# Statistička analiza podataka o studentima na visokim učilištima RH

**Gregurović, Gloria**

**Undergraduate thesis / Završni rad**

**2019**

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

*Permanent link / Trajna poveznica:* https://urn.nsk.hr/urn:nbn:hr:211:676812

*Rights / Prava:* Attribution-NonCommercial-NoDerivs 3.0 Unported/Imenovanje-Nekomercijalno-Bez prerada 3.0

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

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
VARAŽDIN

*Repository / Repozitorij:*

Faculty of Organization and Informatics - Digital Repository

zir.nsk.hr

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

**SVEUČILIŠTE U ZAGREBU**

**FAKULTET ORGANIZACIJE I INFORMATIKE**

**V A R A Ž D I N**

**Gloria Gregurović**

# STATISTIČKA ANALIZA PODATAKA O STUDENTIMA NA VISOKIM UČILIŠTIMA RH

**ZAVRŠNI RAD**

**Varaždin, 2019.**

**SVEUČILIŠTE U ZAGREBU**

**FAKULTET ORGANIZACIJE I INFORMATIKE**

**V A R A Ž D I N**

**Gloria Gregurović**

**Matični broj: Z-42090/13tzv**

**Studij: Primjena informacijske tehnologije u poslovanju**

# STATISTIČKA ANALIZA PODATAKA O STUDENTIMA NA VISOKIM UČILIŠTIMA RH

**ZAVRŠNI RAD**

**Mentor/Mentorica:**

Izv. Prof. Dr. Sc. Jasminka Dobša

**Varaždin, travanj 2019.**

*Gloria Gregurović*

**Izjava o izvornosti**

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

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

**Sažetak**

U ovom radu su analizirani podaci o broju upisanih studenata na visoka učilišta u Republici Hrvatskoj sa Portala otvorenih podataka Republike Hrvatske. Analizirani su podaci o broju upisanih studenata po vrsti studijskog programa i po tipu visokog učilišta metodama analize vremenskih nizova: trendovima i indeksiranim brojevima. Također su ispitane korelacije broja upisanih studenata po znanstvenim područjima. Rad se sastoji od teorijskog i praktičnog dijela. U teorijskom dijelu rada su objašnjeni pojmovi u statistici kao što su analiza vremenskih nizova, korelacije i uredski statistički alat Excel. U praktičnom dijelu rada je korišten alat Excel u kojem su dobiveni grafovi i tablice. Grafovi i tablice su dobiveni na temelju podataka sa Portala otvorenih podataka Republike Hrvatske kao jedinog izvora podataka za analizu.

**Ključne riječi:** statistika; analiza, podaci; studenti; Excel; trend;

# Sadržaj

1. Uvod ..... 1
2. Statistika ..... 2
2.1. Što je statistika? ..... 2
2.2. Analiza vremenskih nizova ..... 2
2.2.1. Indeksi ..... 3
2.2.1.1. Individualni indeksi ..... 3
2.2.1.2. Skupni indeksi ..... 4
2.2.2. Srednje vrijednosti vremenskih nizova ..... 5
2.2.2.1. Statičke vrijednosti vremenskih nizova ..... 5
2.2.2.2. Dinamičke srednje vrijednosti vremenskih nizova ..... 6
2.3. Korelacija ..... 8
2.3.1. Jednostavna linearna korelacija ..... 8
2.3.2. Jednostavna krivolinijska korelacija ..... 9
2.3.3. Korelacija ranga ..... 9
2.4. Statistički alat Excel ..... 9
3. Primjer statističke analize ..... 10
3.1. Broj studenata po tipu studija ..... 10
3.1.1. Indeksi po tipovima studija ..... 12
3.1.1.1. Verižni indeksi po tipovima studija ..... 12
3.1.1.2. Bazni indeksi po tipovima studija ..... 13
3.1.2. Linearni trend po tipovima studija ..... 14
3.1.2.1. Jednadžba linearnog trenda po tipovima studija ..... 14
3.1.2.2. Prosječna godišnja stopa promjene po tipovima studija ..... 16
3.1.2.2. Prognoza za 2018/19 akademsku godinu po tipovima studija ..... 16
3.1.3. Eksponencijalni trend po tipovima studija ..... 17

3.1.4. Stručni studij ....19
3.1.4.1. Indeksi javnih i privatnih visokih učilišta stručnih studija ....19
3.1.4.2. Trendovi javnih i privatnih visokih učilišta stručnih studija ....20
3.1.5. Sveučilišni studij ....23
3.1.5.1. Indeksi javnih i privatnih visokih učilišta sveučilišnih studija ....24
3.1.5.2. Trendovi javnih i privatnih visokih učilišta sveučilišnih studija ....25
3.2. Broj studenata po vrsti studijskog programa ....27
3.2.1. Vrste studijskih programa stručnih studija ....28
3.2.1.1. Indeksi broja studenata po vrstama studijskih programa stručnih studija ....30
3.2.1.2. Trendovi broja studenata po vrstama studijskih programa stručnih studija ..31
3.2.2. Vrste studijskih programa sveučilišnih studija ....36
3.2.2.1. Indeksi broja studenata po vrstama sveučilišnih studija ....37
3.2.2.2. Trendovi broja studenata po vrstama sveučilišnih studija ....40
3.3. Korelacija broja studenata po poljima i područjima ....46
3.3.1. Korelacija za javna visoka učilišta ....46
3.3.2. Korelacija za privatna visoka učilišta ....48
4. Zaključak ....51
Popis literature ....52
Popis slika ....53
Popis tablica ....55

# 1. Uvod

U ovom radu provedena je analiza podataka o broju upisanih studenata po vrsti studijskog programa i po tipu visokog učilišta. Upotrijebljene metode analize vremenskih nizova su trendovi i indeksirani brojevi. Također, ispitana je korelacija broja upisanih studenata po znanstvenim poljima i područjima. Tema je značajna jer su potrebni budući stručnjaci i znanstvenici na različitim znanstvenim područjima. Autorica ovog rada je motivirana za odabir teme jer je zanima koja su područja zanimljiva drugim studentima i kako se statistički brojevi mogu prognozirati. Drugo poglavlje „Statistika“ je teorijski dio ovog rada. U drugom poglavlju je naglasak na literaturi, pojmu statistike, analizi vremenskih nizova i korelaciji. Treće poglavlje „Primjer statističke analize“ je praktični dio ovog rada. U trećem poglavlju su na praktičnom primjeru prikazani grafovi i tablice koristeći statistički alat Excel na temelju podataka o brojevima studenata na visokim učilištima. U drugom poglavlju je korištena literatura, a u trećem poglavlju je manji naglasak na literaturi te se koriste formule i spoznaje iz drugog poglavlja.

# 2. Statistika

Ovo poglavlje se odnosi na teorijski dio ovog rada tj. opisane su statističke metode. U potpoglavljima su objašnjeni što je statistika, analiza vremenskih nizova, korelacija i statistički alat Excel.

## 2.1. Što je statistika?

Statistika je grana matematike koja služi za istraživanje, opisivanje te analizu i usporedbu masovnih pojava koje se susreću u društvu i prirodi. U statistici se koristi brojčani način opisivanja jer je precizan, kratak i jasan. Zahvaljujući tome, statistika je primjenjiva u gotovo svim područjima znanstvenog i praktičnog istraživanja. Postoje mnoge definicije statistike, npr. *„Statistika je nauka o metodama za istraživanje masovnih pojava pomoću brojčanog izražavanja“* [1]. Postoje dvije vrste statističkih modela. Deskriptivni i inferencijalni statistički modeli. Deskriptivni statistički modeli primjenjuju načine promatranja, grupiranja, tabeliranja, izračunavanja i grafičkog prikazivanja mnogobrojnih i međusobno različitih statističko analitičkih karakteristika ili parametara. Deskriptivna statistika se bavi „uređivanjem prikupljenih, empirijskih podataka, njihovim grafičkim prikazivanjem i opisivanjem pomoću numeričkih vrijednosti“ [2]. Inferencijalni statistički modeli temelje se na uzorcima konačnog ili beskonačnog skupa. Statistički procesi, u inferencijalnim statističkim modelima, ravnaju se po zakonima vjerojatnosti. Inferencijalnim statističkim modelima donose se vjerodostojni sudovi o cijelom skupu, odnosno promatranoj masovnoj pojavi [1]. Kod inferencijalne statistike se donose zaključci o osnovnom skupu temeljem istraživanja na uzorku. Inferencijalna statistika se bavi „metodama koje se zasnivaju na teoriji vjerojatnosti i koje omogućavaju da se donose zaključci o populaciji pomoću uzoraka iz populacije“ [2]. Drugi naziv za inferencijalnu statistiku je induktivna statistika [2]. Sve statističke metode daju zaključke s nekom vjerojatnošću, stoga se statističke metode temelje na teoriji vjerojatnosti [2].

## 2.2. Analiza vremenskih nizova

*„Vremenski niz skup je strogo uređenih vrijednosti varijable koja predočuje određenu pojavu ili neki statistički proces u vremenu“* [3]. Prema istoj literaturi su navedene formule u ovom poglavlju. Statističkom analizom vremenskih nizova obuhvaćamo opisivanje tijeka razvoja masovnih pojava u vremenu, predviđanje i kontrolu dinamičkih procesa te objašnjavanje tijeka masovne pojave pomoći drugih pojava. U statističkoj analizi, pri

promatranju masovnih pojava u vremenu, razlikujemo intervalni od trenutačnog vremenskog niza. U intervalnom nizu promatraju se, odnosno zbrajaju vrijednosti pojave po vremenskim intervalima, te taj niz ima svojstvo kumulativnosti. U trenutačnom vremenskom nizu vrijednosti su kronološki uređene i povezane s odabranim vremenskim točkama, te se prikazuju kao stanja masovne pojave te nemaju svojstvo kumulativnosti [3]. Kumulativnost je sveobuhvatnost zbrojenih vrijednosti.

## 2.2.1.Indeksi

Pod pojmom indeks misli se na relativan broj kojim se prikazuju omjeri različitih stanja jedne pojave ili jedne skupine pojava u različitim vremenima/mjestima. Razlikujemo individualne i skupne indekse. U individualne indekse spadaju verižni indeksi i indeksi stalne baze. Drugi naziv za 'verižni indeks' je 'lančani indeks', a to je indeks s promjenjivom bazom [4], [5]. Individualnim indeksima analizira se jedna pojava. Skupne indekse koristimo ako želimo analizirati skupne pojave. U skupne indekse spadaju indeks vrijednosti, indeks količina i indeks cijena.

### 2.2.1.1. Individualni indeksi

Kao što je spomenuto, u individualne indekse spadaju indeksi s promjenjivom bazom (verižni ili lančani) i indeksi stalne baze. U nastavku su objašnjeni verižni indeksi. Da bismo dobili verižni indeks, potrebno je svako iduće stanje u vremenskom nizu podijeliti s prethodnim stanjem istog vremenskog niza te dobiveni iznos pomnožiti sa 100. Verižnim indeksima prikazuje se smjer kretanja pojave [3]. Ako je verižni indeks veći od 100 znači da pojava raste, a ako je manji od 100 znači da pojava pada u promatranom razdoblju u odnosu na prethodno razdoblje. Ako od verižnog indeksa odbijemo 100, dobijemo individualnu stopu promjene pojave u promatranom razdoblju u odnosu na prethodno razdoblje. Verižni indeksi grafički se prikazuju linijama okrenutim iznad odnosno ispod baze 100. Ako su indeksi veći od 100 linije su okrenute iznad baze, a ako su manji od 100 linije su okrenute ispod baze. Takvim grafičkim prikazom lako je uočiti smjer kretanja pojave. Formula za izračunavanje verižnih indeksa:

$$V_t = 100\frac{y_t}{y_{t-1}}$$

(Izvor: Kero, Dobša i Bojanić-Glavica, 2008)

U formuli na prethodnoj strani, $V_t$ je dobiven verižni indeks u vremenu $t$, $Y_t$ je broj kojeg želimo analizirati u istom vremenu $t$. Formula za izračunavanje individualne stope promjena u uzastopnim razdobljima:

$$s_t = V_t - 100$$

(Izvor: Kero, Dobša i Bojanić-Glavica, 2008)

U formuli iznad, $S_t$ je dobivena stopa promjene u vremenskoj točki *t*, a $V_t$ je verižni indeks u istoj točki *t*. U nastavku su objašnjeni indeksi stalne baze. Indeksi na stalnoj bazi se dobivaju tako da se frekvencije jednog vremenskog niza podijele s jednom frekvencijom nekog razdoblja koja je uzeta za bazu i dobiveni kvocijent se pomnoži sa 100. Indekse na stalnoj bazi čitamo kao postotke, koje dobijemo tako da od svakog promatranog indeksa oduzmemo 100, koji pokazuju za koliko posto se pojava povećala ili smanjila u promatranom razdoblju u odnosu na bazno razdoblje. Grafički prikaz indeksa na stalnoj bazi prikazuje se kao što se prikazuju frekvencije originalnog vremenskog niza, jedina razlika je u tome što je u mjerilu ordinate vidljiva linija 100 što znači da to mjerilo ne počinje od nule. Formula za izračunavanje indeksa na stalnoj bazi:

$$I_t = 100\frac{y_t}{y_b}$$

(Izvor: Kero, Dobša i Bojanić-Glavica, 2008)

U formuli iznad. $I_t$ je dobiven indeks na stalnoj bazi, $Y_t$ je statistički niz kojeg želimo analizirati, a $Y_b$ je vrijednost statističkog niza kojeg želimo analizirati u baznom vremenu. Formula za pripadajuće stope promjena prema baznom razdoblju:

$$s_t = I_t - 100$$

(Izvor: Kero, Dobša i Bojanić-Glavica, 2008)

U formuli iznad, $S_t$ je dobivena stopa promjene, a $I_t$ je indeks na stalnoj bazi. Ponekad, u praktičnim situacijama, postoji potreba da se niz lančanih indeksa preračuna u niz indeksa na stalnoj bazi. To preračunavanje izvodi se tako da se niz lančanih indeksa postupnim množenjem preračunava u indekse na stalnoj bazi prvog razdoblja, ali su u poglavlju 3 korištene formule bez spomenutog preračunavanja.

### 2.2.1.2. Skupni indeksi

Skupnim indeksima analiziraju se skupne pojave. Skupne pojave sastoje se od više individualnih pojava. Pojave se analiziraju posebnom vrstom relativnih brojeva (skupni indeksi). Skupni indeksi veoma su korisni kod izračunavanja indeksa troškova života. Razlikujemo 3 vrste skupnih indeksa, a to su skupni indeks cijena, skupni indeks količina i skupni indeks vrijednosti. Kod analiziranja skupnih pojava najčešće se izračunavaju Laspeyresov indeks količina i cijena, Paascheov indeks količina i cijena i indeks vrijednosti.

Važnost pojedine pojave ili ponder, u skupnoj pojavi, određuje se na različite načine, a najčešće vrijednostima pojava ili njima proporcionalnim veličinama. „Skupni indeksi čitaju se tako da se od svakog indeksa odbije 100 te tako dobivena razlika interpretira kao postotak koji prikazuje za koliko je postotaka vrijednost, količina ili cijena izvještajnog razdoblja veća ili manja od baznog razdoblja.“ [3].

## 2.2.2. Srednje vrijednosti vremenski nizova

Vremenske nizove analiziramo pomoću statističkih modela kojima opisujemo stanje pojave u vremenu. Ti modeli mogu se svrstati na modele pomoću kojih se analiziraju vremenski nizovi čije frekvencije ne variraju sukladno s vremenom, a to su, takozvane, srednje statističke vrijednosti vremenskih nizova (aritmetička sredina – intervalni vremenski niz, kronološka sredina – trenutačni vremenski niz, geometrijska sredina – intervalni i trenutačni vremenski niz) i modeli pomoću kojih se analiziraju vremenski nizovi čije frekvencije variraju sukladno s vremenom, a to je trend koji kao srednja dinamička vrijednost može, po obliku, biti linearan i krivolinijski.

### 2.2.2.1. Statičke vrijednosti vremenskih nizova

Pojave koje nemaju ili ne pokazuju opću razvojnu tendenciju, približno su statističkog karaktera i analiziraju se statističkim srednjim vrijednostima. To su prosječne vrijednosti članova vremenskog niza oko kojih se ti članovi manje ili više gomilaju. U srednje statističke vrijednosti vremenskog niza ubrajaju se aritmetička sredina intervalnog vremenskog niza, kronološka sredina trenutačnog vremenskog niza i geometrijska sredina intervalnog i trenutačnog vremenskog niza. U nastavku su objašnjeni aritmetička sredina (intervalni niz), kronološka sredina (trenutačni niz) i geometrijska sredina (intervalni i trenutačni niz). Aritmetička sredina intervalnog niza izračunava se kao aritmetička sredina članova tog niza. Dobijemo ju tako da zbrojimo sve frekvencije niza te dobivenu sumu podijelimo s brojem frekvencija niza. Formula za aritmetičku sredinu intervalnog vremenskog niza:

$$\bar{y} = \frac{\sum_{i=1}^{k} y_t}{k}$$

(Izvor: Kero, Dobša i Bojanić-Glavica, 2008)

U formuli iznad, $\bar{y}$ je dobivena aritmetička sredina intervalnog vremenskog niza, $k$ je konačna vrijednost sumacije i broj frekvencija niza, $i$ je početna vrijednost sumacije, $y_t$ je broj kojeg želimo analizirati. Grčko slovo ∑ (sigma) označava sumaciju ili zbir brojeva u nizu koji se, ako $i$ počinje od 1, može zapisati i ovako:

$$1 + 2 + 3 + \cdots + k$$

Kronološka sredina je ponderirana srednja vrijednost. To znači da se kod izračunavanja kronološke sredine svaka frekvencija niza mora množiti s vremenskim ponderom odnosno dužinom razdoblja za koje se pretpostavlja da ima frekvenciju na razini koju pokazuje pojava u definiranom trenutku vremena. Kronološkom sredinom se tako izračunava prosječno stanje vremenskog niza u definiranoj jedinici vremena. Formula za kronološku sredinu vremenskog niza:

$$KS = \frac{\sum_{t=1}^{k} y_t v_t}{\sum_{t=1}^{k} v_t}$$

(Izvor: Kero, Dobša i Bojanić-Glavica, 2008)

U formuli iznad, *KS* je dobivena kronološka sredina vremenskog niza, *k* je konačna vrijednost sumacije, *t* je početna vrijednost sumacije, $y_t$ je broj kojeg želimo analizirati, $v_t$ je verižni indeks. Ako unutar vremenskog niza postoji jedan ili više članova pozitivne ekstremne vrijednosti koristi se geometrijska sredina. Geometrijska sredina izračunava se kao k-ti korijen iz produkta članova vremenskog niza. Ubraja se u potpune srednje vrijednosti te na nju utječu svi članovi niza. Kod vremenskih nizova koji se sastoje od ekstremno malih članova ne preporučuje se korištenje geometrijske sredine zbog njezine manje reprezentativnosti. Formula za geometrijsku sredinu vremenskog niza:

$$G = \sqrt[k]{y_1 y_2 \dots y_k}$$

(Izvor: Kero, Dobša i Bojanić-Glavica, 2008)

U formuli iznad, *G* je dobivena geometrijska sredina vremenskog niza, *k* je stupanj korijena i broj članova vremenskog niza, *y* su članovi vremenskog niza od 1 do *k*.

#### 2.2.2.2. Dinamičke srednje vrijednosti vremenskih nizova

Kada promatramo neku pojavu u vremenu ona najčešće pokazuje neku dinamiku, odnosno kretanje. Samim time kako se pojava kreće u vremenu mijenja se i njezina razvojna tendencija po obliku, smjeru i intenzitetu. Razvojna tendencija neke pojave naziva se trend. Trend, na neki način, predstavlja dinamičku srednju vrijednost. Po obliku razlikujemo linearan i krivolinijski trend. Po smjeru kretanja trend može biti pozitivan ili negativan. Što se tiče intenziteta trenda, može biti vrlo različitih gradacija. Intenzitet trenda ovisi o pojavi koju ispitujemo, odnosno analiziramo, statističkim metodama i modelima. Cilj analize neke pojave pomoću tenda je da se otkrije zakonitost razvoja pojave, te da se na temelju toga predvidi danje kretanje i opći razvoj pojave. Zbog toga je veoma bitno da trend bude što bolji reprezentant kretanja pojave. U nastavku su objašnjeni linearni trend eksponencijalni trend i

metoda pomičnih prosjeka. Linearni trend služi kako bismo prikazali pojave koje imaju približno istu apsolutnu promjenu u istim razdobljima. Pod približno istom apsolutnom promjenom, mislimo na približno isti rast ili pad promjene koju analiziramo. Formula linearnog trenda:

$$y = bx + a$$

(Izvor: Kero, Dobša i Bojanić-Glavica, 2008)

U formuli iznad, *y* je zavisna varijabla, x je promatrana vremenska varijabla koja počinje od nule na početku promatranog razdoblja, *a* je očekivana vrijednost, *b* je broj za koliko se analizirani broj (npr. studenata) prosječno povećavao (ili smanjivao ako je *b* negativan). Da bi analitičarima i istraživačima trend bio od značaja, reprezentativnost trenda mora biti značajna. Razina odnosno stupanj reprezentativnosti linearnog trenda mjeri se apsolutnim i relativnim mjerama reprezentativnosti, odnosno disperzije. Apsolutne mjere reprezentativnosti su varijanca i standardna devijacija, a relativna mjera reprezentativnosti je koeficijent varijacije. Trend je reprezentativniji ako su varijanca, standardna devijacija i koeficijent varijacije manji. Eksponencijalni trend se koristi za analiziranje pojava u kojima se članovi vremenskog niza, kojeg promatramo, mijenjaju za neki približno isti relativan iznos. Formula eksponencijalnog trenda:

$$y = ae^{cx}$$

(Izvor: Kero, Dobša i Bojanić-Glavica, 2008)

U formuli iznad, *y* je zavisna varijabla, *x* je vremenska varijabla, *a* je očekivana vrijednost za *y*, *e* je konstanta koja se naziva Eulerovim brojem, Napierovom konstantom ili bazom prirodnog logaritma koja približno iznosi 2,71828183, a *c* je dodatni faktor koji uz *x* daje eksponent konstanti *e*. Kod ispitivanja reprezentativnosti eksponencijalnog trenda koriste se standardna devijacija kao apsolutna mjera reprezentativnosti i koeficijent varijacije kao relativna mjera reprezentativnosti. Isto kao i kod linearnog trenda, što su mjere reprezentativnosti manjih numeričkih vrijednosti, trend je reprezentativniji i obrnuto. Metoda pomičnih prosjeka koristi se za izračunavanje trenda vrijednosti. Ona osigurava jednostavno i brzo dolaženje do veličina trenda. Pomični prosjeci izračunavaju se kao aritmetičke sredine uzastopnih frekvencija. U statističkim analizama razlikujemo jednostavne i vagane pomične prosjeke.

