\ vrijednost$

$I - sezonski\ index$

$$\overline{x} = \frac{19071}{12} = 1589{,}25$$

$$I = \frac{938}{1589{,}25} * 100 = 59{,}02$$

Tablica 11. Izdani studentski ugovori Studentskog servisa Pula prema mjesecima za razdoblje 2018. godine uz izračun sezonskog indeksa

Mjesec	Broj podignutih ugovora	Sezonski indeksi
I.	938	59,02
II	911	57,32
III.	944	59,40
IV.	1173	73,81
V.	1539	96,84
VI.	2440	153,53
VII.	3123	196,51
VIII.	2467	155,23
IX.	1424	89,60
X.	1309	82,37
XI.	1631	102,63
XII.	1172	73,74

Izvor: djelo autorice završnog rada temeljem podataka SS Pula

Prema dobivenim rezultatima, moglo bi se zaključiti da količina podignutih ugovora podliježe sezonskim utjecajima. U razdoblju do lipnja broj podignutih ugovora podliježe sezonskim utjecajima ispodprosječnom tendencijom. U periodu od lipnja do rujna podignut je veći broj studentskih ugovora od prosječnog što ukazuje na sezonalni karakter pojave iznadprosječnom tendencijom. Nakon toga, broj podignutih ugovora ponovo je manji od prosječnog, s iznimkom u studenom mjesecu promatrane godine. Kako se radi o studentskim poslovima, očekivano je kako će najveći broj ugovora biti podignut upravo u mjesecima kad studenti nemaju predavanja te se odluče za rad posredstvom Student servisa.

Tablica 12. Poduzeća koja najviše zapošljavaju studente posredstvom Student servisa Pula od 1. Siječnja 2018. do 31. Prosinca 2018.

Rang	Naziv poduzeća
1.	Arena Hospitality Group d.o.o.
2.	Zračna luka Pula
3.	Maistra d.d.
4.	Kaufland Hrvatska k.d.
5.	Plodine d.d.
6.	Valamar Rivijera
7.	Spar Hrvatska d.o.o.
8.	Globalna hrana d.o.o. (McDonald`s)
9.	C.M.G.C. d.o.o.
10.	TDR d.o.o.

Izvor: djelo autorice završnog rada temeljem podataka SS Pula

Iz popisa poduzeća koja najviše zapošljavaju studente posredstvom Studentskog servisa Pula, uočava se kako se studenti najviše zapošljavaju u sektoru turizma, ugostiteljstva te trgovine. Uglavnom su to veća poduzeća koja, kad potražuju studente za rad posredstvom Student servisa, imaju potrebe za većim brojem studenata (15 do 30 studenata) pa je shvatljivo kako je najveći broj studentskih ugovora izdano u svrhu rada u gore navedenima. Njihova potražnja za radnom snagom posebice raste u ljetnim mjesecima, usporedno s povećanjem količine ponude rada studenata te čine znatan udio u broju podignutih ugovora Studentskog servisa Pula.

5. Zaključak

Čovjek sa svojim obilježjima i djelovanjem, i statistika, odnosno njeni podaci i analize, tvore neraskidivu međuovisnu vezu, djelujući jedan na drugog, bilo kao izvor podataka ili kao povod budućeg promišljanja i ponašanja. Akt rođenja, sklapanja braka, zapošljavanje/nezaposlenost, kupovanje stana, zaposlenost studenata…samo su dio aspekta ljudskog života koji možemo prikazati pomoću brojeva ili kodova te učiniti statističkim podatkom. Čovjek je izvor i uzrok tih podataka, ali on ih i prikuplja i obrađuje, dok statistika, svakom tom aspektu daje smisao prevodeći ga u objektivnu statističku informaciju.

Kako bi statističko istraživanje bilo mjerodavno, važno je primijeniti prikladnu statističku metodu analize podataka. Primarni podaci rezultat su primarnog istraživanja. Sekundarnim podacima, koji su rezultat istraživanja drugih istraživača i skupina, danas se, zahvaljujući Internetu, može pristupiti u svakom trenutku. Suvremena obrada podataka odvija se elektroničkim putem što smanjuje vrijeme obrade kao i mogućnost pogreške. Sve faze statističkog istraživanja važno je dobro poznavati i provesti, kako bi rezultati bili kvalitetni i precizni, a njihovo naknadno tumačenje i analiza utemeljeno i ispravno. Značajan korak, u statističkom istraživanju, je podatke prikazane tabelarno i/ili grafički pravilno i protumačiti u svrhu kvalitetne interpretacije rezultata.

