Model procjene troškova održavanja i uporabe građevina na primjeru građevina Sveučilišta Josipa Jurja Strossmayera u Osijeku

Krstić, Hrvoje

Doctoral thesis / Disertacija

2011

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Civil Engineering and Architecture Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Građevinski i arhitektonski fakultet Osijek**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:133:865357

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

GRAĐEVINSKI I ARHITEKTONSKI FAKULTET OSIJEK
Faculty of Civil Engineering and Architecture Osijek

Repository / Repozitorij:

Repository GrAFOS - Repository of Faculty of Civil Engineering and Architecture Osijek

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
GRAĐEVINSKI FAKULTET OSIJEK

Hrvoje Krstić

MODEL PROCJENE TROŠKOVA ODRŽAVANJA I UPORABE GRAĐEVINA NA PRIMJERU GRAĐEVINA SVEUČILIŠTA JOSIPA JURJA STROSSMAYERA U OSIJEKU

Doktorski rad

Osijek, 2011.

DOKTORSKI RAD

MODEL PROCJENE TROŠKOVA ODRŽAVANJA I UPORABE GRAĐEVINA NA PRIMJERU GRAĐEVINA SVEUČILIŠTA JOSIPA JURJA STROSSMAYERA U OSIJEKU

PODACI O AUTORU

Ime i prezime:	**dr.sc. Hrvoje Krstić**, dipl.ing.građ.
Mjesto i godina rođenja:	Vinkovci, 1981.
Diplomirao:	Sveučilište Josipa Jurja Strossmayera u Osijeku, Građevinski fakultet Osijek , 2005.,
Zaposlen:	Sveučilište Josipa Jurja Strossmayera u Osijeku, Građevinski fakultet Osijek

PODACI O DOKTORSKOM RADU:

Znanstveno područje:	Tehničke znanosti
Znanstveno polje:	Građevinarstvo
Znanstvena grana:	Organizacija i tehnologija građenja
Mentor:	prof.dr.sc. Saša Marenjak

POSTUPAK OCJENE I OBRANA:

Prijava teme:	veljača 2011.
Povjerenstvo za ocjenu:	prof.dr.sc. Ivica Završki, predsjednik, prof.dr.sc. Saša Marenjak, mentor i član i prof.dr.sc. Ksenija Čulo, član
Povjerenstvo za obranu:	prof.dr.sc. Ivica Završki, predsjednik, prof.dr.sc. Saša Marenjak, mentor i član, prof.dr.sc. Ksenija Čulo, član, prof.dr.sc. Petar Brana, član i doc.dr.sc. Zlata Dolaček-Alduk,član
Mjesto i datum obrane:	Građevinski fakultet Osijek, 23. studeni 2011.

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
GRAĐEVINSKI FAKULTET OSIJEK

Hrvoje Krstić

MODEL PROCJENE TROŠKOVA ODRŽAVANJA I UPORABE GRAĐEVINA NA PRIMJERU GRAĐEVINA SVEUČILIŠTA JOSIPA JURJA STROSSMAYERA U OSIJEKU

Doktorski rad

Osijek, 2011.

Mentor rada: prof.dr.sc. Saša Marenjak, dipl.ing.građ.

Doktorski rad ima 268 listova

ŽIVOTOPIS

Hrvoje Krstić rođen je 27. svibnja 1981. godine u Vinkovcima, Republika Hrvatska. Osnovnu i srednju školu završio je u Vinkovcima. Maturirao je s odličnim uspjehom 1999. godine u Gimnaziji „Matija Antun Reljković“, opći smjer. Iste je godine upisao sveučilišni dodiplomski studij Građevinskog fakulteta Osijek, Sveučilišta J. J. Strossmayera u Osijeku, kojeg je završio 27. listopada 2005. godine s izvrsnim uspjehom te stekao visoku stručnu spremu i stručno zvanje diplomiranog inženjera građevinarstva.

Od siječnja 2006. godine zaposlen je na suradničkom mjestu asistenta na Građevinskom fakultetu u Osijeku. Na radnom mjestu asistenta obavlja poslove područja rada koje obuhvaća nastavnu, znanstveno-istraživačku i stručnu djelatnost. Iste godine upisao je poslijediplomski doktorski studij Građevinskog fakulteta u Osijeku.

Član je Udruge diplomiranih inženjera Građevinskog fakulteta Sveučilišta Josipa Jurja Strossmayera u Osijeku i Hrvatske udruge za organizaciju građenja.

Od akademske godine 2005/06 sudjeluje u nastavi i obavlja poslove održavanja vježbi na sveučilišnom diplomskom studiju iz predmeta *Upravljanje projektima*, *Procesi planiranja i kontrole građenja*, *Ponude i ugovori, Organizacija građenja* i *Održavanje građevina*, i na stručnom studiju iz predmeta *Organizacija građenja.* Od akademske godine 2011/12 sudjeluje u nastavi i obavlja poslove održavanja vježbi na stručnom specijalističkom studiju iz predmeta *Ugovori u graditeljstvu* i *Cjeloživotna eksploatacija i održavanje građevina*.