## 2.3. Korelacija

Korelacija je povezanost između različitih pojava koje se predstavljaju kao vrijednosti dviju varijabli. U masovnim pojavama postoje međusobni utjecaji, stoga promjena jedne ili više pojava može rezultirati promjenom neke druge, ovisne, pojave. Kauzalna veza tj. uzročna veza bi bila ona korelacija u kojoj jedna varijabla utječe na drugu pri čemu je jedna varijabla uzrok, a druga varijabla je posljedica. Svaka korelacija nije uzročna veza, ali svaka uzročna veza je korelacija [6]. Korelacijska analiza masovnih pojava služi kako bismo ispitali uzajamnu ovisnost i varijacije među promatranim pojavama. Primjenom korelacijske analize, kod istraživanja masovnih pojava, cilj je definirati veze među pojavama po obliku, smjeru i jakosti. Po obliku razlikujemo linearnu i krivolinijsku korelaciju, po smjeru razlikujemo pozitivnu i negativnu korelaciju i po jakosti razlikujemo funkcionalnu i stohastičku korelaciju. O linearnoj korelaciji govorimo ako promjena jedne pojave povlači za sobom promjenu druge pojave za određeni jednaki iznos, a o krivolinijskoj korelaciji govorimo ako promjena jedne pojave nije praćena promjenom druge pojave za određeni jednaki iznos. Što se tiče smjera korelacije, o pozitivnom smjeru korelacije govorimo ako rast jedne pojave prati rast druge pojave, ili kada pad jedne pojave prati pad druge pojave, a o negativnom smjeru korelacije govorimo ako jedna pojava u svom kretanju raste, a druga pada. Veze među pojavama razlikuju se i po jakosti. Funkcionalne veze među pojavama su jake, takozvane teorijske veze. One postoje u slučajevima kada svakoj vrijednosti jedne pojave korespondira točno određena vrijednost druge pojave. Stohastičke veze su slabije veze među pojavama te se svakodnevno susrećemo u praksi. Postoji i višestruka korelacija. O njoj govorimo ako u analizi veza među pojavama ustanovimo da jedna pojava ovisi o dvije ili više drugih pojava.

### 2.3.1. Jednostavna linearna korelacija

Kao što je spomenuto ranije, o linearnoj korelaciji govorimo ako promjena jedne pojave povlači za sobom promjenu druge pojave za određeni jednaki iznos. Povezanost, odnosno jakost među pojavama mjeri se koeficijentom determinacije i koeficijentom korelacije. Koeficijent determinacije je mjera jakosti među pojavama izražena u drugom stupnju i predstavlja omjer protumačenog kvadrata odstupanja i ukupnom kvadrata odstupanja. Vrijednosti koeficijenta determinacije kreću se u zatvorenom intervalu od 0 do 1. Pearsonov koeficijent korelacije je mjera jakosti linearne veze među pojavama izražena u prvom stupnju. Može zauzeti vrijednosti od -1 do +1. ako je koeficijent korelacije bliži gornjim granicama, pojava je jača. Ako koeficijent korelacije ima vrijednost 0, onda možemo zaključiti da između promatranih pojava nema linearne međuzavisnosti.

### 2.3.2. Jednostavna krivolinijska korelacija

O krivolinijskoj korelaciji govorimo ako promjena jedne pojave nije praćena promjenom druge pojave za određeni jednaki iznos. Jakost veze među tim pojavama mjeri se koeficijentom krivolinijske korelacije, kojega se još naziva i indeksom korelacije, i koeficijentom determinacije. Izračunati koeficijenti krivolinijske korelacije nemaju svojstvo simetričnosti. Ako koeficijente krivolinijske determinacije pomnožimo sa 100, oni prikazuju postotak protumačenog odstupanja u korelacijskom modelu.

### 2.3.3. Korelacija ranga

*"Mjerenje stupnja statističke veze između pojava danih u obliku modaliteta redoslijedne (rang) varijable izvodi se na više različitih načina. Najpoznatiji je Spearmanov koeficijent korelacije ranga za analizu veze između dvije varijable ranga."* [3]. Vrijednosti *Spearmanovog koeficijenta korelacije ranga* mogu biti u intervalu od -1 do +1. Ako se radi o vrlo značajnoj statističkoj vezi između rangova promatranih pojava, koeficijent poprima graničnu vrijednost u slučaju preklapanja rangova proučavanih promjena. Ako je koeficijent korelacije ranga jednak 0, to znači da između rangova promatranih pojava nema statističke veze.

## 2.4. Statistički alat Excel

Microsoft Excel je uredski alat koji je u ovom radu korišten kao statistički alat za potrebe trećeg poglavlja, razvijen od strane Microsofta, koji služi za proračunske tablice i analizu podataka. Excel je dio aplikacijskog paketa Microsoft Office. Excel se može koristiti na brojne načine. Samo neki od njih su korištenje formule za automatsko popunjavanje ćelija na temelju podataka iz drugih ćelija i možemo podatke iz tablica prikazati u grafikone za grafički prikaz. Excel datoteku korisnici poznaju kao radnu knjigu koja se sastoji od više radnih listova (eng. worksheet). Svaki radni list sastoji se od mnogo redaka i stupaca.

# 3. Primjer statističke analize

U ovom poglavlju prikazana je analiza podataka o broju upisanih studenata po vrsti studijskog programa i po tipu visokog učilišta. Upotrijebljene su spoznaje iz drugog poglavlja kao što su trendovi i indeksirani brojevi kao korištene metode analize vremenskih nizova te je ispitana korelacija broja upisanih studenata po znanstvenim poljima i područjima. Podaci su analizirani korištenjem ranije spomenutog uredskog alata Microsoft Excel kao statističkog alata. Podaci su preuzeti iz Portala otvorenih podataka Republike Hrvatske (https://data.gov.hr/dataset/broj-studenata) [7].

## 3.1. Broj studenata po tipu studija

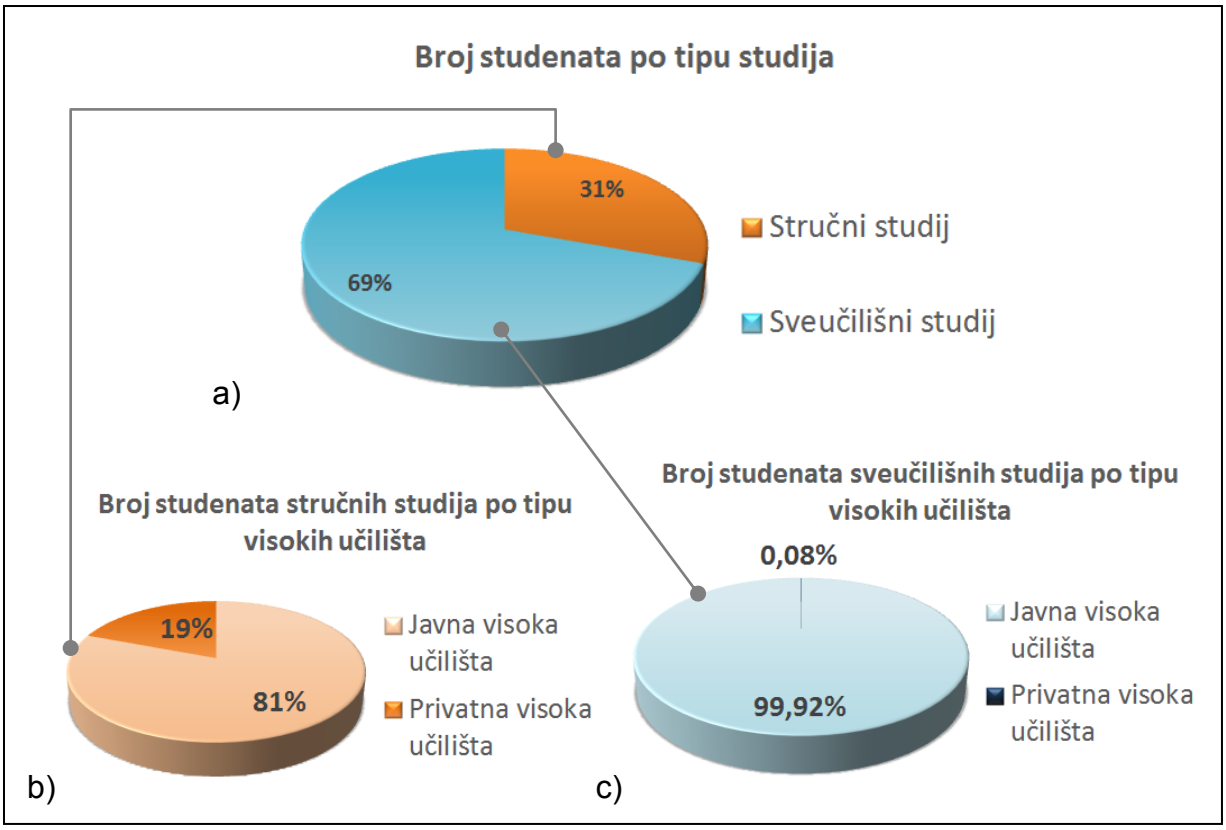
Tipovi studija mogu biti stručni studij i sveučilišni studij, a visoka učilišta mogu biti javna i privatna. Na sljedećoj tablici je stručni studij podijeljen na javna i privatna učilišta, a sveučilišni studij je također podijeljen na javna i privatna visoka učilišta.

Tablica 1: Broj upisanih studenata po akademskim godinama i tipu studija

| **Tip studija** | **2008/09** | **2009/10** | **2010/11** | **2011/12** | **2012/13** | **2013/14** |
|---|---|---|---|---|---|---|
| **X** | **0** | **1** | **2** | **3** | **4** | **5** |
| **Stručni studij** | **56.831** | **58.249** | **62.517** | **63.240** | **59.624** | **55.050** |
| Javna visoka učilišta | 45.907 | 46.298 | 47.672 | 48.170 | 45.317 | 39.065 |
| Privatna visoka učilišta | 10.924 | 11.951 | 14.845 | 15.070 | 14.307 | 15.985 |
| **Sveučilišni studij** | **128.767** | **127.058** | **131.534** | **134.178** | **128.661** | **123.626** |
| Javna visoka učilišta | 128.669 | 126.929 | 131.371 | 133.984 | 128.274 | 122.882 |
| Privatna visoka učilišta | 98 | 129 | 163 | 194 | 387 | 744 |
| **Ukupno studenata:** | **185.598** | **185.307** | **194.051** | **197.418** | **188.285** | **178.676** |

(Izvor: Portal otvorenih podataka Republike Hrvatske, 2019)

„X“ je varijabla koja označava promatrane vremenske točke s ishodištem 0 (nula) na početku promatranog razdoblja potom se točke postupno povećavaju za 1. U tablici iznad, svaka vremenska točka označava jednu akademsku godinu. Vremenska točka služi kao najmanja vremenska jedinica (ne postoje polugodišnji podaci). U daljnjoj analizi u ovom radu, jedinica za *x* je jedna godina, a jedinica za *y* je jedan student. Temeljem podataka iz tablice iznad, izvedeni su grafovi koji brojeve studenata prikazuju slikovito i u postocima na sljedećoj strani.




Slika 1: Podjela studenata po tipu studija a) Ukupan broj studenata b) Studenata na sveučilišnim studijima c) Studenata na stručnim studijima

Na slici iznad su prikazana tri grafa koja se temelje na podacima iz tablice na prethodnoj strani. Iz grafa a) možemo iščitati da je 69% od ukupnog broja studenata u Hrvatskoj u razdoblju od 2008. do 2014. godine upisano na sveučilišne studije, a 31% njih je upisano na stručne studije. Zaključujemo da je preko dvije trećine studenata upisano na sveučilišnim studijima dok je gotovo trećina studenata na stručnim studijima. U grafu b) se radi o studentima koji su bili upisani na stručne studije. Stručni studiji se dijele na javna i privatna visoka učilišta. Iz ovog grafa vidimo da se u razdoblju od 2008. do 2014. godine više studenata (81%) upisalo na javna visoka učilišta, a manje (19%) na privatna visoka učilišta. U grafu c) se radi o studentima koji su upisali sveučilišne studije. Sveučilišni studiji se, također, dijele na javna i privatna visoka učilišta. Ovaj graf pokazuje da se većina studenata, njih čak 99,92% u razdoblju od 2008. do 2014. godine upisalo na javna visoka učilišta, a samo 0,08% na privatna visoka učilišta. Zaključujemo da graf b) prikazuje da je od ukupnog broja studenata (uključujući na stručnim i sveučilišnim studijima) približno 19% bilo upisano na javna visoka učilišta, a 81% na privatna visoka učilišta u istom razdoblju, budući da je postotak na grafu c) zanemariv.

## 3.1.1.Indeksi po tipovima studija

U ovom poglavlju su po tipovima studija izračunati verižni indeksi i prosječna godišnja stopa promjene te bazni indeksi.

### 3.1.1.1. Verižni indeksi po tipovima studija

Na sljedećoj tablici prikazani su podaci o tipu studija (preuzeti iz tablice u poglavlju 3.1) s izračunatim verižnim indeksima i pripadajućim stopama promjene.

Tablica 2: Verižni indeksi po tipu studija

| Tip studija | 2008/09 | 2009/10 | 2010/11 | 2011/12 | 2012/13 | 2013/14 |
|---|---|---|---|---|---|---|
| **Stručni studij** Yt | **56.831** | **58.249** | **62.517** | **63.240** | **59.624** | **55.050** |
| **Sveučilišni studij** Yt | **128.767** | **127.058** | **131.534** | **134.178** | **128.661** | **123.626** |
| Vt – stručni studij | - | 102,50 | 107,33 | 101,16 | 94,28 | 92,33 |
| St – stručni studij | - | 2,50 | 7,33 | 1,16 | -5,72 | -7,67 |
| Vt – sveučilišni studij | - | 98,67 | 103,52 | 102,01 | 95,89 | 96,09 |
| St – sveučilišni studij | - | -1,33 | 3,52 | 2,01 | -4,11 | -3,91 |

Ovi indeksi nam pokazuju da je od 2008. do 2011. godine rastao broj studenata koji su se upisali na stručne studije, no 2012. i 2013. godine taj broj je počeo padati. Za sveučilišne studije, broj upisanih studenata 2009. godine pao je za 1,33% u odnosu na 2008. godinu, no počeo je rasti 2010. i 2011. godine. 2012. i 2013. godine broj studenata upisanih na sveučilišni studij opet pada. Korištena je sljedeća formula za izračun verižnih indeksa.

$$Vt = \frac{Y_t}{Y_{t-1}} 100$$

U formuli iznad, *Vt* je dobiven verižni indeks u odabranoj ak. godini, $Y_t$ je broj upisanih studenata u istoj ak. godini i $Y_{t-1}$ je broj upisanih studenata u prethodnoj ak. godini. Korištena je sljedeća formula za izračun stopa promjene.

$$St = Vt - 100$$

U formuli iznad je *St* dobivena stopa promjene u odabranoj ak. godini, a *Vt* je verižni indeks u istoj ak. godini. Pomoću formule navedene u nastavku za prosječnu stopu promjene dobivene su sljedeće prosječne godišnje stope. U promatranom razdoblju od 2008. do 2013. godine broj upisanih studenata na stručni studij se prosječno godišnje smanjivao za **0,63%**. U istom promatranom razdoblju, broj upisanih studenata na sveučilišni studij se prosječno godišnje smanjivao za **0,81%**. Korištena je sljedeća formula za prosječnu stopu promjene.

$$Prosječna\ stopa\ promjene = geomean(V_t, V_{t+1} \dots V_{t+n}) - 100$$

U formuli iznad je korištena je funkcija 'geomean' u uredskom alatu Excel. Naziv funkcije 'geomean' je skraćen od engleskih riječi 'geometric mean' što znači 'geometrijska sredina'. Funkcija 'geomean' je u navedenoj formuli primila neke verižne indekse i izračunala je geometrijsku sredinu temeljem primljenih brojeva (funkcija '*nezna*' da su to verižni indeksi, mogu biti neki drugi brojevi). Do dobivenih stopa došlo se tako što su funkciji 'geomean' predani svi verižni indeksi za promatrano razdoblje za svaki tip studija što je izračunato na prethodnoj strani.

### 3.1.1.2. Bazni indeksi po tipovima studija

Na sljedećoj tablici prikazani su podaci o tipu studija (preuzeti iz tablice u poglavlju 3.1) s izračunatim baznim indeksima i pripadajućim stopama promjene.

Tablica 3: Bazni indeksi po tipu studija

| **Tip studija** | **2008/09** | **2009/10** | **2010/11** | **2011/12** | **2012/13** | **2013/14** |
|---|---|---|---|---|---|---|
| **x** | **0** | **1** | **2** | **3** | **4** | **5** |
| **Stručni studij** Yt | **56.831** | **58.249** | **62.517** | **63.240** | **59.624** | **55.050** |
| **Sveučilišni studij** Yt | **128.767** | **127.058** | **131.534** | **134.178** | **128.661** | **123.626** |
| **It – stručni studij** | 100 | 102 | 110 | 111 | 105 | 97 |
| **St – stručni studij** | 0 | 2,50 | 10,01 | 11,28 | 4,91 | -3,13 |
| **It – sveučilišni studij** | 100 | 98,67 | 102,15 | 104,20 | 99,92 | 96,01 |
| **St – sveučilišni studij** | 0 | -1,33 | 2,15 | 4,20 | -0,08 | -3,99 |

Indeksi za stručni studij nam pokazuju da je od 2009. do 2012. godine bilo više studenata koji su upisali stručne studije u odnosu na baznu 2008. godinu, no 2013. godine taj broj pada. Indeksi za sveučilišni studij nam pokazuju da 2009., 2012. i 2013. godine ima manje upisanih studenata u odnosu na baznu 2008. godinu, dok 2010. i 2011. godine je taj broj veći. Akademsku godinu 2008/09 smo proglasili baznom. Korištena je sljedeća formula za izračun baznih indeksa.

$$It = \frac{Yt}{Yb} 100$$

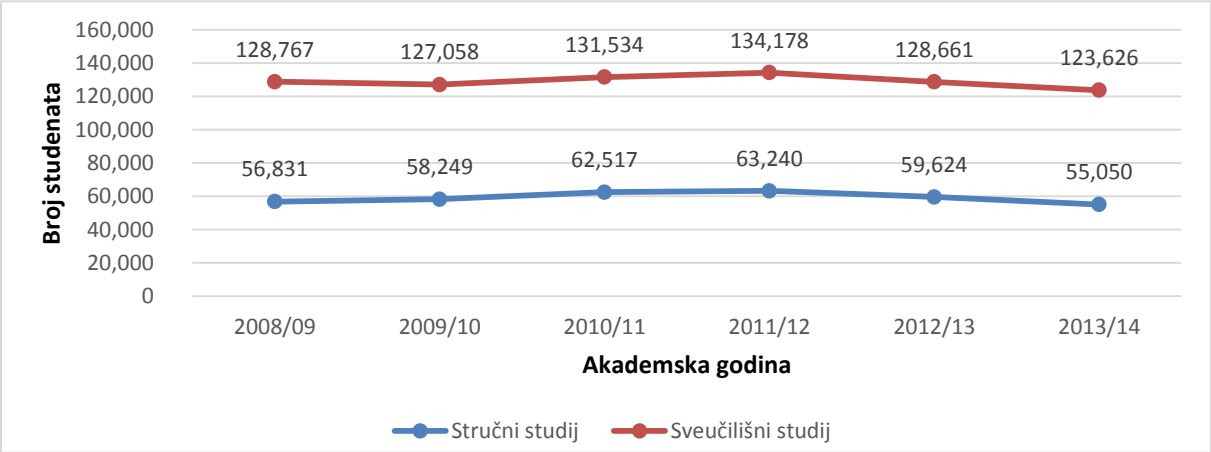
U formuli iznad, *It* je dobiven bazni indeks, *Yt* je broj studenata u određenoj ak. godini, a *Yb* je broj studenata u baznoj ak. godini. Korištena je sljedeća formula za izračun stopa promjene.

$$St = It - 100$$

U prethodnoj formuli, *St* je dobivena stopa promjene, a *It* je bazni indeks.

## 3.1.2.Linearni trend

U ovom poglavlju analiziran je linearni trend broja studenata po tipu studija.