U ovom radu obrađen je primjer prikupljanja i statističke obrade podataka Studentskog servisa Pula. Studentski servis u ulozi posrednika u zapošljavanju između studenata i poslodavaca, prikuplja podatke o njima te ih unosi u informatički program. Prikazom količine registriranih studenata i poslodavaca učinjena je statistička analiza o zapošljavanju studenata posredstvom Studentskog servisa Pula za razdoblje od tri godine (od 2016. do 2018. godina). U promatranom vremenskom razdoblju u blagom je porastu broj registriranih poslodavaca i studenata, kao i broj podignutih ugovora o radu, iz čega je uočen blagi trend porasta zapošljavanja studenata putem Studentskog servisa Pula. Potencijalni razlozi povećanja studentske radne angažiranosti mogu se objasniti i promjenom u Zakonu iz 2018. godine kojom se dozvoljava rad i izvanrednim studentima te propisuje i garantira minimalna satnica od 23,44 kn. Zapošljavanje studenata kao promatrana pojava i predmet ovog istraživanja ima obilježja sezonalnog karaktera. Najviše ugovora o radu u promatranoj 2018. godini izdano je u periodu od

lipnja do rujna. S obzirom da je Pula, odnosno Istra, turistička regija koja u ljetnim mjesecima bilježi priličan broj boravišnih prijava domaćih i inozemnih gostiju, sukladno tome povećane su i potrebe smještajnog, trgovinskog, uslužnog, prijevoznog i ostalog pratećeg sadržaja.

Pažljivo i kvalitetno prikupljanje podataka, njihova obrada i analiza podataka temelj su donošenja vrijednih zaključaka o postojećem stanju. U težnji prema željenom, budućem stanju, taj zaključak postaje ishodište za donošenje ispravnih poslovnih i ostalih odluka. Statistika je tako, spona između realne prošlosti i pretpostavljene željene budućnosti.

Literatura

Knjige

1. Bahovec V. et al., *Statistika,* 1. izdanje, Zagreb, ELEMENT d.o.o., 2015.

2. Bosilj Vukšić, V. i Pejić Bach, M. *Poslovna informatika,* 2. izmijenjeno izdanje, Zagreb, ELEMENT d.o.o., 2015.

3. Dumičić, K. et al., *Poslovna statistika,* 1. izdanje, Zagreb, ELEMENT d.o.o., 2011.

4. Pauše, *Ž. Uvod u matematičku statistiku,* Zagreb, Školska knjiga, 1993.

5. Šošić. I. *Primijenjena statistika*, 2. izmijenjeno izdanje, Zagreb, Školska knjiga, 2006.

6. Žužul, J. et.al., *Statistika u informacijskom društvu*, Zagreb, Europski centar za napredna i sustavna istraživanja ECNSI, 2008.

Internetske stranice

1. Državni zavod za statistiku., 2019., http://dzs.hr (pristupljeno 10. rujna 2019.).

2. Firebird., 2019., http://firebirdsql.org (pristupljeno 1. rujna, 2019.).

3. Konto d.o.o., 2019., http://konto.hr (pristupljeno 1. rujna 2019.)

4.. Studentski centar Pula., 2019., http://scpu.hr (pristupljeno 15. kolovoza 2019.).

Popis slika, grafikona i tablica

Slike

Slika 1. Prikaz odnosa populacije i uzorka

Slika 2. Obrazac za registraciju poslodavaca

Slika 3. Firebird sustav za upravljanje relacijskim bazama podataka

Tablice

Tablica 1. Kriteriji ocjene načina elektroničke obrade podataka

Tablica 2. Jednostavna tablica na primjeru studenata koji su diplomirali/završili studij 2018. godine prema vrsti visokih učilišta

Tablica 3. Složena tablica na primjeru redovitih i izvanrednih studenata koji su diplomirali/završili studij 2018. godine prema vrsti visokih učilišta

Tablica 4. Kombinirana tablica na primjeru studenata koji su diplomirali/završili studij 2018. godine prema vrsti visokih učilišta i spolu

Tablica 5. Kategorije podataka koje prikuplja Student servis Pula

Tablica 6. Učlanjeni studenti i učlanjeni studenti koji su radili posredstvom Student servisa Pula u razdoblju od 1. siječnja 2016. do 31. prosinca 2018. godine