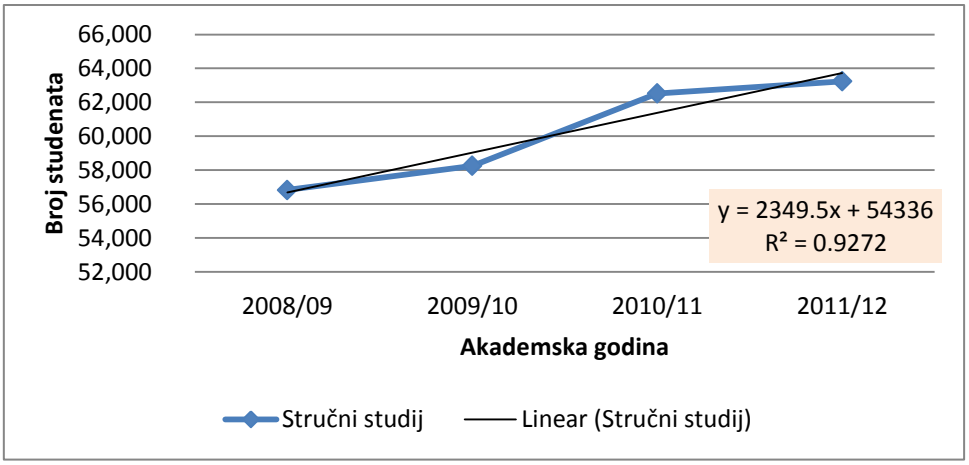



Slika 2: Broj studenata po tipu studija

Na slici iznad, prikazan je linijski grafikon broja studenata po tipu studija od ak. godine 2008/09 do ak. godine 2013/14 na temelju podataka iz tablice u poglavlju 3.1.

### 3.1.2.1. Jednadžba linearnog trenda po tipovima studija

Radi bolje reprezentativnosti, u cijelom 3. poglavlju i potpoglavljima istog, provedena je analiza s pretpostavkom da se nastavio trend kakav je bio do nekoliko godina ranije od 2014. iako su na raspolaganju podaci do 2014. godine. Bolja reprezentativnost se postiže s više podataka, međutim, nemamo podataka nakon 2014. godine. Rastući trend bio je od 2008. do 2011. godine, a padajući trend bio je od 2011. do 2014. godine. Jednako vrijedi za stručne i za sveučilišne studije. Kada bismo gledali cijelo promatrano razdoblje od 2008. do 2014. dobili smo slabu reprezentativnost jer gotovo nema rasta ni pada trenda nego dobivamo uglavnom ravne linije. Na sljedećoj strani su prikazani samo rastući trendovi jer imaju ishodište na početku promatranog razdoblja. Za početak promatranog razdoblja odabrana je akademska godina 2008/09.

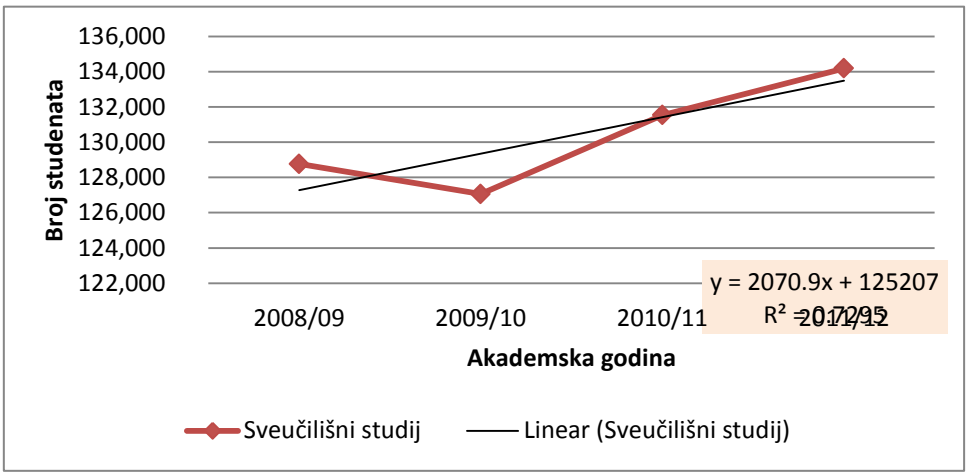



Slika 3: Trend broja studenata stručnih studija od 2008. do 2012. godine

Na slici iznad prikazan je rastući trend broja studenata stručnih studija. Dobiven je koeficijent determinacije 0,92 što znači da je 92% promjena broja upisanih studenata na stručni studij objašnjeno prikazanim linearnim trend modelom. Dobivena je sljedeća jednadžba linearnog trenda.

$$y = 2349{,}5x + 54336$$

Jednadžba iznad znači sljedeće. Očekivana vrijednost za broj upisanih studenata na stručni studij 2008/09 ak. godine je 54336 studenata. U promatranom razdoblju broj upisanih studenata na stručni studij se prosječno godišnje povećavao za 2349,5 studenata.




Slika 4: Trend broja studenata sveučilišnih studija od 2008. do 2012. godine

Na slici iznad prikazan je rastući trend broja studenata sveučilišnih studija. Dobiven je koeficijent determinacije 0,72 što znači da je 72% promjena broja upisanih studenata na sveučilišni studij objašnjeno prikazanim linearnim trend modelom. Dobivena je sljedeća jednadžba linearnog trenda na sljedećoj strani.

$$y = 2070{,}9x + 125207$$

Jednadžba iznad znači sljedeće. Očekivana vrijednost za broj upisanih studenata na sveučilišni studij 2008/09 ak. godine je 125207 studenata. U promatranom razdoblju broj upisanih studenata na sveučilišni studij se prosječno godišnje povećavao za 2070,9 studenata. U jednadžbama linearnog trenda, jedinica za *y* je 1 student, a jedinica za *x* je jedna akademska godina.

### 3.1.2.2. Prosječna godišnja stopa promjene po tipovima studija

Prosječna godišnja stopa promjene broja studenata po tipovima studija je izračunata pod verižnim indeksima po tipovima studija u poglavlju 3.1.1.1 za promatrano razdoblje od 2008/09 do 2013/14 ak. godine. No, ovdje su izračunate prosječne godišnje stope za analizirano razdoblje u prethodnom poglavlju, stoga je promatrano razdoblje u ovom poglavlju od 2008/09 do 2011/12 ak. godine. Koristeći se istom formulom iz poglavlja 3.1.1.1 za prosječnu stopu promjene, dobiveni su sljedeći zaključci. U promatranom razdoblju, broj upisanih studenata na stručni studij se prosječno godišnje povećavao za 3,63%. U promatranom razdoblju, broj upisanih studenata na sveučilišni studij se prosječno godišnje povećavao za 1,38%.

### 3.1.2.3. Prognoza za 2018/19 akademsku godinu po tipovima studija

Ako se broj upisanih studenata nastavi po izračunatom trendu u poglavlju 3.1.2.1, slijedi izračun koliko se studenata može očekivati 2018/19 ak. godine. Koristeći se dobivenim jednadžbama iz istog poglavlja, uvrstili smo za *x* vrijednost 10 jer 10 predstavlja 2018/19 ak. godinu te smo dobili sljedeće zaključke. Promatrani linearni trend u ovom poglavlju je u razdoblju od 2008/09 do 2011/12 ak. godine. Prema linearnom trendu, ak. godine 2018/19 možemo očekivati 77831 studenata upisanih na stručni studij. Prema linearnom trendu, ak. godine 2018/19 možemo očekivati 145916 studenata upisanih na sveučilišni studij. Sljedi prognoziranje na temelju istih linearnih trendova za oba tipa studija.

Tablica 4: Prognoziranje broja studenata na temelju linearnog trenda po tipu studija

| Tip studija | 2012/13 | 2013/14 | 2014/15 | 2015/16 | 2016/17 | 2017/18 | 2018/19 |
|---|---|---|---|---|---|---|---|
| x | 4 | 5 | 6 | 7 | 8 | 9 | 10 |
| Stručni | 66.083 | 68.433 | 70.782 | 73.132 | 75.481 | 77.831 | 80.180 |
| Sveučilišni | 135.562 | 137.632 | 139.703 | 141.774 | 143.845 | 145.916 | 147.987 |

Sljedeća tablica na sljedećoj strani nam služi radi usporedbe prognoziranih podataka iz tablice iznad i stvarnih podataka iz tablice u poglavlju 3.1 za ak. godinu 2012/13 i ak. godinu 2013/14.

Tablica 5: Usporedba stvarnog i prognoziranog broja studenata po tipu studija

| | Stvarni podaci | | Prognozirani podaci | |
|---|---|---|---|---|
| **Tip studija** | **2012/13** | **2013/14** | **2012/13** | **2013/14** |
| **Stručni studij** | **56.831** | **58.249** | **66.083** | **68.433** |
| **Sveučilišni studij** | **128.767** | **127.058** | **135.562** | **137.632** |

Na temelju tablice iznad, možemo zaključiti da je prognoziranje bilo uglavnom točno i prognozirani broj studenata bi se ostvario da se nastavio ranije prikazan trend, međutim, isti trend je počeo padati ranije od očekivanog. Prognoziranje radimo pomoću funkcije 'trend' u uredskom alatu Excel. Primjer upotrijebljene funkcije 'trend':

```
=TREND(C87:H87;C85:H85;I85:M85)
```

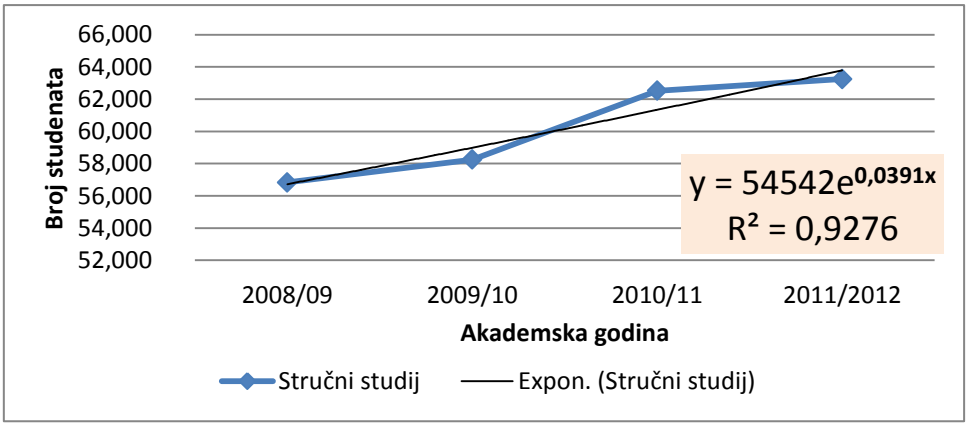
Općenito funkcija 'trend' izgleda ovako:

```
=TREND([poznati ipsiloni];[poznati iksevi];[novi iksevi])
```

Funkcija 'trend' ima tri parametra. Prvi parametar je raspon ćelija poznatih podataka tj. *y*, drugi parametar je raspon ćelija varijable *x* za poznate podatke, a treći parametar je raspon ćelija varijabe *x* za dobivene prognozirane podatke.

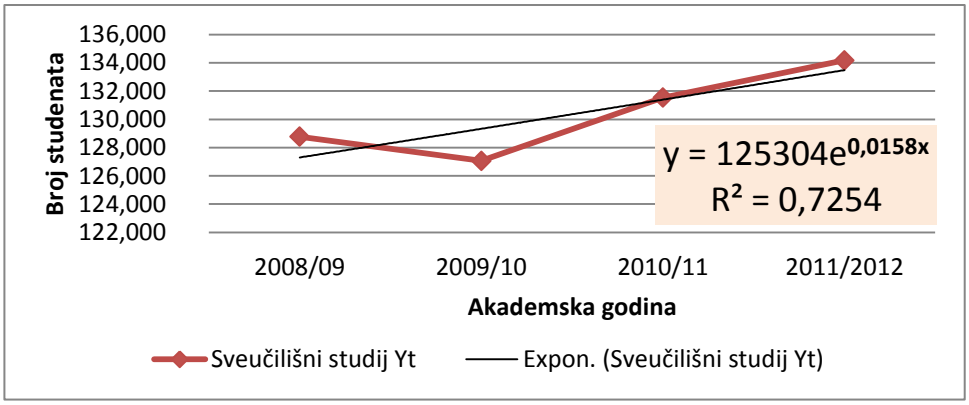
### 3.1.3. Eksponencijalni trend po tipovima studija

Sljedeća slika prikazuje sličan graf i jednake reprezentativnosti kao kod linearnog trenda za broj studenata stručnih studija, ali ovdje je dobivena jednadžba eksponencijalnog trenda.




Slika 5: Trend studenata stručnih studija s eksponencijalnom jednadžbom

Sljedeća slika na sljedećoj strani prikazuje podatke analogno prethodnom grafu za broj studenata sveučilišnih studija.




Slika 6: Trend studenata sveučilišnih studija s eksponencijalnom jednadžbom

Eksponencionalna jednadžba objašnjena je sljedećim formulama.

$$y = ae^{cx}$$

$$y = ab^{x}$$

$$b = e^{c}$$

U navedenim formulama iznad, *y* je broj studenata, *x* je vremenska jedinica, *a* je očekivana vrijednost za *y* koja u ishodišnoj godini iznosi *a*, *b* služi za dobivanje postotka *s* obrazloženog niže, *c* nam služi da bismo izračunali *b*, *e* je konstanta koja približno iznosi 2,71828183 i naziva se Eulerov broj ili Napierova konstanta ili baza prirodnog logaritma. U uredskom alatu Excel, konstantu *e* na neku potenciju računamo pomoću funkcije 'exp'. Sljedeća formula služi za dobivanje postotka *s* koji pokazuje koliko se broj studenata prosječno godišnje povećavao ili smanjivao.

$$s = (b - 1)100$$

$$s = (e^{c} - 1)100$$

Izračunima su dobiveni sljedeći zaključci. Očekivana vrijednost za broj upisanih studenata na stručni studij 2008/09 ak. godine je **54542**. U promatranom razdoblju broj upisanih studenata na stručni studij se prosječno godišnje povećavao za **3,98%**. Očekivana vrijednost za broj upisanih studenata na sveučilišni studij 2008/09 ak. godine je **125304**. U promatranom razdoblju broj upisanih studenata na sveučilišni studij se prosječno godišnje povećavao za **1,59%**. Prema eksponencijalnom trendu ak. godine 2018/19 (*x* je 10) možemo očekivati **80638** studenata upisanih na stručni studij. Prema eksponencijalnom trendu ak. godine 2018/19 možemo očekivati **146751** studenata upisanih na sveučilišni studij. Sljedeća tablica na sljedećoj strani prikazuje prognoziranje studenata na temelju eksponencijalnog trenda po tipu studija koristeći funkciju 'growth' u uredskom alatu Excel.

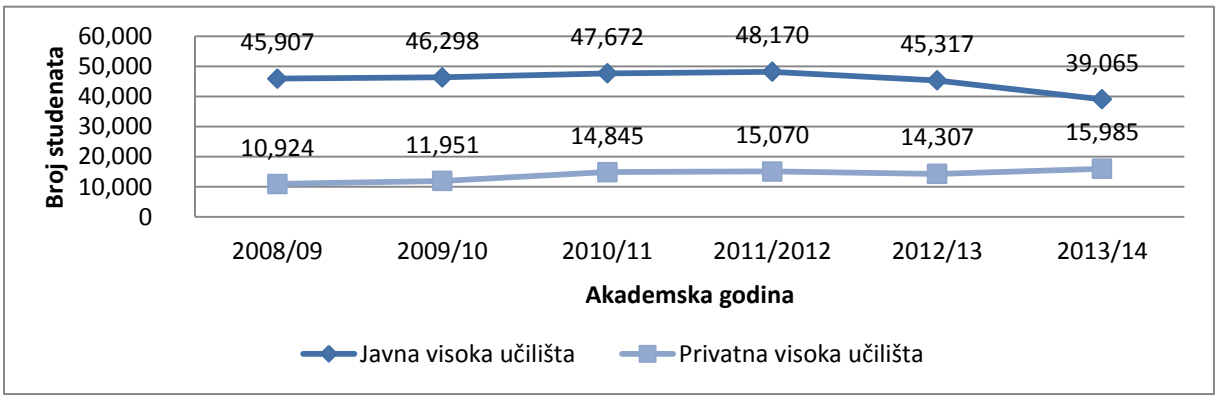
Tablica 6: Prognoziranje studenata na temelju eksponencijalnog trenda po tipu studija

| Tip studija | 2012/13 | 2013/14 | 2014/15 | 2015/16 | 2016/17 | 2017/18 | 2018/19 |
|---|---|---|---|---|---|---|---|
| x | 4 | 5 | 6 | 7 | 8 | 9 | 10 |
| Stručni | 66.328 | 68.975 | 71.727 | 74.589 | 77.566 | 80.661 | 83.880 |
| Sveučilišni | 135.612 | 137.773 | 139.969 | 142.199 | 144.466 | 146.768 | 149.107 |

Funkcija 'growth' se koristi za prognoziranje eksponencijalnog trenda na isti način kao što se funkcija 'trend' koristi za prognoziranje linearnog trenda.

## 3.1.4.Stručni studij

U ovom poglavlju analizirani su brojevi studenata stručnih studija i koliko je njih bilo upisano na javna, a koliko na privatna visoka učilišta.




Slika 7: Broj studenata na stručnom studiju po tipu visokih učilišta

Na slici iznad je prikazan linijski grafikon koji prikazuje broj studenata stručnih studija po tipu visokih učilišta.

### 3.1.4.1. Indeksi javnih i privatnih visokih učilišta stručnih studija

Sljedeća tablica na sljedećoj strani prikazuje verižne indekse i stope promjene za javna i privatna visoka učilišta na stručnim studijima. Indeksi na istoj tablici nam pokazuju da je od 2008. do 2011. godine rastao broj studenata stručnih studija koji su se upisali na javna visoka učilišta, no 2012. i 2013. godine taj broj je počeo padati. Za studente stručnih studija koji su upisali privatna visoka učilišta, broj upisanih studenata raste od 2008. do 2011., godine, no 2012. godine broj upisanih studenata pada za 5,06%, ali već sljedeće godine broj upisanih studenata opet raste i to za 11,73%.

Tablica 7: Verižni indeksi studenata na stručnom studiju po visokim učilištima

| Visoka učilišta na stručnom studiju | 2008/09 | 2009/10 | 2010/11 | 2011/12 | 2012/13 | 2013/14 |
|---|---|---|---|---|---|---|
| Javna Yt | 45907 | 46298 | 47672 | 48170 | 45317 | 39065 |
| Privatna Yt | 10924 | 11951 | 14845 | 15070 | 14307 | 15985 |
| Vt - javna | - | 100,85 | 102,97 | 101,04 | 94,08 | 86,20 |
| St - jvu | - | 0,85 | 2,97 | 1,04 | -5,92 | -13,80 |
| Vt- privatna | - | 109,40 | 124,22 | 101,52 | 94,94 | 111,73 |
| St - pvu | - | 9,40 | 24,22 | 1,52 | -5,06 | 11,73 |

U promatranom razdoblju od 2008. do 2013. godine broj upisanih studenata na stručni studij javnih visokih učilišta se prosječno godišnje smanjivao za 3,18%. U promatranom razdoblju od 2008. do 2013. godine broj upisanih studenata na stručni studij privatnih visokih učilišta studij se prosječno godišnje povećavao za 7,91%. Sljedeća tablica prikazuje bazne indekse za iste podatke kao prethodna tablica.

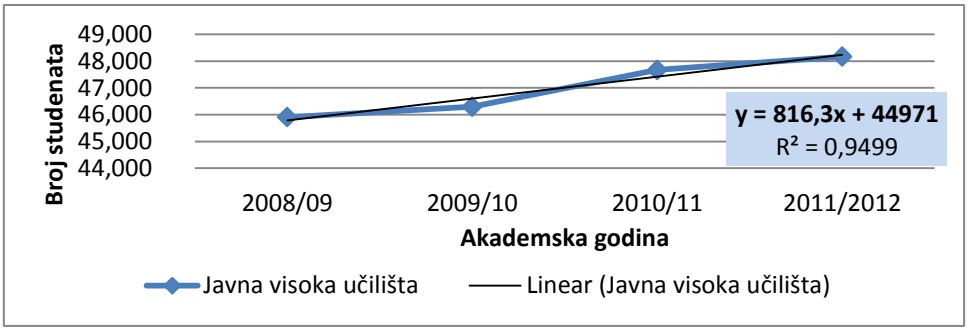
Tablica 8: Bazni indeksi studenata na stručnom studiju po visokim učilištima

| Visoka učilišta na stručnom studiju | 2008/09 | 2009/10 | 2010/11 | 2011/12 | 2012/13 | 2013/14 |
|---|---|---|---|---|---|---|
| Javna Yt | 45907 | 46298 | 47672 | 48170 | 45317 | 39065 |
| Privatna Yt | 10924 | 11951 | 14845 | 15070 | 14307 | 15985 |
| It - javna | 100 | 101 | 104 | 105 | 99 | 85 |
| St - jvu | 0 | 0,85 | 3,84 | 4,93 | -1,29 | -14,90 |
| It- privatna | 100 | 109,40 | 135,89 | 137,95 | 130,97 | 146,33 |
| St - pvu | 0 | 9,40 | 35,89 | 37,95 | 30,97 | 46,33 |

Indeksi za javna visoka učilišta stručnog studija na tablici iznad nam pokazuju da je od 2009. do 2011. godine bilo više studenata koji su upisali javna visoka učilišta u odnosu na baznu 2008. godinu, no 2012. i 2013. godine taj broj pada. Indeksi za privatna visoka učilišta stručnog studija na istoj tablici nam pokazuju da je od 2009. do 2013. godine bilo više studenata koji su upisivali privatna visoka učilišta u odnosu na baznu 2008. godinu.

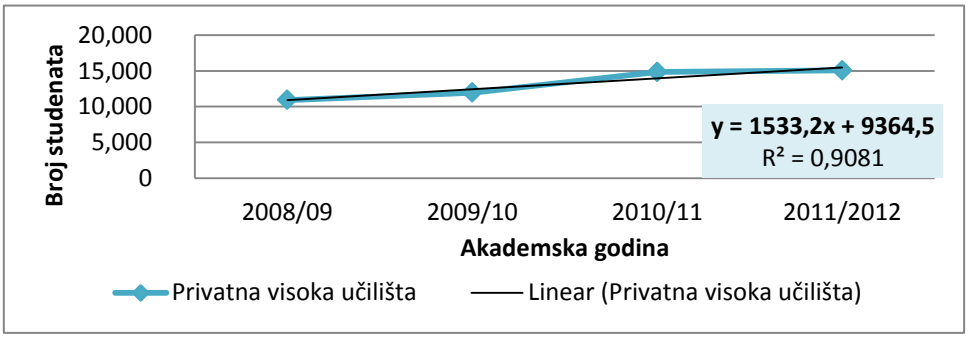
### 3.1.4.2. Trendovi javnih i privatnih visokih učilišta stručnih studija

Sljedeća slika na sljedećoj strani prikazuje linearni trend za javna učilišta na stručnim studijima.




Slika 8: Linearni trend studenata na javnim učilištima stručnih studija

Koeficijent determinacije na grafu na slici iznad je 0,95 što znači da je 95% promjena broja upisanih studenata na stručni studij na javna visoka učilišta objašnjeno prikazanim linearnim trend modelom. Očekivana vrijednost za broj upisanih studenata na stručni studij na javna visoka učilišta 2008/09. godine je **44971**. U promatranom razdoblju broj upisanih studenata na stručni studij na javna visoka učilišta se prosječno godišnje povećavao za **816,3**. U promatranom razdoblju broj upisanih studenata stručnog studija na javna visoka učilišta se prosječno godišnje povećavao za **1,62%**. Sljedeća slika prikazuje linearni trend za privatna učilišta na stručnim studijima.



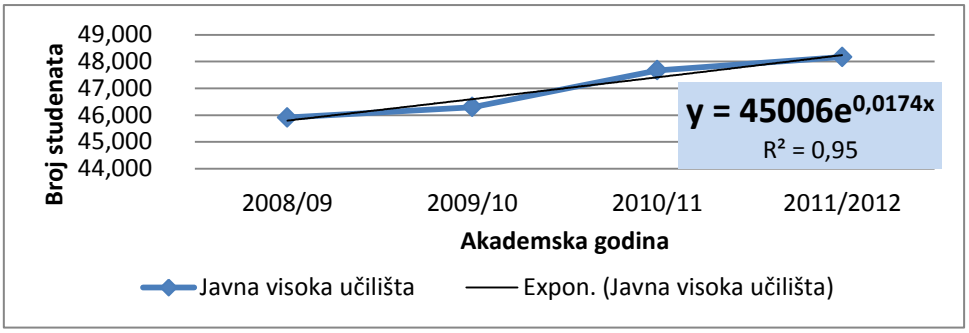

Slika 9: Linearni trend studenata na privatnim učilištima stručnih studija

Koeficijent determinacije na grafu na slici iznad je 0,91 što znači da je 91% promjena broja upisanih studenata na stručni studij na privatna visoka učilišta objašnjeno prikazanim linearnim trend modelom. Očekivana vrijednost za broj upisanih studenata na stručni studij na javna visoka učilišta 2008/09. godine je **9364,5**. U promatranom razdoblju broj upisanih studenata na stručni studij na javna visoka učilišta se prosječno godišnje povećavao za **1533,2**. U promatranom razdoblju broj upisanih studenata stručnog studija na privatna visoka učilišta se prosječno godišnje povećavao za **11,32%**. Prema linearnom trendu 2018/19. ak. godine (*x* je 10) možemo očekivati **53134** studenata stručnog studija upisanih na javna visoka učilišta. Prema linearnom trendu 2018/19 ak. godine možemo očekivati **24696** studenata stručnog studija upisanih na privatna visoka učilišta.

Tablica 9: Prognoziranje studenata na stručnim studijima na temelju linearnog trenda

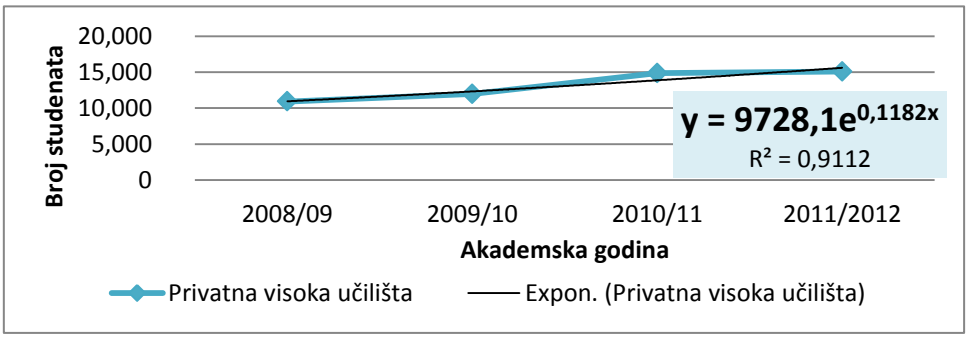
| Učilišta | 2012/13 | 2013/14 | 2014/15 | 2015/16 | 2016/17 | 2017/18 | 2018/19 |
|---|---|---|---|---|---|---|---|
| Javna | 49.053 | 49.869 | 50685 | 51501 | 52318 | 53134 | 53950 |
| Privatna | 17.031 | 18.564 | 20097 | 21630 | 23163 | 24697 | 26230 |

Tablica iznad prikazuje prognoziranje broja studenata na javnim i privatnim visokim učilištima na stručnim studijima na temelju linearnog trenda.




Slika 10: Eksponencijalni trend studenata na javnim učilištima stručnih studija

Reprezentativnost na slici iznad je 95%. Očekivana vrijednost za broj upisanih studenata na stručni studij na javna visoka učilišta 2008/09. godine je **45006**. U promatranom razdoblju broj upisanih studenata na stručni studij na javna visoka učilišta se prosječno godišnje povećavao za **1,75%**. Prema eksponencijalnom trendu ak. godine 2018/19 (*x* je 10) možemo očekivati **53560** studenata stručnog studija upisanih na javna visoka učilišta.




Slika 11: Eksponencijalni trend studenata na privatnim učilištima stručnih studija

Reprezentativnost na slici iznad je 91%. Očekivana vrijednost za broj upisanih studenata na stručni studij na javna visoka učilišta 2008/09. godine je **9728,1**. U promatranom razdoblju broj upisanih studenata na stručni studij na javna visoka učilišta se prosječno godišnje povećavao za **12,55%**. Prema eksponencijalnom trendu ak. godine 2018/19 možemo očekivati **31722** studenata stručnog studija upisanih na privatna visoka učilišta.

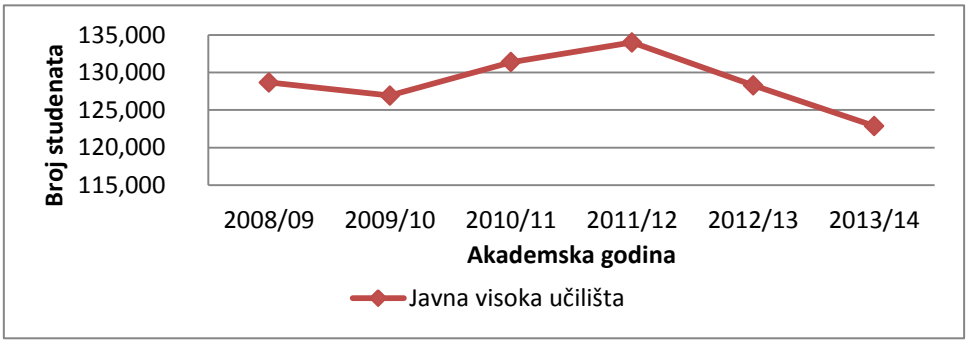
Tablica 10: Prognoziranje studenata na stručnim studijima – eksponencijalni trend

| Učilišta | 2012/13 | 2013/14 | 2014/15 | 2015/16 | 2016/17 | 2017/18 | 2018/19 |
|---|---|---|---|---|---|---|---|
| Javna | 49.087 | 49.947 | 50.822 | 51.712 | 52.617 | 53.538 | 54.476 |
| Privatna | 17.568 | 19.772 | 22.253 | 25.045 | 28.188 | 31.725 | 35.705 |

Tablica iznad prikazuje prognoziranje pomoću funkcije 'growth' za javna i privatna visoka učilišta stručnih studija.

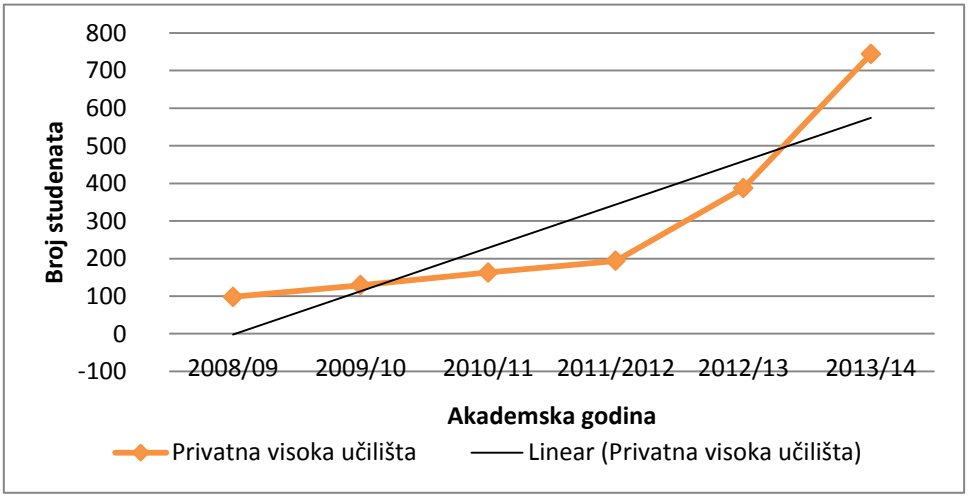
### 3.1.5.Sveučilišni studij

U ovom poglavlju analizirani su brojevi studenata sveučilišnih studija na isti način kao što su analizirani brojevi studenata stručnih studija u poglavlju 3.1.4. Sljedeća slika prikazuje linearni graf koji prikazuje broj studenata sveučilišnih studija javnih učilišta.




Slika 12: Broj studenata na javnim učilištima sveučilišnih studija

Broj studenata sveučilišnih studija privatnih učilišta je prikazan na sljedećem grafu.




Slika 13: Broj studenata na privatnim učilištima sveučilišnih studija

Prethodna dva grafa su prikazana odvojeno zbog velike razlike u podacima između javnih i privatnih studija.

### 3.1.5.1. Indeksi javnih i privatnih visokih učilišta sveučilišnih studija

Sljedeća tablica prikazuje verižne indekse i stope promjene za javna i privatna visoka učilišta na sveučilišnim studijima na isti način kao što je ranije analizirano za stručne studije.

Tablica 11: Verižni indeksi studenata na sveučilišnom studiju po visokim učilištima

| Visoka učilišta | 2008/09 | 2009/10 | 2010/11 | 2011/12 | 2012/13 | 2013/14 |
|---|---|---|---|---|---|---|
| Javna Yt | 128.669 | 126.929 | 131.371 | 133.984 | 128.274 | 122.882 |
| Privatna Yt | 98 | 129 | 163 | 194 | 387 | 744 |
| Vt - javna | - | 98,65 | 103,50 | 101,99 | 95,74 | 95,80 |
| St - jvu | - | -1,35 | 3,50 | 1,99 | -4,26 | -4,20 |
| Vt- privatna | - | 131,63 | 126,36 | 119,02 | 199,48 | 192,25 |
| St - pvu | - | 31,63 | 26,36 | 19,02 | 99,48 | 92,25 |

Verižni indeksi na tablici iznad nam pokazuju da je broj studenata koji su upisivali sveučilišni studij na javnim visokim učilištima 2009. godine pao u odnosu na 2008. godinu. 2010. i 2011. godine taj broj je rastao, ali je 2012. i 2013. godine opet pao broj upisanih studenata. Za studente sveučilišnih studija koji su upisivali privatna visoka učilišta, broj upisanih je svake godine (od 2008. do 2013.) rastao u odnosu na prethodnu godinu. U promatranom razdoblju od 2008. do 2013. godine broj upisanih studenata na sveučilišni studij javnih visokih učilišta se prosječno godišnje smanjivao za 0,92%. U promatranom razdoblju od 2008. do 2013. godine broj upisanih studenata na sveučilišni studij privatnih visokih učilišta se prosječno godišnje povećavao za 49,99%. Indeksi za javna visoka učilišta sveučilišnog studija na tablici ispod nam pokazuju da je 2009., 2012. i 2013. godine bilo manje studenata koji su upisali javna visoka učilišta u odnosu na baznu 2008. godinu, a 2010. i 2011. godine je bilo više studenata u odnosu na 2008. godinu.

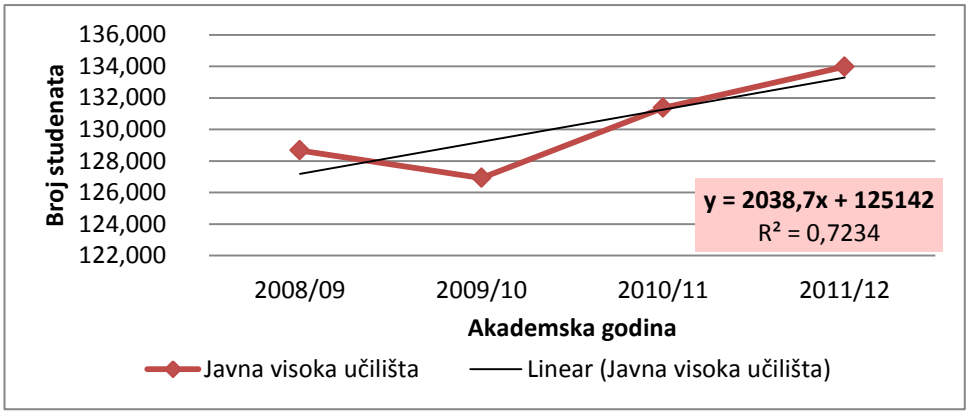
Tablica 12: Bazni indeksi studenata na sveučilišnom studiju po visokim učilištima

| Visoka učilišta | 2008/09 | 2009/10 | 2010/11 | 2011/12 | 2012/13 | 2013/14 |
|---|---|---|---|---|---|---|
| Javna Yt | 128.669 | 126.929 | 131.371 | 133.984 | 128.274 | 122.882 |
| Privatna Yt | 98 | 129 | 163 | 194 | 387 | 744 |
| It - javna | 100 | 99 | 102 | 104 | 100 | 96 |
| St - jvu | 0 | -1,35 | 2,10 | 4,13 | -0,31 | -4,50 |
| It- privatna | 100 | 131,63 | 166,33 | 197,96 | 394,90 | 759,18 |
| St - pvu | 0 | 31,63 | 66,33 | 97,96 | 294,90 | 659,18 |

Indeksi za privatna visoka učilišta sveučilišnog studija na istoj tablici nam pokazuju da je od 2009. do 2013. godine bilo više studenata u odnosu na baznu 2008. godinu.

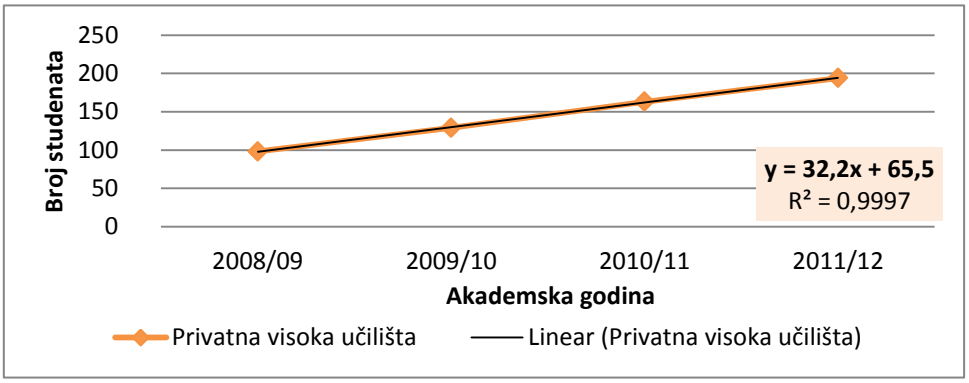
### 3.1.5.2. Trendovi javnih i privatnih visokih učilišta sveučilišnih studija

Sljedeća slika prikazuje linearni trend broja studenata sveučilišnog studija na javnim visokim učilištima.




Slika 14: Linearni trend studenata na javnim učilištima sveučilišnih studija

Reprezentativnost na slici iznad je 72%. Očekivana vrijednost za broj upisanih studenata na sveučilišni studij na javna visoka učilišta 2008/09 ak. godine je **125142**. U promatranom razdoblju broj upisanih studenata na sveučilišni studij na javna visoka učilišta se prosječno godišnje povećavao za **2038,7**. U promatranom razdoblju broj upisanih studenata sveučilišnog studija na javna visoka učilišta se prosječno godišnje povećavao za **1,36%**. Sljedeća slika prikazuje linearni trend broja studenata sveučilišnog studija na privatnim visokim učilištima. Koeficijent determinacije na slici ispod je približno 1 što znači da je reprezentativnost približno 100%. Očekivana vrijednost za broj upisanih studenata na sveučilišni studij na javna visoka učilišta 2008/09 ak. godine je **65,5**.




Slika 15: Linearni trend studenata na privatnim učilištima sveučilišnih studija

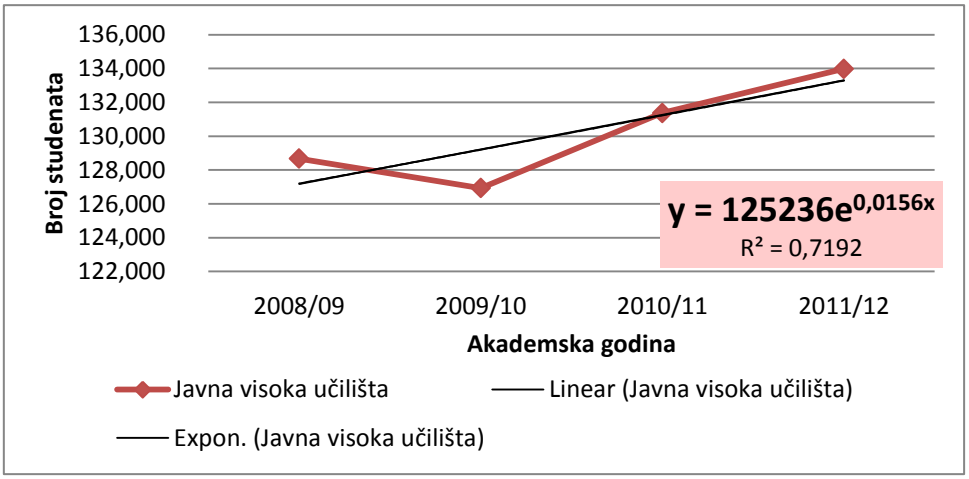
U promatranom razdoblju broj upisanih studenata na sveučilišni studij na javna visoka učilišta se prosječno godišnje povećavao za **32,2**. U promatranom razdoblju broj upisanih studenata sveučilišnog studija na privatna visoka učilišta se prosječno godišnje povećavao za **25,56%**. Sljedeća tablica prikazuje prognoziranje broja studenata sveučilišnog studija

upisanih na javna visoka učilišta i privatna visoka učilišta u razdoblju od 2012/13 do 2018/19 ak. godine na temelju linearnog trenda.

Tablica 13: Prognoziranje studenata na sveučilišnim studijima na temelju linearnog trenda

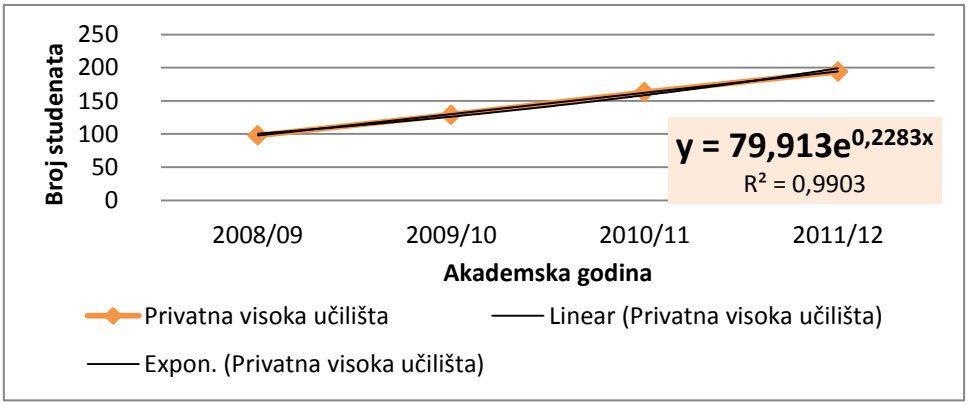
| Učilišta | 2012/13 | 2013/14 | 2014/15 | 2015/16 | 2016/17 | 2017/18 | 2018/19 |
|---|---|---|---|---|---|---|---|
| Javna | 135.335 | 137.374 | 139.412 | 141.451 | 143.490 | 145.529 | 147.567 |
| Privatna | 227 | 259 | 291 | 323 | 355 | 388 | 420 |

Prema linearnom trendu 2018/19 ak. godine (*x* je 10) možemo očekivati **145529** studenata sveučilišnog studija upisanih na javna visoka učilišta. Prema linearnom trendu ak. godine 2018/19 možemo očekivati **387,5** studenata sveučilišnog studija upisanih na privatna visoka učilišta. Na sljedećoj slici prikazan je eksponencijalan trend broja studenata javnih učilišta sveučilišnih studija.