Tablica 7. Verižni indeksi učlanjenih studenata u Student servis Pula u periodu od 1. siječnja 2016. godine do 31. prosinca 2018. godine

Tablica 8. Registrirani poslodavci i izdani ugovori u Student servisu Pula u razdoblju od 1. siječnja 2016 do 31. prosinca 2018. godine

Tablica 9. Relativni brojevi koordinacije (RBK) izdanih ugovora i registriranih poslodavaca u Student servisu Pula za razdoblje od 1. siječnja 2016. do 31. prosinca 2018. godine

Tablica 10. Izdani studentski ugovori Studentskog servisa Pula prema mjesecima za razdoblje 2018. godine

Tablica 11. Izdani studentski ugovori Studentskog servisa Pula prema mjesecima za razdoblje 2018. godine uz izračun sezonskog indeksa

Tablica 12. Poduzeća koja najviše zapošljavaju studente posredstvom Student servisa Pula od 1. siječnja 2016. do 31. prosinca 2018. godine

Grafikoni

Grafikon 1. Jednostavni stupčasti grafikon na primjeru upisanih studenata na stručne i sveučilišne studije u RH u zimskom semestru prema akademskim godinama za razdoblje od 2009. do 2018. godine

Grafikon 2. Strukturni grafikon na primjeru studenta koji su diplomirali/završili studij na visokim učilištima prema vrsti visokih učilišta u 2018. godini

Grafikon 3. Histogram frekvencija na primjeru radnog staža zaposlenika u poduzeću „XY“

Grafikon 4. Poligon frekvencija na primjeru radnog staža zaposlenika u poduzeću „XY“

Grafikon 5. Linijski grafikon više skupina podataka (poligon frekvencija) na primjeru ukupno zaposlenih u Istarskoj županiji prema administrativnim izvorima prema stanju 31. ožujka 2019. godine

Grafikon 6. Kretanje učlanjenih studenti i učlanjenih studenata koji su radili posredstvom Student servisa Pula u razdoblju od 1. siječnja 2016. do 31. prosinca 2018. godine

Grafikon 7. Kretanje registriranih poslodavaca i izdanih ugovora u Student servisu Pula u razdoblju od 1. siječnja 2016 do 31. prosinca 2018. godine

Grafikon 8. Kretanje izdanih studentskih ugovora Studentskog servisa Pula prema mjesecima za razdoblje 2018. godine

Sažetak

Statistika je znanost prisutna u svakom aspektu našeg života. Prikupljanjem podataka, obradom i vrednovanjem rezultata pruža nam pravovremene, točne i pouzdane informacije koje su temelj daljnjih akcija. Ovisno o području djelatnosti, primjenjuju se deskriptivne ili inferencijalne statističke metode. Odabir metode ovisi o varijabli čiji se podaci žele istražiti. Postoji više načina podjele statističkih podataka, a najvažnija je podjela na kvantitativne i kvalitativne jer određuje mogućnost provođenja računskih operacija. Nakon prikupljanja podataka, oni se grupiraju pa zatim obrađuju i tabelarno i/ili grafički prikazuju. Dobiveni rezultati ocjenjuju se te sastavljaju u obliku izvješća kako bi se uvidjeli potencijalne prednosti, odnosno nedostaci te preporučile izmjene. U ovom radu bavi se prikupljanjem i obradom podataka Studentskog servisa Pula koji koristi informatički program poduzeća Konto d.o.o. Na temelju podataka prikupljenim od studenata i poslodavaca na godišnjoj razini utvrđuje trend rasta, odnosno pada posredovanja Studentskog servisa Pula u poslovanju studenata.

Ključne riječi: statistika, podatak, obrada, Student servis Pula

Summary

Statistics is a science present in every aspect of our lives. By collecting data, processing and evaluating results, it provides us with timely, accurate and reliable information that underlies further action. Depending on the field of activity, descriptive or inferential statistical methods are applied. The chosen method depends on the variable whose data are to be investigated. There are several ways to divide statistics, the most important to divide them into quantitative and qualitative ones as it determines the ability to perform computational operations. After the data being collected, they are grouped, processed and tabulated and / or graphically presented. The results obtained are evaluated and compiled into a report in order to identify potential issues and recommend changes. The present thesis deals with the collection and processing of data collected from the Student Service Pula, which uses the IT program of the company Konto d.o.o. On the basis of data collected from students and employers on an annual basis, it determines the trend of growth or decline of the mediation work of the Student Service Pula in the student business.

Keywords : statistics, data, processing, Student Service Pula