Slika 16: Eksponencijalni trend studenata na javnim učilištima sveučilišnih studija

Očekivana vrijednost za broj upisanih studenata na sveučilišni studij na javna visoka učilišta 2008/09 ak. godine je **125236**. U promatranom razdoblju broj upisanih studenata na sveučilišni studij na javna visoka učilišta se prosječno godišnje povećavao za **1,57%**. Na sljedećoj slici na sljedećoj strani prikazan je eksponencijalan trend broja studenata privatnih učilišta sveučilišnih studija.




Slika 17: Eksponencijalni trend studenata na privatnim učilištima sveučilišnih studija

Očekivana vrijednost za broj upisanih studenata na sveučilišni studij na javna visoka učilišta 2008/09 ak. godine je **79,913**. U promatranom razdoblju broj upisanih studenata na sveučilišni studij na javna visoka učilišta se prosječno godišnje povećavao za **25,65%**.

Tablica 14: Prognoziranje studenata na sveučilišnim studijima – eksponencijalni trend

| Učilišta | 2012/13 | 2013/14 | 2014/15 | 2015/16 | 2016/17 | 2017/18 | 2018/19 |
|---|---|---|---|---|---|---|---|
| Javna | 139669 | 141863 | 144091 | 146354 | 148652 | 139669 | 141863 |
| Privatna | 395 | 496 | 623 | 783 | 984 | 395 | 496 |

Tablica iznad prikazuje izračune funkcije 'growth'. Prema formuli za eksponencijalni trend ak. godine 2018/19. možemo očekivati **152370** studenata sveučilišnog studija upisanih na javna visoka učilišta, a **819** studenata na privatna visoka učilišta.

## 3.2. Broj studenata po vrsti studijskog programa

U ovom poglavlju je analiziran broj studenata po vrsti studijskog programa. Tip studija može biti, kao što je to opisano ranije, stručni studij i sveučilišni studij, a vrsta studija može biti prediplomski, preddiplomski, dodiplomski, diplomski, poslijediplomski i slično ("preddiplomski" može biti sveučilišni studij, a "prediplomski" stručni studij). Sljedeća tablica koja prelazi na sljedeću stranu prikazuje broj studenata po vrsti studija, a prikazane vrste studija na istoj tablici su raspoređene po tipu studija.

Tablica 15: Broj studenata po vrsti studija

| Vrsta i tip studija | 2008/09 | 2009/10 | 2010/11 | 2011/12 | 2012/13 | 2013/14 |
|---|---|---|---|---|---|---|
| x | 0 | 1 | 2 | 3 | 4 | 5 |
| Sveučilišni | | | | | | |
| - Preddiplomski | 63.991 | 63.418 | 64.214 | 65.200 | 64.131 | 61.105 |

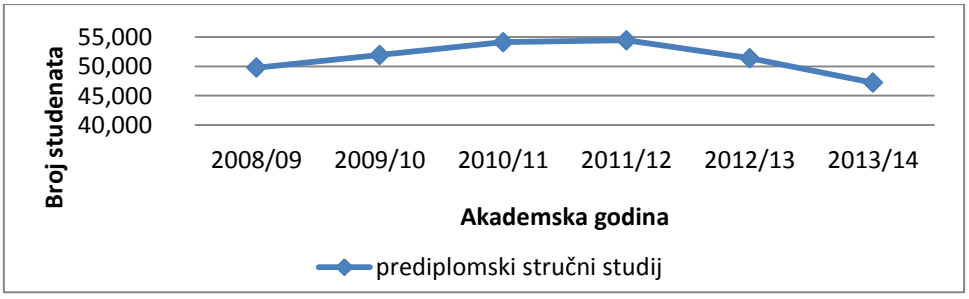
| Vrsta i tip studija | 2008/09 | 2009/10 | 2010/11 | 2011/12 | 2012/13 | 2013/14 |
|---|---|---|---|---|---|---|
| - Diplomski | 6.225 | 15.771 | 23.369 | 26.450 | 27.995 | 29.390 |
| - integrirani preddiplomski i diplomski | 17.039 | 20.498 | 22.597 | 23.016 | 22.809 | 23.290 |
| - poslijediplomski specijalistički | 4.028 | 3.372 | 4.414 | 4.655 | 2.309 | 1.856 |
| - poslijediplomski sveučilišni | 5.480 | 4.736 | 4.736 | 5.633 | 4.934 | 5.079 |
| - sveučilišni dodiplomski* | 31.301 | 18.885 | 11.630 | 8.228 | 5.488 | 2.861 |
| - poslijediplomski sveučilišni znanstveni* | 703 | 378 | 574 | 996 | 995 | 45 |
| **Ukupno sveučilišni:** | **128.767** | **127.058** | **131.534** | **134.178** | **128.661** | **123.626** |
| Stručni | | | | | | |
| - prediplomski stručni | 49.789 | 51.914 | 54.098 | 54.440 | 51.382 | 47.222 |
| - specijalistički diplomski stručni | 2.493 | 3.721 | 6.074 | 6.999 | 7.313 | 7.226 |
| - poslijediplomski stručni* | 21 | 22 | 0 | 1 | 47 | 0 |
| - stručni dodiplomski* | 4.528 | 2.592 | 2.345 | 1.800 | 882 | 602 |
| **Ukupno stručni:** | **56.831** | **58.249** | **62.517** | **63.240** | **59.624** | **55.050** |
| **Ukupno:** | **185.598** | **185.307** | **194.051** | **197.418** | **188.285** | **178.676** |
| * studijski programi koji se 2019. godine više ne izvode, ali postoje studenti na njima | | | | | | |

(Izvor: Portal otvorenih podataka Republike Hrvatske, 2019)

U nastavku su podaci iz prethodne tablice analizirani trendovima i indeksiranim brojevima.

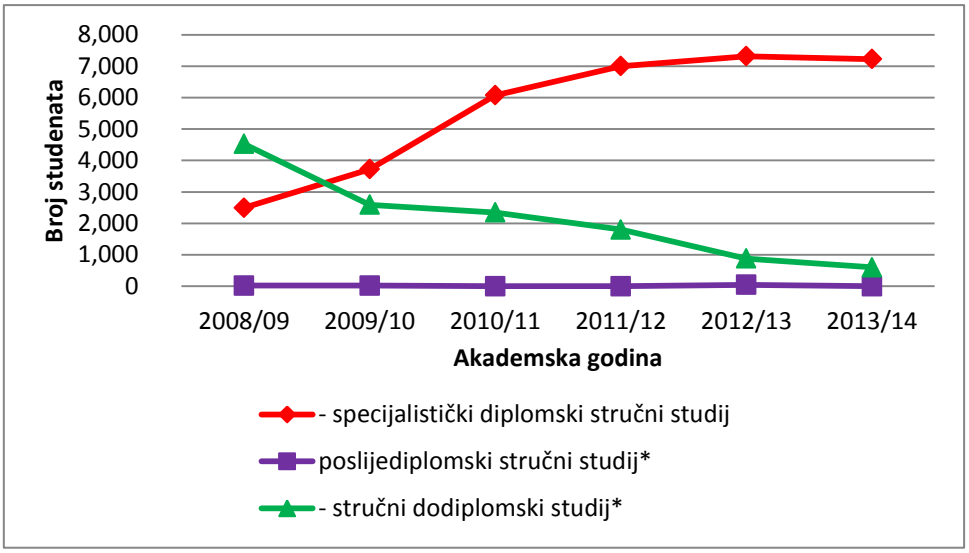
## 3.2.1. Vrste studijskih programa stručnih studija

Slijedi analiza na isti način kao u prethodnim poglavljima. Na sljedećoj slici je prikazan graf koji prikazuje broj studenata prediplomskog stručnog studija.




Slika 18: Broj studenata prediplomskog stručnog studija

Broj studenata prediplomskog stručnog studija je prikazan na zasebnom grafu zbog velike razlike u podacima između ovog i preostalih vrsta studija. Na sljedećoj slici je prikazan graf koji prikazuje broj studenata stručnog studija po vrsti studija osim prediplomskog stručnog studija. Na svim slikama koje prikazuju grafove su znakom asteriska odnosno "*" označeni studiji koji se ne izvode, ali postoje studenti na njima.




Slika 19: Broj studenata po vrsti stručnih studija

Broj studenata na poslijediplomskom stručnom studiju je bio najmanje 0, a najviše 47 što je velika razlika u podacima u odnosu na ostale vrste studija, stoga je isti broj prikazan na sljedećoj slici odvojeno od ostalih vrsta studija.




Slika 20: Broj studenata po vrsti stručnih studija

### 3.2.1.1. Indeksi broja studenata po vrstama studijskih programa stručnih studija

Sljedeća tablica prikazuje verižne indekse broja studenata stručnih studija po vrstama studija.

Tablica 16: Verižni indeksi studenata raspoređenih stručnih studija po vrsti studija

| Visoka učilišta | 2008/09 | 2009/10 | 2010/11 | 2011/12 | 2012/13 | 2013/14 |
|---|---|---|---|---|---|---|
| - prediplomski stručni studij (1) | 49.789 | 51.914 | 54.098 | 54.440 | 51.382 | 47.222 |
| - specijalistički diplomski stručni studij (2) | 2.493 | 3.721 | 6.074 | 6.999 | 7.313 | 7.226 |
| - poslijediplomski stručni studij* (3) | 21 | 22 | 0 | 1 | 47 | 0 |
| - stručni dodiplomski studij* (4) | 4.528 | 2.592 | 2.345 | 1.800 | 882 | 602 |
| Vt - 1 | - | 104,27 | 104,21 | 100,63 | 94,38 | 91,90 |
| St - 1 | - | 4,27 | 4,21 | 0,63 | -5,62 | -8,10 |
| Vt - 2 | - | 149,26 | 163,24 | 115,23 | 104,49 | 98,81 |
| St - 2 | - | 49,26 | 63,24 | 15,23 | 4,49 | -1,19 |
| Vt - 3 | - | 104,76 | 0,00 | ∞ | 4700,00 | 0,00 |
| St - 3 | - | 4,76 | -100,00 | ∞ | 4600,00 | -100,00 |
| Vt - 4 | - | 57,24 | 90,47 | 76,76 | 49,00 | 68,25 |
| St - 4 | - | -42,76 | -9,53 | -23,24 | -51,00 | -31,75 |

Verižni indeksi na tablici iznad nam pokazuju da je broj studenata na prediplomskim stručnim studijima i specijalističkim diplomskim stručnim studijima svake godine padao, broj studenata poslijediplomskog stručnog studija je 2010. i 2013. godine pao 100% što znači da nije bilo studenata, a broj studenata dodiplomskih studija je padao do 2012. godine, a 2013. je porastao. U promatranom razdoblju od 2008. do 2013. godine broj upisanih studenata na prediplomski stručni studij se prosječno godišnje smanjivao za 1,05%. U istom razdoblju broj upisanih studenata na specijalistički diplomski stručni studij se prosječno godišnje povećavao za 23,72%. U istom razdoblju broj upisanih studenata na poslijediplomski stručni studij se prosječno godišnje smanjivao za 100% jer je broj studenata težio nuli. U istom razdoblju broj upisanih studenata na stručni dodiplomski studij se prosječno godišnje smanjivao za 33,21%. Sljedeća tablica prikazuje bazne indekse broja studenata stručnih studija po vrstama studija, a bazna ak. godina je 2008/09.

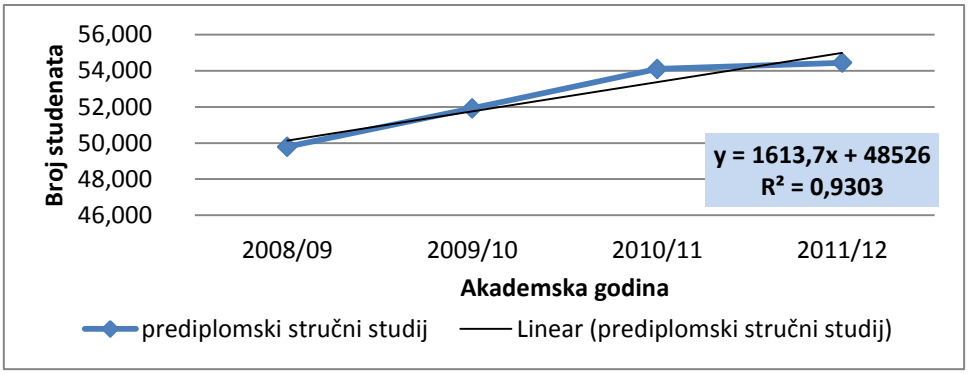
Tablica 17: Bazni indeksi studenata raspoređenih stručnih studija po vrsti studija

| Visoka učilišta | 2008/09 | 2009/10 | 2010/11 | 2011/12 | 2012/13 | 2013/14 |
|---|---|---|---|---|---|---|
| - prediplomski stručni studij (1) | 49.789 | 51.914 | 54.098 | 54.440 | 51.382 | 47.222 |
| - specijalistički diplomski stručni studij (2) | 2.493 | 3.721 | 6.074 | 6.999 | 7.313 | 7.226 |
| - poslijediplomski stručni studij* (3) | 21 | 22 | 0 | 1 | 47 | 0 |
| - stručni dodiplomski studij* (4) | 4.528 | 2.592 | 2.345 | 1.800 | 882 | 602 |
| It - 1 | 100 | 104,27 | 108,65 | 109,34 | 103,20 | 94,84 |
| St - 1 | 0 | 4,27 | 8,65 | 9,34 | 3,20 | -5,16 |
| It-2 | 100 | 149,26 | 243,64 | 280,75 | 293,34 | 289,85 |
| St - 2 | 0 | 49,26 | 143,64 | 180,75 | 193,34 | 189,85 |
| It - 3 | 100 | 104,76 | 0,00 | 4,76 | 223,81 | 0,00 |
| St - 3 | 0 | 4,76 | -100,00 | -95,24 | 123,81 | -100,00 |
| It-4 | 100 | 57,24 | 51,79 | 39,75 | 19,48 | 13,30 |
| St - 4 | 0 | -42,76 | -48,21 | -60,25 | -80,52 | -86,70 |

Preddiplomski stručni studij – po indeksima zaključujemo da je od 2009. do 2012. godine bilo više studenata u odnosu na baznu 2008. godinu, a 2013. ih je bilo manje. Specijalistički diplomski stručni studij – po indeksima zaključujemo da je u razdoblju od 2009. do 2013. godine bilo više studenata u odnosu na baznu 2008. godinu. Poslijediplomski stručni studij – po indeksima zaključujemo da je 2009. i 2012. godine bilo više upisanih studenata u odnosu na baznu godinu, a 2010., 2011. i 2013. manje. Stručni dodiplomski studij – po indeksima zaključujemo da je u razdoblju od 2009. do 2013. godine bilo manje upisanih studenata u odnosu na baznu 2008. godinu.

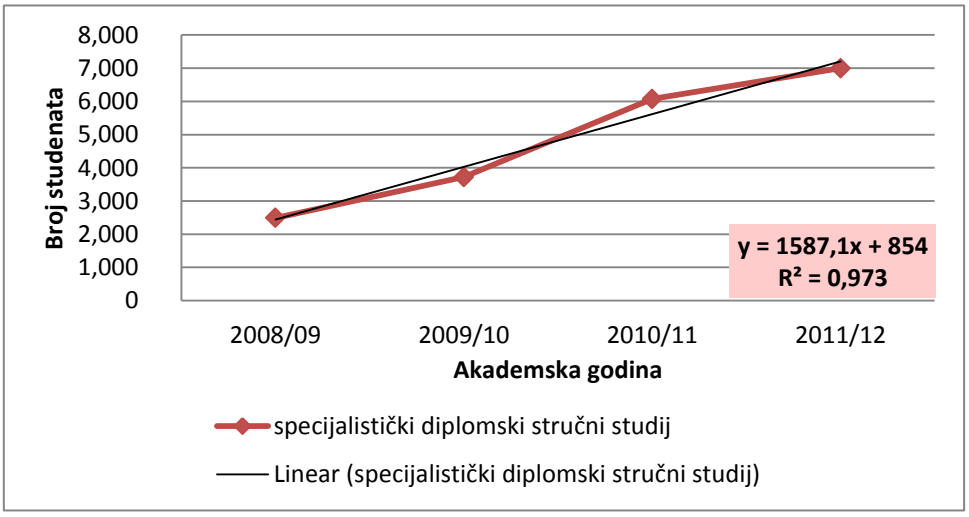
### 3.2.1.2. Trendovi broja studenata po vrstama studijskih programa stručnih studija

U ovom poglavlju su analizirani trendovi na isti način kao što je to analizirano ranije. Svi grafovi koji prikazuju razdoblje, prikazuju promatrano razdoblje u izračunima. Sljedeća slika na sljedećoj strani prikazuje linearnu jednadžbu i graf koji prikazuje linearni trend broja studenata prediplomskog stručnog studija.



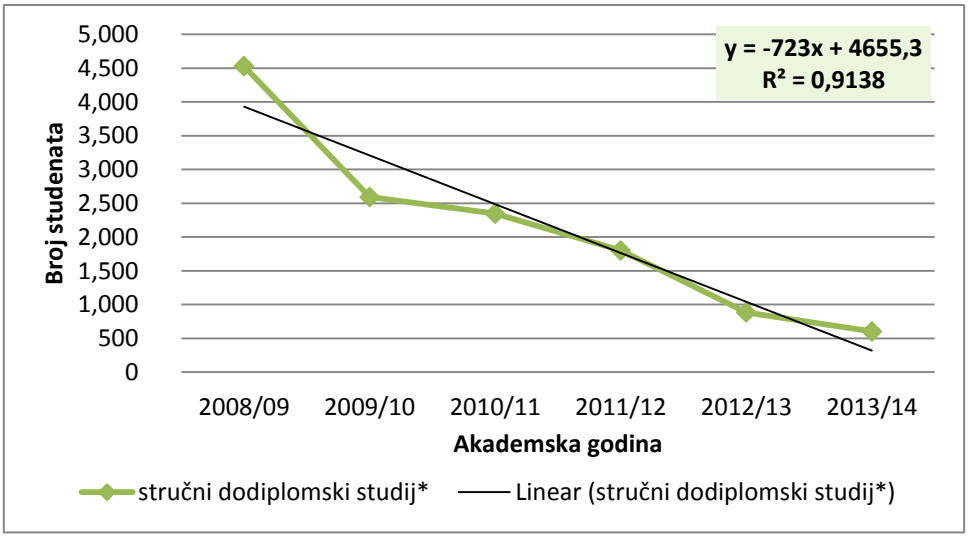

Slika 21: Linearni trend broja studenata prediplomskog stručnog studija

U nastavku slijede izračunati podaci za prediplomski stručni studij. Očekivana vrijednost za broj upisanih studenata 2008/09. godine je **48526**. U promatranom razdoblju broj upisanih studenata se prosječno godišnje povećavao za **1613,7**. U promatranom razdoblju broj upisanih studenata se prosječno godišnje povećavao za **3,02%.** Sljedeća slika prikazuje linearnu jednadžbu i graf koji prikazuje linearni trend broja studenata specijalističkog diplomskog stručnog studija.



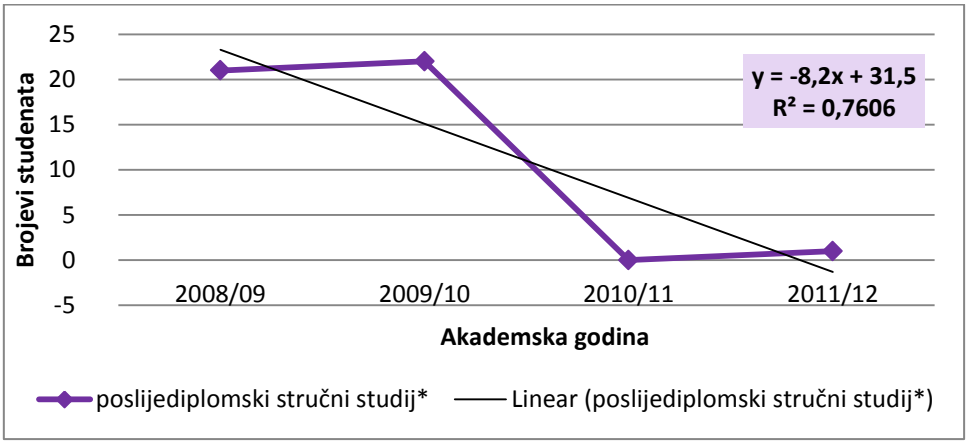

Slika 22: Linearni trend broja specijalističkog diplomskog stručnog studija

U nastavku slijede izračunati podaci za specijalistički diplomski stručni studij. Očekivana vrijednost za broj upisanih studenata 2008/09. godine je **854**. U promatranom razdoblju broj upisanih studenata se prosječno godišnje povećavao za **1587,1**. U promatranom razdoblju broj upisanih studenata se prosječno godišnje povećavao za **41,07%.** Sljedeća slika na sljedećoj strani prikazuje linearnu jednadžbu i graf koji prikazuje linearni trend broja studenata stručnog dodiplomskog studija u razdoblju od 2008/09 do 2013/14 ak. godine.




Slika 23: Linearni trend broja studenata stručnog dodiplomskog studija

U nastavku slijede izračunati podaci za stručni dodiplomski studij. Očekivana vrijednost za broj upisanih studenata 2008/09. godine je **4655,3**. U promatranom razdoblju broj upisanih studenata se prosječno godišnje smanjivao za **723**. U promatranom razdoblju broj upisanih studenata se prosječno godišnje smanjivao za **33,21%.** Sljedeća slika prikazuje linearnu jednadžbu i graf koji prikazuje linearni trend broja studenata poslijediplomskog stručnog studija.



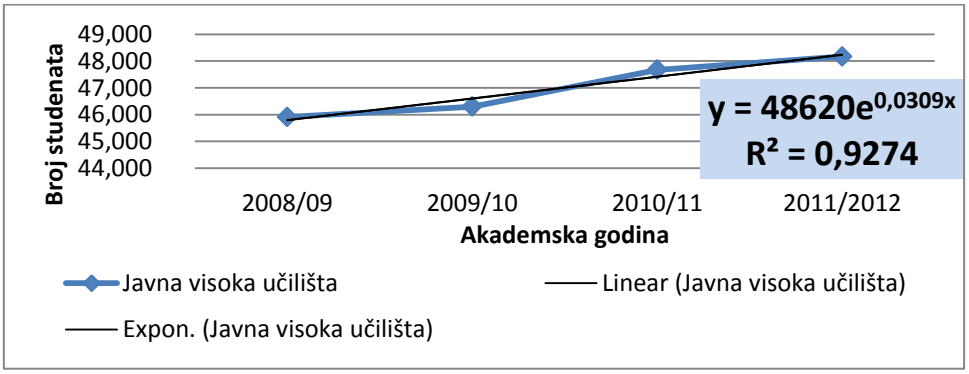

Slika 24: Linearni trend broja studenata poslijediplomskog stručnog studija

U nastavku slijede izračunati podaci za poslijediplomski stručni studij. Očekivana vrijednost za broj upisanih studenata 2008/09. godine je **31,5**. U promatranom razdoblju broj upisanih studenata se prosječno godišnje smanjivao za **8,2**. U promatranom razdoblju broj upisanih studenata se prosječno godišnje smanjivao za **100%** jer je broj studenata bio nula. Sljedeća tablica na sljedećoj strani prikazuje rezultate prognoziranja broja studenata linearnim trendom odnosno funkcijom 'trend' u uredskom alatu Excel po vrstama studija na stručnim studijima.

Tablica 18: Prognoziranje studenata linearnim trendom po vrstama stručnih studija

| Vrsta stručnog studija | 2012/13 | 2013/14 | 2014/15 | 2015/16 | 2016/17 | 2017/18 | 2018/19 |
|---|---|---|---|---|---|---|---|
| prediplomski stručni | 56.595 | 58.208 | 59.822 | 61.436 | 63.049 | 64.663 | 66.277 |
| specijalistički diplomski stručni studij | 8.790 | 10.377 | 11.964 | 13.551 | 15.138 | 16.725 | 18.312 |
| poslijediplomski stručni studij* | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| stručni dodiplomski studij* | 709 | 0 | 0 | 0 | 0 | 0 | 0 |

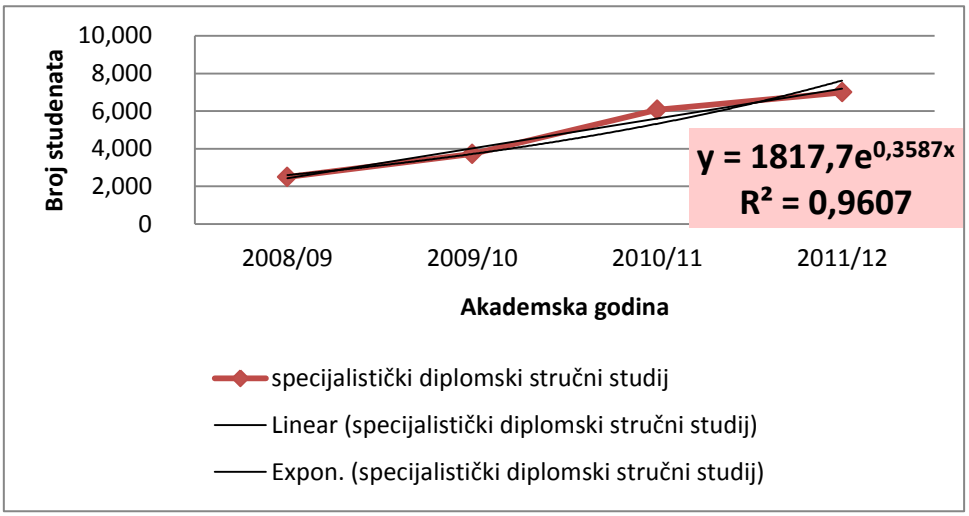
Dobiveni negativni brojevi funkcijom 'trend' u tablici iznad su zamijenjeni s nulom jer takav rezultat znači da se prognozira da neće biti studenata. Prema linearnom trendu u promatranim razdobljima, ak. godine 2018/19 (*x* je 10) možemo očekivati **64663** studenata prediplomskog stručnog studija. Prema linearnom trendu iste godine možemo očekivati **16725** studenata specijalističkog diplomskog stručnog studija. Prema linearnom trendu iste godine neće biti upisanih studenata na stručni dodiplomski studij ni na poslijediplomski stručni studij. Sljedeća slika prikazuje eksponencijalnu jednadžbu i graf koji prikazuje eksponencijalni trend broja studenata prediplomskog stručnog studija.




Slika 25: Eksponencijalni trend broja studenata prediplomskog stručnog studija

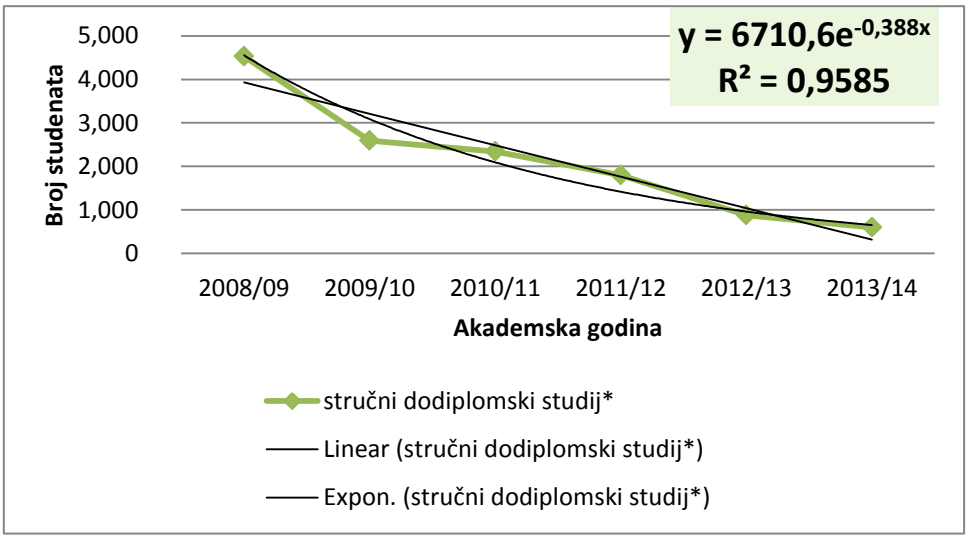
U nastavku slijede izračunati podaci za prediplomski stručni studij. Očekivana vrijednost za broj upisanih studenata 2008/09. godine je **48620**. U promatranom razdoblju broj upisanih studenata se prosječno godišnje povećavao za **3,13%.**

Sljedeća slika prikazuje eksponencijalnu jednadžbu i graf koji prikazuje eksponencijalni trend broja studenata specijalističkog diplomskog stručnog studija.




Slika 26: Eksponencijalni trend broja studenata specijalističkog diplomskog stručnog studija

U nastavku slijede izračunati podaci za specijalistički diplomski stručni studij. Očekivana vrijednost za broj upisanih studenata 2008/09. godine je **1817,7**. U promatranom razdoblju broj upisanih studenata se prosječno godišnje povećavao za **43,14%**. Sljedeća slika prikazuje eksponencijalnu jednadžbu i graf koji prikazuje eksponencijalni trend broja studenata stručnog dodiplomskog studija.




Slika 27: Eksponencijalni trend broja studenata stručnog dodiplomskog studija

U nastavku slijede izračunati podaci za stručni dodiplomski studij. Očekivana vrijednost za broj upisanih studenata 2008/09. godine je **6710,6**. U promatranom razdoblju broj upisanih studenata se prosječno godišnje smanjivao za **32,15%**. Sljedeća tablica na sljedećoj strani prikazuje rezultate prognoze eksponencijalnog trenda odnosno funkcije 'growth'.

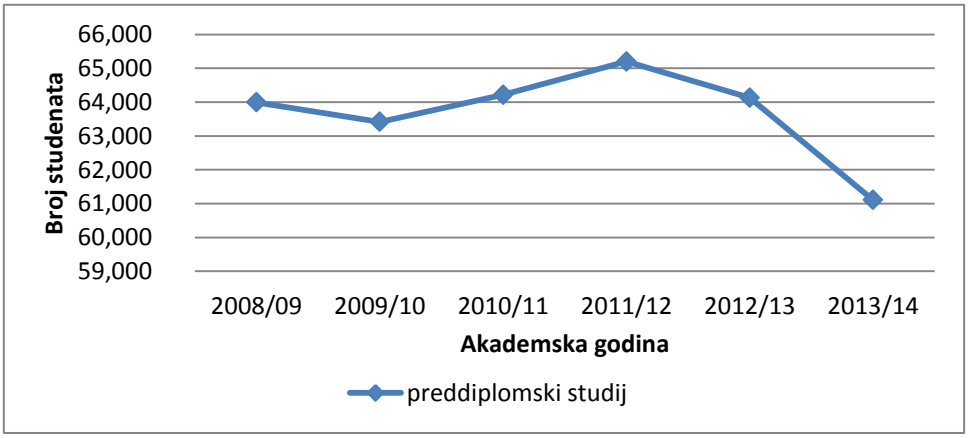
Tablica 19: Prognoziranje studenata eksponencijalnim trendom po vrstama stručnih studija

| Vrsta stručnog studija | 2012/13 | 2013/14 | 2014/15 | 2015/16 | 2016/17 | 2017/18 | 2018/19 |
|---|---|---|---|---|---|---|---|
| prediplomski stručni | 56.747 | 58.528 | 60.366 | 62.261 | 64.216 | 66.232 | 68.311 |
| specijalistički diplomski stručni studij | 10.925 | 15.638 | 22.385 | 32.043 | 45.869 | 65.658 | 93.987 |
| poslijediplomski stručni studij* | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| stručni dodiplomski studij* | 1.295 | 972 | 730 | 548 | 411 | 309 | 232 |

Prema eksponencijalnim trendovima u promatranim razdobljima, ak. godine 2018/19 možemo očekivati **66223** studenata prediplomskog stručnog studija, **27269** studenata specijalističkog diplomskog stručnog studija i **139** studenata na stručni dodiplomski studij. Eksponencijalni trend broja studenata poslijediplomskog stručnog studija nije moguće izračunati zbog broja studenata jednakog nuli u promatranom razdoblju.

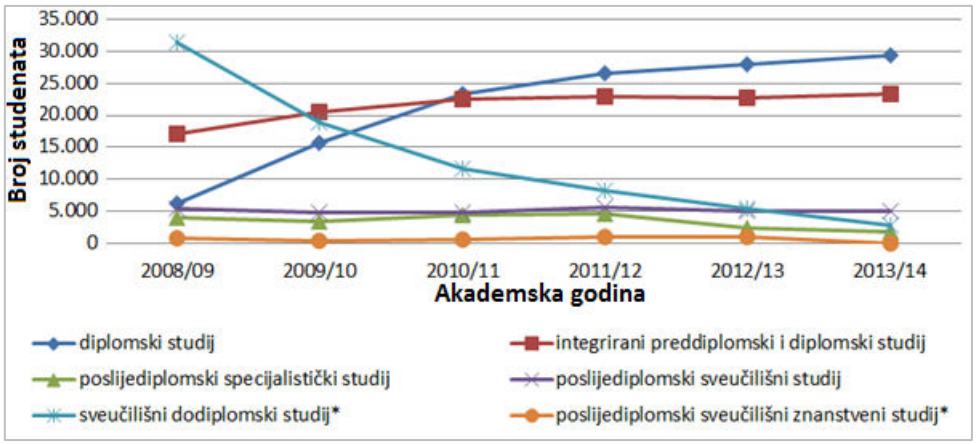
## 3.2.2. Vrste studijskih programa sveučilišnih studija

Slijedi analiza na isti način kao u prethodnim poglavljima. Na sljedećoj slici je prikazan graf koji prikazuje broj studenata preddiplomkog sveučilišnog studija.




Slika 28: Broj studenata preddiplomskog sveučilišnog studija

Na sljedećoj slici je prikazan graf koji prikazuje broj studenata sveučilišnog studija po vrsti studija sveučilišnih studija osim preddiplomskog studija koji je ranije izdvojen zbog velike razlike u podacima.




Slika 29: Broj studenata sveučilišnog studija po vrsti studija

U svim tablicama i slikama su asteriscima označeni studiji koji se više ne izvode, ali postoje studenti na njima prema podacima 2019. godine.

### 3.2.2.1. Indeksi broja studenata po vrstama sveučilišnih studija

Sljedeća tablica koja prelazi na sljedeću stranu prikazuje verižne indekse za broj studenata po vrstama sveučilišnih studija.

Tablica 20: Verižni indeksi broja studenata po vrstama sveučilišnih studija

| Vrsta sveučilišnog studija | 2008/09 | 2009/10 | 2010/11 | 2011/12 | 2012/13 | 2013/14 |
|---|---|---|---|---|---|---|
| preddiplomski | 63.991 | 63.418 | 64.214 | 65.200 | 64.131 | 61.105 |
| diplomski | 6.225 | 15.771 | 23.369 | 26.450 | 27.995 | 29.390 |
| integrirani preddiplomski i diplomski | 17.039 | 20.498 | 22.597 | 23.016 | 22.809 | 23.290 |
| poslijediplomski specijalistički | 4.028 | 3.372 | 4.414 | 4.655 | 2.309 | 1.856 |
| poslijediplomski sveučilišni | 5.480 | 4.736 | 4.736 | 5.633 | 4.934 | 5.079 |
| sveučilišni dodiplomski* | 31.301 | 18.885 | 11.630 | 8.228 | 5.488 | 2.861 |
| poslijediplomski sveučilišni znanstveni* | 703 | 378 | 574 | 996 | 995 | 45 |

| Vrsta sveučilišnog studija | 2008/09 | 2009/10 | 2010/11 | 2011/12 | 2012/13 | 2013/14 |
|---|---|---|---|---|---|---|
| Vt - 1 | - | 99,10 | 101,26 | 101,54 | 98,36 | 95,28 |
| St - 1 | - | **-0,90** | **1,26** | **1,54** | **-1,64** | **-4,72** |
| Vt-2 | - | 253,35 | 148,18 | 113,18 | 105,84 | 104,98 |
| St - 2 | - | **153,35** | **48,18** | **13,18** | **5,84** | **4,98** |
| Vt - 3 | - | 120,30 | 110,24 | 101,85 | 99,10 | 102,11 |
| St - 3 | - | **20,30** | **10,24** | **1,85** | **-0,90** | **2,11** |
| Vt-4 | - | 83,71 | 130,90 | 105,46 | 49,60 | 80,38 |
| St - 4 | - | **-16,29** | **30,90** | **5,46** | **-50,40** | **-19,62** |
| Vt-5 | - | 86,42 | 100,00 | 118,94 | 87,59 | 102,94 |
| St - 5 | - | **-13,58** | **0,00** | **18,94** | **-12,41** | **2,94** |
| Vt-6 | - | 60,33 | 61,58 | 70,75 | 66,70 | 52,13 |
| St - 6 | - | **-39,67** | **-38,42** | **-29,25** | **-33,30** | **-47,87** |
| Vt-7 | - | 53,77 | 151,85 | 173,52 | 99,90 | 4,52 |
| St - 7 | - | **-46,23** | **51,85** | **73,52** | **-0,10** | **-95,48** |

Temeljem prikazanih verižnih indeksa na tablici iznad, dobivene su prosječne godišnje stope promjene od 2008/09 do 2011/12 ak. godine kako prikazuje sljedeća tablica.

Tablica 21: Prosječne godišnje stope temeljem verižnih indeksa broja studenata po vrstama sveučilišnih studija

| Vrsta sveučilišnog studija | Prosječna godišnja stopa od 2008/09 do 2011/12 |
|---|---|
| preddiplomski | 0,63% |
| diplomski | 61,97% |
| integrirani preddiplomski i diplomski | 10,54% |
| poslijediplomski specijalistički | 4,94% |
| poslijediplomski sveučilišni | 0,92% |
| sveučilišni dodiplomski* | -35,94% |
| poslijediplomski sveučilišni znanstveni* | 12,31% |

Sljedeća tablica na sljedećoj strani prikazuje bazne indekse broja studenata po vrstama sveučilišnih studija s baznom 2008/09 ak. godinom.

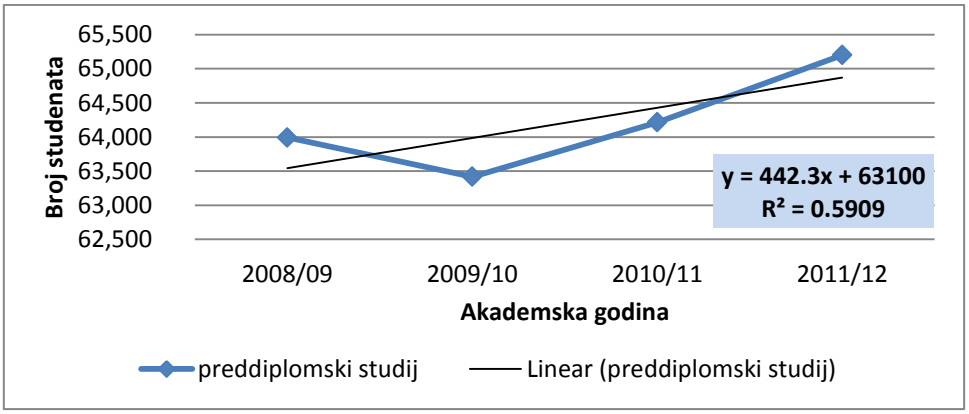
Tablica 22: Bazni indeksi broja studenata po vrstama sveučilišnih studija

| Vrsta sveučilišnog studija | 2008/09 | 2009/10 | 2010/11 | 2011/12 | 2012/13 | 2013/14 |
|---|---|---|---|---|---|---|
| - preddiplomski studij | 63.991 | 63.418 | 64.214 | 65.200 | 64.131 | 61.105 |
| - diplomski studij | 6.225 | 15.771 | 23.369 | 26.450 | 27.995 | 29.390 |
| - integrirani preddiplomski i diplomski studij | 17.039 | 20.498 | 22.597 | 23.016 | 22.809 | 23.290 |
| - poslijediplomski specijalistički studij | 4.028 | 3.372 | 4.414 | 4.655 | 2.309 | 1.856 |
| - poslijediplomski sveučilišni studij | 5.480 | 4.736 | 4.736 | 5.633 | 4.934 | 5.079 |
| - sveučilišni dodiplomski studij* | 31.301 | 18.885 | 11.630 | 8.228 | 5.488 | 2.861 |
| - poslijediplomski sveučilišni znanstveni studij* | 703 | 378 | 574 | 996 | 995 | 45 |
| It - 1 | 100 | 99,10 | 100,35 | 101,89 | 100,22 | 95,49 |
| St - 1 | 0 | **-0,90** | **0,35** | **1,89** | **0,22** | **-4,51** |
| It-2 | 100 | 253,35 | 375,41 | 424,90 | 449,72 | 472,13 |
| St - 2 | 0 | **153,35** | **275,41** | **324,90** | **349,72** | **372,13** |
| It - 3 | 100 | 120,30 | 132,62 | 135,08 | 133,86 | 136,69 |
| St - 3 | 0 | **20,30** | **32,62** | **35,08** | **33,86** | **36,69** |
| It-4 | 100 | 83,71 | 109,58 | 115,57 | 57,32 | 46,08 |
| St - 4 | 0 | **-16,29** | **9,58** | **15,57** | **-42,68** | **-53,92** |
| It-5 | 100 | 86,42 | 86,42 | 102,79 | 90,04 | 92,68 |
| St - 5 | 0 | **-13,58** | **-13,58** | **2,79** | **-9,96** | **-7,32** |
| It-6 | 100 | 60,33 | 37,16 | 26,29 | 17,53 | 9,14 |
| St - 6 | 0 | **-39,67** | **-62,84** | **-73,71** | **-82,47** | **-90,86** |
| It-7 | 100 | 53,77 | 81,65 | 141,68 | 141,54 | 6,40 |
| St - 7 | 0 | **-46,23** | **-18,35** | **41,68** | **41,54** | **-93,60** |

Po baznim indeksima na tablici iznad zaključujemo da je na diplomskom studiju 2013. godine bilo značajnije više studenata nego 2008. godine. Također značajnije zaključujemo da je na poslijediplomskom sveučilišnom znanstvenom studiju 2013. godine bilo značajnije manje studenata nego 2008. godine što se slabije vidjelo na ranije prikazanom grafu.

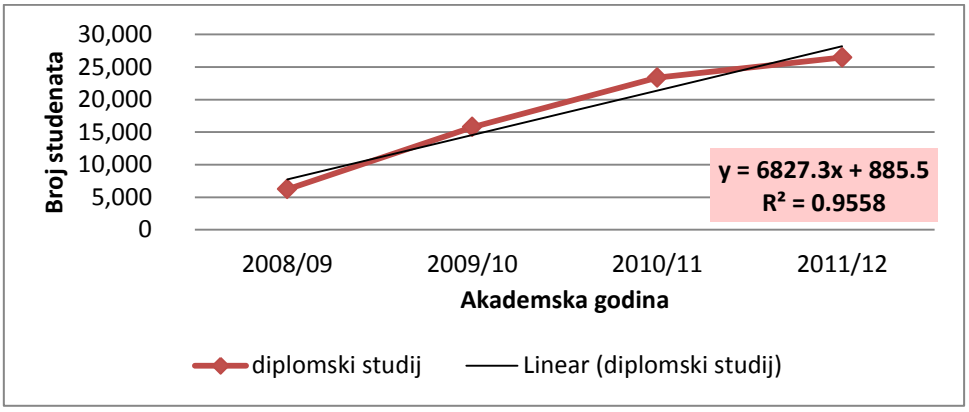
### 3.2.2.2. Trendovi broja studenata po vrstama sveučilišnih studija

U ovom poglavlju su izračunati linearni i eksponencijalni trendovi broja studenata po vrstama sveučilišnih studija. Promatrana su razdoblja koja daju prikladan koeficijent determinacije. Podaci za poslijediplomski sveučilišni studij i za poslijediplomski sveučilišni znanstveni studij nisu nikako reprezentativni, stoga su izostavljeni. Sljedeći graf prikazuje linearni trend broja studenata preddiplomskog studija.



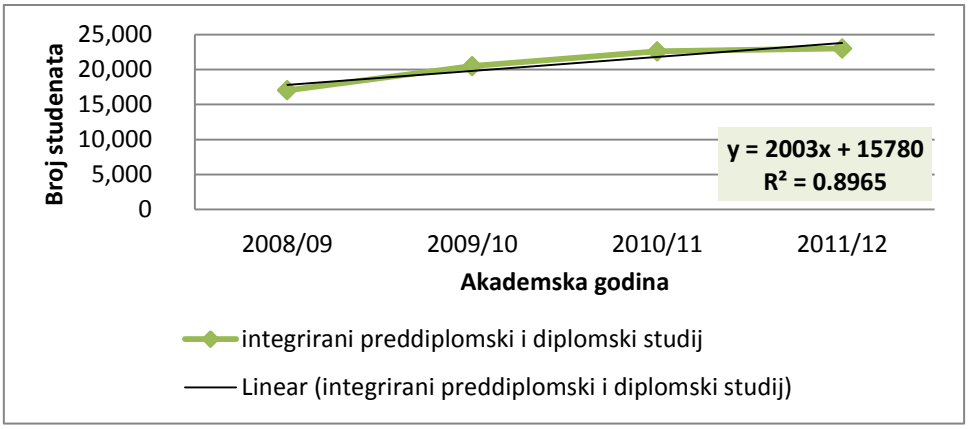

Slika 30: Linearni trend preddiplomskog studija

Očekivana vrijednost za broj upisanih studenata 2008/09 ak. godine je **63100**. U promatranom razdoblju broj upisanih studenata se prosječno godišnje povećavao za **442,3**. U promatranom razdoblju broj upisanih studenata prediplomskog studija se prosječno godišnje povećavao za **0,63%**. Sljedeći graf prikazuje linearni trend broja studenata diplomskog studija.



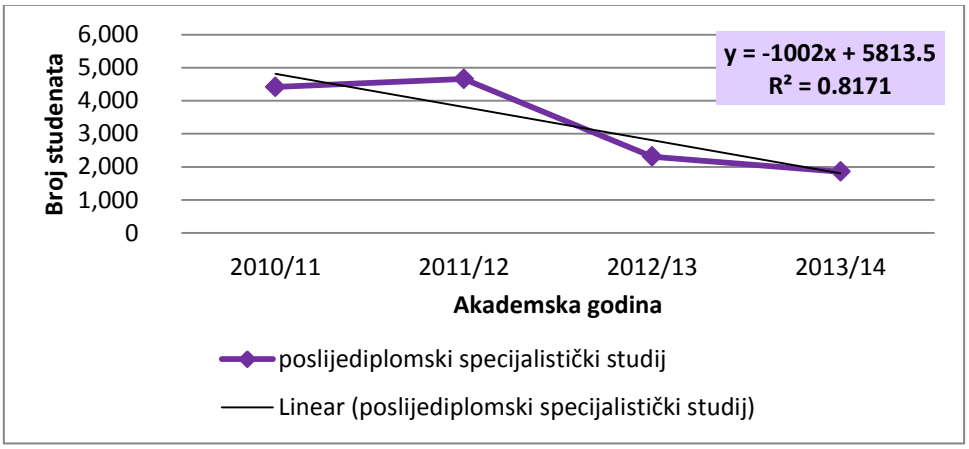

Slika 31: Linearni trend studenata diplomskog studija

Očekivana vrijednost za broj upisanih studenata na 2008/09 ak. godine je **885,5**. U promatranom razdoblju broj upisanih studenata se prosječno godišnje povećavao za **6827,3**. U promatranom razdoblju broj upisanih studenata diplomskog studija se prosječno godišnje povećavao za **61,97%**. Sljedeći graf na sljedećoj strani prikazuje linearni trend broja studenata integriranog preddiplomskog i diplomskog studija.



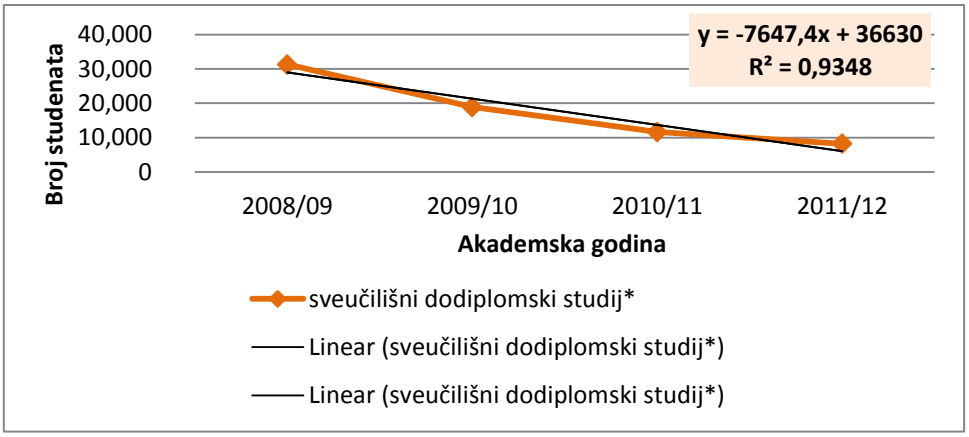

Slika 32: Linearni trend studenata integriranog preddiplomskog i diplomskog studija

Očekivana vrijednost za broj upisanih studenata 2008/09 ak. godine je **15780**. U promatranom razdoblju broj upisanih studenata se prosječno godišnje povećavao za **2003**. U promatranom razdoblju broj upisanih studenata integriranog preddiplomskog i diplomskog studija se prosječno godišnje povećavao za **10,54%**. Promatrano razdoblje na slici iznad se malo razlikuje od drugih grafova u ovom poglavlju radi jače reprezentativnosti. Sljedeći graf prikazuje linearni trend broja studenata poslijediplomskog specijalističkog studija.




Slika 33: Linearni trend studenata poslijediplomskog specijalističkog studija

Očekivana vrijednost za broj upisanih studenata 2010/11 ak. godine je **5813,5**. U promatranom razdoblju broj upisanih studenata se prosječno godišnje smanjivao za **1002**. promatranom razdoblju broj upisanih studenata poslijediplomskog specijalističkog studija se prosječno godišnje povećavao za **4,94%**. Sljedeći graf prikazuje linearni trend broja studenata sveučilišnog dodiplomskog studija.



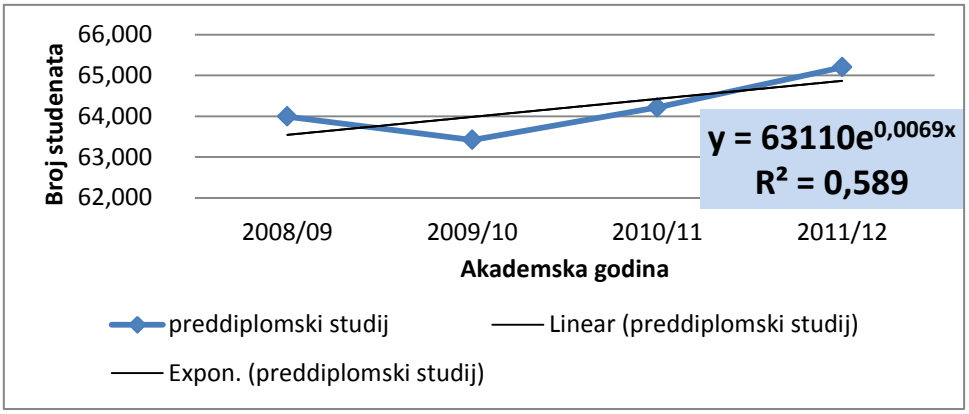

Slika 34: Linearni trend studenata sveučilišnog dodiplomskog studija

Očekivana vrijednost za broj upisanih studenata 2008/09 ak. godine je **36630**. U promatranom razdoblju broj upisanih studenata se prosječno godišnje smanjivao za **7647,4**. U promatranom razdoblju broj upisanih studenata sveučilišnog dodiplomskog studija se prosječno godišnje smanjivao za **35,94%**. Sljedeća tablica prikazuje prognoziranje broja studenata linearnim trendom po vrstama sveučilišnih studija koristeći funkciju 'trend'.

Tablica 23: Prognoziranje studenata linearnim trendom po vrstama sveučilišnih studija

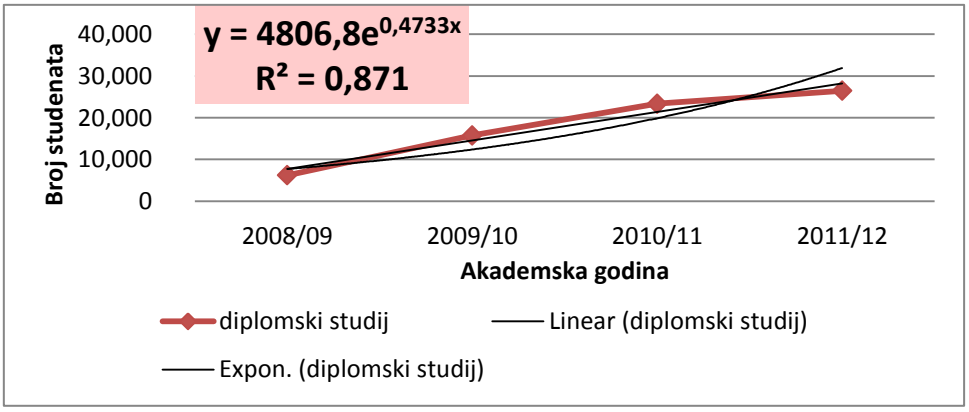
| Vrsta sveučilišnog studija | 2012/13 | 2013/14 | 2014/15 | 2015/16 | 2016/17 | 2017/18 | 2018/19 |
|---|---|---|---|---|---|---|---|
| preddiplomski | 65.312 | 65.754 | 66196 | 66638 | 67081 | 67523 | 67965 |
| diplomski | 35.022 | 41.849 | 48677 | 55504 | 62331 | 69159 | 75986 |
| integrirani preddiplomski i diplomski | 25.795 | 27.798 | 29801 | 31804 | 33807 | 35810 | 37813 |
| poslijediplomski specijalistički | 4.848 | 5.140 | 5433 | 5725 | 6017 | 6310 | 6602 |
| poslijediplomski sveučilišni | 5.261 | 5.307 | 5353 | 5399 | 5445 | 5491 | 5536 |
| sveučilišni dodiplomski* | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| poslijediplomski sveučilišni znanstveni* | 932 | 1.039 | 1147 | 1254 | 1362 | 1469 | 1577 |

Negativni brojevi u tablici na prethodnoj strani su zamijenjeni s nulom jer se u takvih slučajevima prognozira da neće biti studenata. Sljedeći graf prikazuje trend broja studenata sveučilišnog preddiplomskog studija i dobivenu eksponencijalnu formulu.



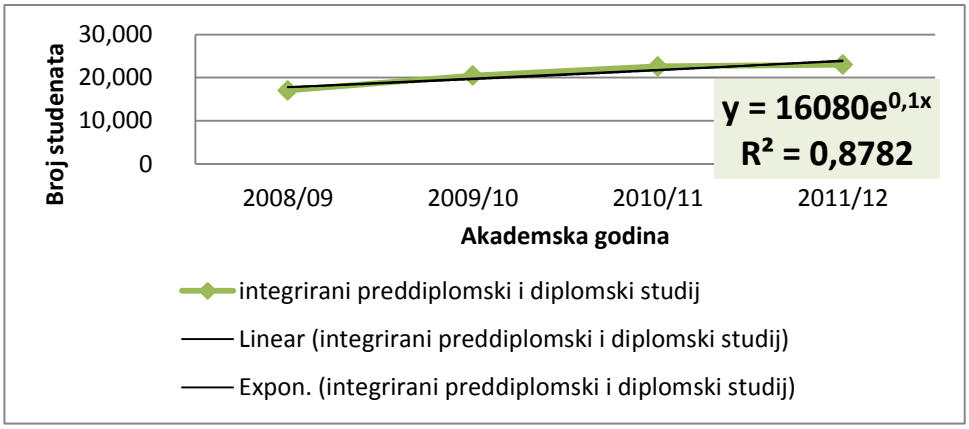

Slika 35: Trend studenata preddiplomskog studija i eksponencijalna formula

Očekivana vrijednost za broj upisanih studenata 2008/09 ak. godine je **63110**. U promatranom razdoblju broj upisanih studenata se prosječno godišnje povećavao za **0,69%**. Sljedeći graf prikazuje trend broja studenata diplomskog studija i dobivenu eksponencijalnu formulu.



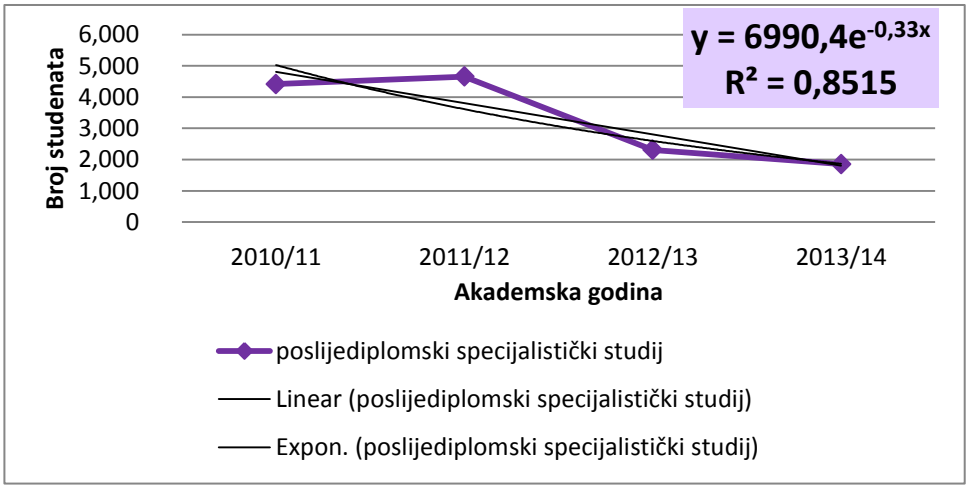

Slika 36: Trend studenata diplomskog studija i eksponencijalna formula

Očekivana vrijednost za broj upisanih studenata 2008/09 ak. godine je **4806,8**. U promatranom razdoblju broj upisanih studenata se prosječno godišnje povećavao za **60,52%**. Sljedeći graf prikazuje trend broja studenata integriranog preddiplomskog i diplomskog studija i dobivenu eksponencijalnu formulu.



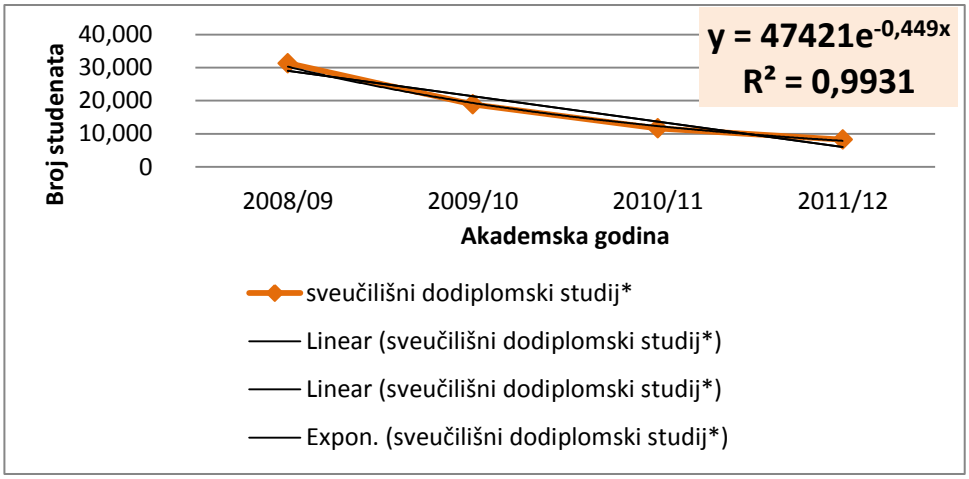

Slika 37: Eksponencijalni trend studenata integriranog preddiplomskog i diplomskog studija

Očekivana vrijednost za broj upisanih studenata 2008/09 ak. godine je **16080**. U promatranom razdoblju broj upisanih studenata se prosječno godišnje povećavao za **10,51%**. Sljedeći graf prikazuje trend broja studenata poslijediplomskog specijalističkog studija i dobivenu eksponencijalnu formulu.




Slika 38: Eksponencijalni trend studenata poslijediplomskog specijalističkog studija

Očekivana vrijednost za broj upisanih studenata 2010/11 ak. godine je **6990,4**. U promatranom razdoblju broj upisanih studenata se prosječno godišnje smanjivao za **28,1%**. Sljedeći graf prikazuje trend broja studenata sveučilišnog dodiplomskog studija i dobivenu eksponencijalnu formulu.




Slika 39: Trend studenata sveučilišnog dodiplomskog studija i eksponencijalna formula

Očekivana vrijednost za broj upisanih studenata 2008/09 ak. godine je **47421**. U promatranom razdoblju broj upisanih studenata se prosječno godišnje smanjivao za **36,17%**. Sljedeća tablica prikazuje prognoziranje broja studenata eksponencijalnim trendom po vrstama sveučilišnih studija koristeći funkciju 'growth' u uredskom alatu Excel.

Tablica 24: Prognoziranje studenata eksponencijalnim trendom sveučilišnih studija

| Vrsta sveučilišnog studija | 2012/13 | 2013/14 | 2014/15 | 2015/16 | 2016/17 | 2017/18 | 2018/19 |
|---|---|---|---|---|---|---|---|
| preddiplomski | 65.314 | 65.763 | 66216 | 66672 | 67131 | 67593 | 68059 |
| diplomski | 51.248 | 82.270 | 132070 | 212016 | 340355 | 546382 | 877122 |
| integrirani preddiplomski i diplomski | 26.505 | 29.292 | 32371 | 35774 | 39534 | 43690 | 48283 |
| poslijediplomski specijalistički | 4.873 | 5.228 | 5609 | 6018 | 6456 | 6926 | 7431 |
| poslijediplomski sveučilišni | 5.237 | 5.280 | 5324 | 5368 | 5413 | 5458 | 5503 |
| sveučilišni dodiplomski* | 5.015 | 3.200 | 2042 | 1303 | 831 | 530 | 338 |
| poslijediplomski sveučilišni znanstveni* | 900 | 1.042 | 1206 | 1396 | 1616 | 1870 | 2165 |

Prognozirani broj studenata preddiplomskog studija prema eksponencijalnoj formuli za 2018/19. ak. godinu je 67618.

## 3.3. Korelacija broja studenata po poljima i područjima

U ovom poglavlju ispitana je korelacija broja studenata po znanstvenim poljima i područjima. Korelacija broja studenata po poljima i područjima znači da rast ili pad broja studenata na jednom polju ili području prati rast ili pad broja studenata na nekom drugom polju ili području. Korelacija je objašnjena u poglavlju 2.3, a u ovom poglavlju se te spoznaje primjenjuju. Vrijednost korelacije može biti između -1 i 1. Korelacija može biti negativna, pozitivna, a ako je nula, onda nema korelacije. Korelacija između -0,2 i 0,2 je neznatna jer je blizu nule. Za ispitivanje korelacije u uredskom alatu Excel, korištena je funkcija 'pearson'. Slične rezultate moguće je dobiti korištenjem drugih funkcija kao što je 'correl'.

### 3.3.1. Korelacija za javna visoka učilišta

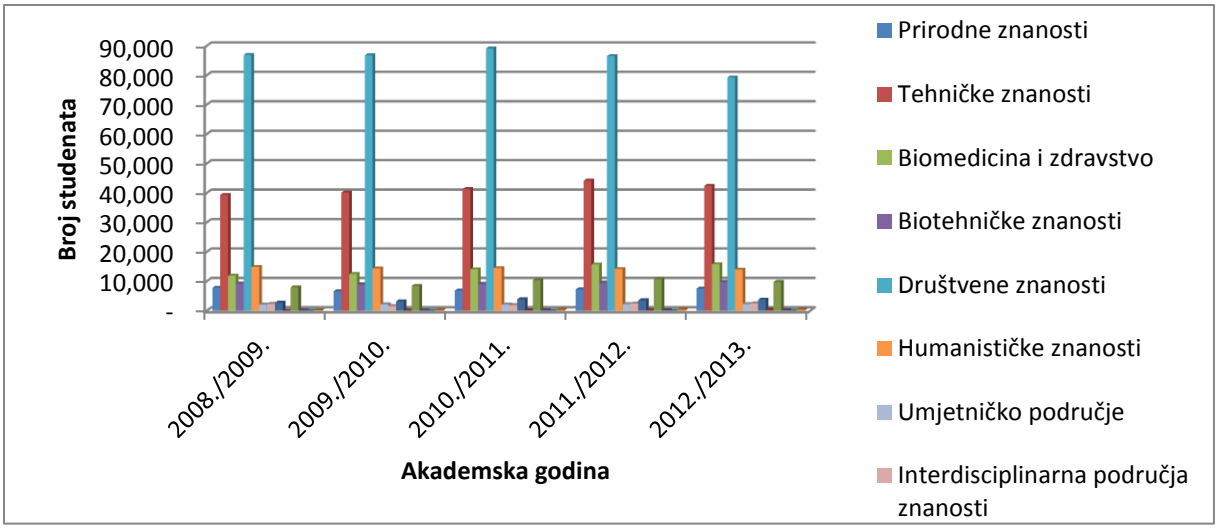
Sljedeća tablica prikazuje brojeve studenata po znanstvenim područjima od 2008/09 do 2012/13 ak. godine na javnim visokim učilištima.

Tablica 25: Broj studenata po znanstvenim područjima javnih visokih učilišta

| Znanstveno područje | 2008/09 | 2009/10 | 2010/11 | 2011/12 | 2012/13 |
|---|---|---|---|---|---|
| Prirodne znanosti | 7.779 | 6.650 | 6.863 | 7.291 | 7.531 |
| Tehničke znanosti | 39.361 | 40.168 | 41.347 | 44.192 | 42.442 |
| Biomedicina i zdravstvo | 11.921 | 12.480 | 14.092 | 15.729 | 15.818 |
| Biotehničke znanosti | 9.246 | 8.977 | 9.146 | 9.542 | 9.805 |
| Društvene znanosti | 86.925 | 86.792 | 89.089 | 86.539 | 79.249 |
| Humanističke znanosti | 14.889 | 14.350 | 14.467 | 14.138 | 13.983 |
| Umjetničko područje | 2.096 | 2.194 | 2.115 | 2.254 | 2.253 |
| Interdisciplinarna područja znanosti | 2.359 | 1.616 | 1.924 | 2.469 | 2.510 |
| **Ukupno** | **174.576** | **173.227** | **179.043** | **182.154** | **173.591** |

(Izvor: Portal otvorenih podataka Republike Hrvatske, 2019)

Sljedeća slika na sljedećoj strani prikazuje graf na temelju tablice iznad.




Slika 40: Broj studenata po znanstvenim područjima na javnim visokim učilištima (Izvor: Portal otvorenih podataka Republike Hrvatske, 2019)

Ispitivanjem korelacije broja studenata svakog područja s brojem studenata svakog područja dobiveni su sljedeći rezultati kako je prikazano u sljedeće dvije tablice.

Tablica 26: Rezultati ispitivanja korelacija na javnim visokim učilištima – dio 1/2

| Znanstveno područje ispod s kojim je uspoređeno područje desno | Prirodne znanosti | Tehničke znanosti | Biomedicina i zdravstvo | Biotehničke znanosti |
|---|---|---|---|---|
| Tehničke znanosti | 0,03 | | | |
| Biomedicina i zdravstvo | 0,11 | **0,94** | | |
| Biotehničke znanosti | **0,62** | **0,67** | **0,81** | |
| Društvene znanosti | **-0,44** | -0,29 | **-0,52** | **-0,81** |
| Humanističke znanosti | **0,20** | **-0,79** | **-0,86** | **-0,63** |
| Umjetničko područje | -0,03 | **0,77** | **0,76** | **0,65** |
| Interdisciplinarna područja znanosti | **0,88** | 0,50 | **0,56** | **0,87** |

Iz tablice iznad zaključujemo kako slijedi u nastavku. Broj studenata prirodnih znanosti je u korelaciji s porastom broja studenata biotehničkih znanost i interdisciplinarnih područja, a padom broja studenata društvenih znanosti. Broj studenata tehničkih znanosti u korelaciji je s porastom broja studenata biomedicine, biotehničkih znanosti i umjetničkog područja, a padom broja studenata humanističkih znanosti. Broj studenata medicine i zdravstva je u korelaciji s porastom broja studenata biotehničkih znanosti, umjetničkog i interdisciplinarnog područja, a padom društvenih i humanističkih znanosti. Broj studenata biotehničkih znanosti je u korelaciji s porastom broja studenata umjetničkog područja i interdisciplinarnog područja znanosti, a padom broja studenata društvenih i humanističkih

znanosti. Sljedeća tablica prikazuje rezultate ispitivanja korelacije koji nisu stali u prethodnoj tablici.

Tablica 27: Rezultati ispitivanja korelacija na javnim visokim učilištima – dio 2/2

| Znanstveno područje ispod s kojim je uspoređeno područje desno | Društvene znanosti | Humanističke znanosti | Umjetničko područje |
|---|---|---|---|
| Humanističke znanosti | **0,62** | | |
| Umjetničko područje | **-0,64** | **-0,92** | |
| Interdisciplinarna područja znanosti | **-0,54** | **-0,21** | 0,34 |

Iz tablice iznad zaključujemo kako slijedi u nastavku. Broj studenata društvenih znanosti je u korelaciji s porastom broja studenata humanističkih znanosti, a padom broja studenata umjetničkog područja i interdisciplinarnih područja znanosti. Broj studenata humanističkih znanosti je u korelaciji s padom broja studenata umjetničkog područja i interdisciplinarnog područja znanosti. Broj studenata umjetničkog područja je u korelaciji s porastom broja studenata interdisciplinarnog područja znanosti.

## 3.3.2. Korelacija za privatna visoka učilišta

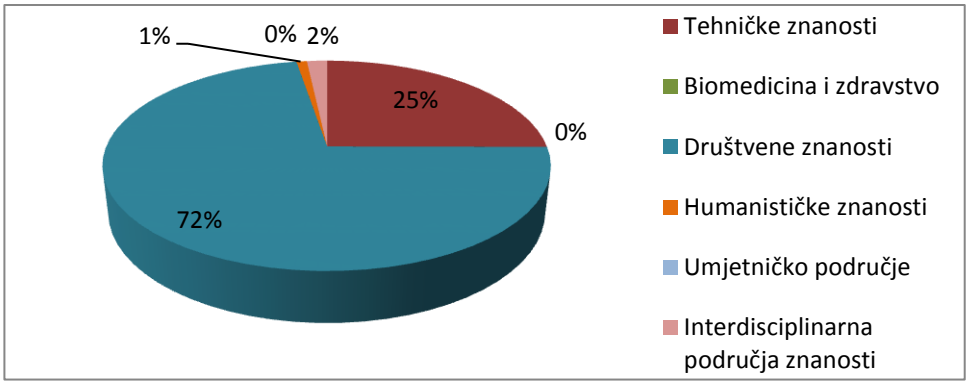
Sljedeća tablica prikazuje brojeve studenata po znanstvenim područjima od 2008/09 do 2012/13 ak. godine na privatnim visokim učilištima.

Tablica 28: Broj studenata po znanstvenim područjima privatnih visokih učilišta

| Znanstveno područje | 2008/09 | 2009/10 | 2010/11 | 2011/12 | 2012/13 |
|---|---|---|---|---|---|
| Tehničke znanosti | 2.763 | 3.189 | 3.902 | 3.562 | 3.767 |
| Biomedicina i zdravstvo | 0 | 53 | 162 | 246 | 375 |
| Društvene znanosti | 7.969 | 8.454 | 10.428 | 10.749 | 9.789 |
| Humanističke znanosti | 98 | 109 | 136 | 155 | 199 |
| Umjetničko područje | 0 | 0 | 0 | 0 | 35 |
| Interdisciplinarna područja znanosti | 192 | 275 | 380 | 552 | 529 |
| **Ukupno** | **11.022** | **12.080** | **15.008** | **15.264** | **14.694** |

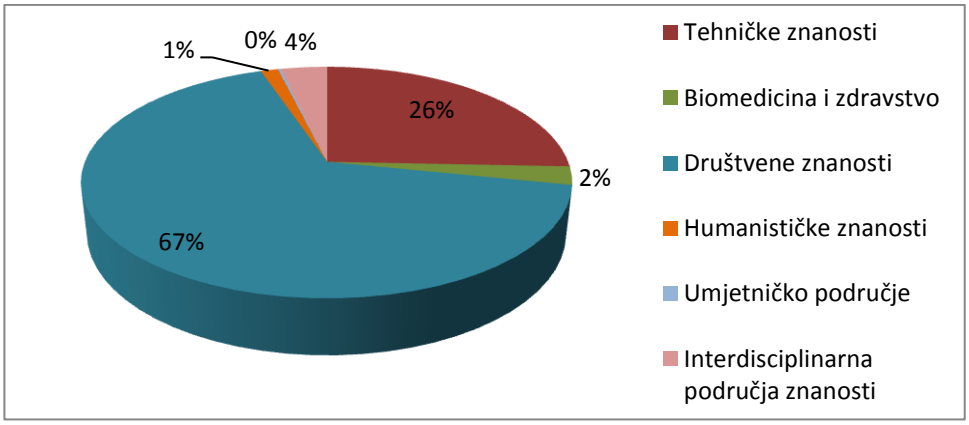
(Izvor: Portal otvorenih podataka Republike Hrvatske, 2019)

Sljedeća slika na sljedećoj strani prikazuje broj studenata po znanstvenim područjima na privatnim visokim učilištima 2008/09 ak. godine.




Slika 41: Broj studenata na privatnim visokim učilištima u 2008/09 ak. godini

Sljedeća slika na sljedećoj strani prikazuje broj studenata po znanstvenim područjima na privatnim visokim učilištima 2012/13 ak. godine.




Slika 42: Broj studenata na privatnim visokim učilištima u 2012/13 ak. godini

Ispitivanjem korelacije dobiveni su sljedeći rezultati na sljedeće dvije tablice.

Tablica 29: Rezultati ispitivanja korelacija na privatnim visokim učilištima – dio 1/2

| Znanstveno područje ispod s kojim je uspoređeno područje desno | Tehničke znanosti | Biomedicina i zdravstvo | Društvene znanosti |
|---|---|---|---|
| Biomedicina i zdravstvo | **0,78** | | |
| Društvene znanosti | **0,88** | **0,72** | |
| Humanističke znanosti | **0,75** | **1,00** | **0,66** |
| Umjetničko područje | **0,40** | **0,77** | 0,14 |
| Interdisciplinarna područja znanosti | **0,77** | **0,93** | **0,86** |

Iz prethodne tablice na prethodnoj strani zaključujemo kako slijedi u nastavku. Broj studenata tehničkih znanosti je u korelaciji s porastom broja studenata na svim ostalim znanstvenim područjima. Broj studenata medicine i zdravstva je u korelaciji s porastom broja studenata na svim ostalim znanstvenim područjima te u korelaciji 100% s porastom broja studenata humanističkih znanosti. Broj studenata društvenih znanosti je u korelaciji s porastom broja studenata humanističkih i interdisciplinarnih područja znanosti. Čest porast u korelacijama znači da su brojevi studenata sve veći što je točno prema podacima iz ranije prikazane tablice prema Portalu otvorenih podataka. Sljedeća tablica prikazuje rezultate ispitivanja korelacije koji nisu stali u prethodnoj tablici.

Tablica 30: Rezultati ispitivanja korelacija na privatnim visokim učilištima – dio 2/2

| Znanstveno područje ispod s kojim je uspoređeno područje desno | Humanističke znanosti | Umjetničko područje |
|---|---|---|
| Umjetničko područje | **0,83** | |
| Interdisciplinarna područja znanosti | **0,90** | **0,51** |

Iz prethodne tablice zaključujemo kako slijedi u nastavku. Broj studenata humanističkih znanosti je u korelaciji s porastom broja studenata umjetničkog područja i interdisciplinarnih područja znanosti. Broj studenata umjetničkog područja je u korelaciji s porastom broja studenata interdisciplinarnih područja znanosti.

# 4. Zaključak

Statistika je primjena matematike za analizu podataka. U ovom radu su korištene formule za izračun verižnih indeksa, indeksa na stalnoj bazi, linearni trend i eksponencijalni trend te su uz ove formule navedene još neke. U provedenom primjeru statističke analize, dobiveni rezultati prognoziranja su uglavnom točni (što se vidi po akademskim godinama 2012/13 i 2013/14), ali ne možemo očekivati da će se broj studenata povećavati kao što to pokazuju dobiveni linearni i eksponencijalni trendovi jer postoje ograničenja kao što su upisne kvote i broj stanovnika koji bi mogao studirati. Dakle, prognoza na temelju trendova nije uvijek ostvariva, najviše zbog ograničenja nekim drugim statističkim podacima. Ispitivanjem korelacija su dobivene sljedeće jače korelacije. U korelaciji na javnim visokim učilištima su broj studenata na umjetničkom području s padom broja studenata humanističkih znanosti (-0,92) i broj studenata biomedicine i zdravstva s porastom broja studenata tehničkih znanosti (0,94). U korelaciji na privatnim visokim učilištima su broj studenata interdisciplinarnih područja znanosti s porastom broja studenata biomedicine i zdravstva (0,93) i broj studenata interdisciplinarnih područja znanosti s porastom broja studenata humanističkih znanosti (0,90).

# Popis literature


[1] I. Šošić, Serdar, (1981). "Uvod u statistiku", Školska knjiga, Zagreb

[2] V. Čuljak (2005) "Matematička statistika", *Građevinski fakultet sveučilišta u Zagrebu*. Dostupno: http://www.grad.hr/vera/webnastava/vjerojatnostistatistika/html/VISch11.html [Pristupano 23.02.2019.].

[3] K. Kero, J. Dobša, B. Bojanić-Glavica. (2008). "Statistika (deskriptivna i inferencijalna) i vjerojatnost", Varteks d.o.o., Varaždin

[4] P. Newbold, W. L. Carlson, B. M. Thorne. (2010). "Statistika za poslovanje i ekonomiju", Mate d.o.o. i Zagrebačka škola ekonomije i menadžmenta, Zagreb

[5] B. Petz, V. Kolesarić, D. Ivanec (2012) "Petzova statistika", Naklada slap, Zagreb

[6] s.n. (2019) "Korelacija", *Hrvatska Wikipedija*. Dostupno: https://hr.wikipedia.org/wiki/Korelacija [Pristupano 14.03.2019.]

[7] Vlada Republike Hrvatske (2019) "Broj studenata", *Portal otvorenih podataka Republike Hrvatske*. Dostupno: https://data.gov.hr/dataset/broj-studenata [Pristupano 20.12.2018.].

# Popis slika

Slika 1: Podjela studenata po tipu studija ..... 11
Slika 2: Broj studenata po tipu studija ..... 14
Slika 3: Trend broja studenata stručnih studija od 2008. do 2012. godine ..... 15
Slika 4: Trend broja studenata sveučilišnih studija od 2008. do 2012. godine ..... 15
Slika 5: Trend studenata stručnih studija s eksponencijalnom jednadžbom ..... 17
Slika 6: Trend studenata sveučilišnih studija s eksponencijalnom jednadžbom ..... 18
Slika 7: Broj studenata na stručnom studiju po tipu visokih učilišta ..... 19
Slika 8: Linearni trend studenata na javnim učilištima stručnih studija ..... 21
Slika 9: Linearni trend studenata na privatnim učilištima stručnih studija ..... 21
Slika 10: Eksponencijalni trend studenata na javnim učilištima stručnih studija ..... 22
Slika 11: Eksponencijalni trend studenata na privatnim učilištima stručnih studija ..... 22
Slika 12: Broj studenata na javnim učilištima sveučilišnih studija ..... 23
Slika 13: Broj studenata na privatnim učilištima sveučilišnih studija ..... 23
Slika 14: Linearni trend studenata na javnim učilištima sveučilišnih studija ..... 25
Slika 15: Linearni trend studenata na privatnim učilištima sveučilišnih studija ..... 25
Slika 16: Eksponencijalni trend studenata na javnim učilištima sveučilišnih studija ..... 26
Slika 17: Eksponencijalni trend studenata na privatnim učilištima sveučilišnih studija ..... 27
Slika 18: Broj studenata prediplomskog stručnog studija ..... 28
Slika 19: Broj studenata po vrsti stručnih studija ..... 29
Slika 20: Broj studenata po vrsti stručnih studija ..... 29
Slika 21: Linearni trend broja studenata prediplomskog stručnog studija ..... 32
Slika 22: Linearni trend broja specijalističkog diplomskog stručnog studija ..... 32
Slika 23: Linearni trend broja studenata stručnog dodiplomskog studija ..... 33
Slika 24: Linearni trend broja studenata poslijediplomskog stručnog studija ..... 33
Slika 25: Eksponencijalni trend broja studenata prediplomskog stručnog studija ..... 34
Slika 26: Eksponencijalni trend broja studenata specijalističkog diplomskog stručnog studija ..... 35
Slika 27: Eksponencijalni trend broja studenata stručnog dodiplomskog studija ..... 35
Slika 28: Broj studenata preddiplomskog sveučilišnog studija ..... 36
Slika 29: Broj studenata sveučilišnog studija po vrsti studija ..... 37
Slika 30: Linearni trend preddiplomskog studija ..... 40
Slika 31: Linearni trend studenata diplomskog studija ..... 40
Slika 32: Linearni trend studenata integriranog preddiplomskog i diplomskog studija ..... 41
Slika 33: Linearni trend studenata poslijediplomskog specijalističkog studija ..... 41
Slika 34: Linearni trend studenata sveučilišnog dodiplomskog studija ..... 42
Slika 35: Trend studenata preddiplomskog studija i eksponencijalna formula ..... 43
Slika 36: Trend studenata diplomskog studija i eksponencijalna formula ..... 43

Slika 37: Eksponencijalni trend studenata integriranog preddiplomskog i diplomskog studija....44
Slika 38: Eksponencijalni trend studenata poslijediplomskog specijalističkog studija....44
Slika 39: Trend studenata sveučilišnog dodiplomskog studija i eksponencijalna formula....45
Slika 40: Broj studenata po znanstvenim područjima na javnim visokim učilištima....47
Slika 41: Broj studenata na privatnim visokim učilištima u 2008/09 ak. godini....49
Slika 42: Broj studenata na privatnim visokim učilištima u 2012/13 ak. godini....49

# Popis tablica

Tablica 1: Broj upisanih studenata po akademskim godinama i tipu studija .....10
Tablica 2: Verižni indeksi po tipu studija .....12
Tablica 3: Bazni indeksi po tipu studija .....13
Tablica 4: Prognoziranje broja studenata na temelju linearnog trenda po tipu studija .....16
Tablica 5: Usporedba stvarnog i prognoziranog broja studenata po tipu studija .....17
Tablica 6: Prognoziranje studenata na temelju eksponencijalnog trenda po tipu studija .....19
Tablica 7: Verižni indeksi studenata na stručnom studiju po visokim učilištima.....20
Tablica 8: Bazni indeksi studenata na stručnom studiju po visokim učilištima.....20
Tablica 9: Prognoziranje studenata na stručnim studijima na temelju linearnog trenda.....22
Tablica 10: Prognoziranje studenata na stručnim studijima – eksponencijalni trend .....23
Tablica 11: Verižni indeksi studenata na sveučilišnom studiju po visokim učilištima .....24
Tablica 12: Bazni indeksi studenata na sveučilišnom studiju po visokim učilištima .....24
Tablica 13: Prognoziranje studenata na sveučilišnim studijima na temelju linearnog trenda.26
Tablica 14: Prognoziranje studenata na sveučilišnim studijima – eksponencijalni trend.....27
Tablica 15: Broj studenata po vrsti studija .....27
Tablica 16: Verižni indeksi studenata raspoređenih stručnih studija po vrsti studija.....30
Tablica 17: Bazni indeksi studenata raspoređenih stručnih studija po vrsti studija.....31
Tablica 18: Prognoziranje studenata linearnim trendom po vrstama stručnih studija .....34
Tablica 19: Prognoziranje studenata eksponencijalnim trendom po vrstama stručnih studija36
Tablica 20: Verižni indeksi broja studenata po vrstama sveučilišnih studija .....37
Tablica 21: Prosječne godišnje stope temeljem verižnih indeksa broja studenata po vrstama sveučilišnih studija.....38
Tablica 22: Bazni indeksi broja studenata po vrstama sveučilišnih studija .....39
Tablica 23: Prognoziranje studenata linearnim trendom po vrstama sveučilišnih studija.....42
Tablica 24: Prognoziranje studenata eksponencijalnim trendom sveučilišnih studija .....45
Tablica 25: Broj studenata po znanstvenim područjima javnih visokih učilišta .....46
Tablica 26: Rezultati ispitivanja korelacija na javnim visokim učilištima – dio 1/2.....47
Tablica 27: Rezultati ispitivanja korelacija na javnim visokim učilištima – dio 2/2.....48
Tablica 28: Broj studenata po znanstvenim područjima privatnih visokih učilišta .....48
Tablica 29: Rezultati ispitivanja korelacija na privatnim visokim učilištima – dio 1/2.....49
Tablica 30: Rezultati ispitivanja korelacija na privatnim visokim učilištima – dio 2/2.....50