SAŽETAK

Model procjene troškova održavanja i uporabe građevina na primjeru građevina Sveučilišta Josipa Jurja Strossmayera u Osijeku

U radu se istražuje mogućnost prikupljanja podataka i informacija o karakteristikama građevina i načinima uporabe građevina Sveučilišta Josipa Jurja Strossmayera u Osijeku, kao i o troškovima održavanja i uporabe navedenih građevina. Podatci su prikupljani pomoću upitnika koji su poslani svim sastavnicama Sveučilišta u Osijeku, a traženi su opći podatci o uporabi i karakteristikama građevine i podatci o troškovima održavanja i uporabe građevina prema unaprijed definiranoj strukturi troškova. Rezultat prikupljanja i obrade navedenih podataka i informacija je stvaranje baze podataka o troškovima održavanja i uporabe građevina Sveučilišta koja se temelji na prikupljenim podatcima o povijesnim troškovima građevina iste ili slične funkcionalne namjene. Analiziranje takve baze podataka omogućilo je u ovome radu i razvoj modela predviđanja troškova održavanja i uporabe građevina i troškova uporabe građevina Sveučilišta u Osijeku te utvrđivanja utjecaja pojedinih karakteristika građevina, odnosno varijabli modela na troškove održavanja i uporabe građevina. Istraživanjem je utvrđeno kako je moguće stvaranje matematičkog modela predviđanja troškova održavanja i uporabe javnih građevina visokogradnje za potrebe znanstveno obrazovnih ustanova Sveučilišta u Osijeku uporabom statističkih metoda. Utvrđena je mogućnost primjene višestruke regresijske analize pri izradi modela procjene troškova održavanja i uporabe, kao i primjenjivost metode postupne eliminacije varijabli za određivanje statistički značajnih varijabli modela. Definiranjem modela procjene troškova održavanja i uporabe, odnosno varijabli modela, definirane su i karakteristike građevine i način uporabe koji utječu na troškove održavanja i uporabe, a time i informacije potrebne za projektiranje novih građevina sličnog tipa s obzirom na racionalizaciju troškova održavanja i uporabe. Definirane su prednosti i ograničenja modela procjene troškova održavanja i uporabe i modela procjene troškova uporabe. Osnovna prednost primjene oba modela je jednostavnost primjene i potreban mali broj podataka koji su lako dostupni i prisutni kod svake građevine za procjenu analiziranih troškova održavanja i uporabe. Osnovno ograničenje oba modela je primjenjivost isključivo na fakultetske građevine Sveučilišta u Osijeku. Primjenom modela dobivenih provedenim istraživanjem moguće je planirati proračun troškova održavanja i uporabe fakultetskih građevina na razini građevina Sveučilišta u Osijeku za određena vremenska razdoblja. Unatoč relativno dužem razdoblju od pojave metode troškova životnog ciklusa, metoda i dalje nije sastavni dio suvremenog načina projektiranja. Neki od razloga su nedostatak pouzdanih podataka i nedostatak motivacije za uporabu zbog složenosti postojećih metoda. Rezultati provedenog istraživanja mogli bi pomoći pri savladavanju ovih zapreka.

Ključne riječi: *troškovi održavanja i uporabe građevina, baza podataka o troškovima održavanja i uporabe građevina, modeli procjene troškova održavanja i uporabe građevina*

SUMMARY

Maintenance and Operation cost's prediction model based on the Facilities of the University of Josip Juraj Strossmayer in Osijek

This study explores the possibility of collecting data and information about building characteristics and operational characteristics of buildings at the University of Josip Juraj Strossmayer in Osijek as well as the possibility of collecting data concerning maintenance and operation costs of those buildings. Data were collected using a questionnaire sent to all constituents of the University, general data about the usage and characteristics of building and data concerning costs of maintenance and operation in buildings were requested according to pre-defined cost data structure. The result of collecting and processing these data and information was creation of database about maintenance and operation costs of University buildings based on historical buildings data records with same or similar functional building purposes. Due to analysis of formed database in this work it was possible to develop models for calculating maintenance and operations costs and operations cost for buildings of the University, as well as determining impact of certain buildings characteristics, model variables, on maintenance and operational costs. The research found that it is possible to create mathematical models for predicting maintenance and operations costs of public buildings for scientific and educational purposes of University by using specific statistical methods. It was found that it is possible to use multiple regression analysis to develop models for predicting maintenance and operations costs and to use Stepwise method to determine statistically significant variables of the cost models. By defining the model for calculating maintenance and operational cost, cost model variables were also defined and therefore ways of usage and characteristics of building which affect the maintenance and operational costs, and respectively the information necessary for the design new buildings of similar purpose considering the rationalization of maintenance and operational costs. Advantages and limitations of model for calculating maintenance and operational cost and model for calculating operational costs of University buildings are defined. The main advantage of applying either of models is the ease of application and small numbers of item required for calculating cost and also facts that required data are easy to obtain and that they present in every building of similar purpose. Primary limitations of both models are applicability only to buildings at the University of Osijek. By applying models obtained in this research it is possible to plan and calculate the maintenance and operational costs of University buildings for certain time periods. Despite a relatively long period since the appearance of life cycle cost method the method is still not part part of modern design methods. Possible reasons for this might be in the lack of reliable data and lack of motivation to apply method due to the complexity of existing methods. The results of this research could help to overcome these obstacles.

Key words: *costs of building maintenance and operation, building maintenance and operation database, models for calculating maintenance and operational costs of buildings*

SADRŽAJ

1 UVOD 1
1.1 OBRAZLOŽENJE TEME I OPRAVDANOST ISTRAŽIVANJA 1
1.1.1 Predmet istraživanja 1
1.1.2 Svrha i ciljevi istraživanja 2
1.1.3 Metode istraživanja i kompozicija rada 4
1.2 METODA TROŠKOVA ŽIVOTNOG CIKLUSA GRAĐEVINA 6
1.2.1 Povijesni pregled i definicije 6
1.2.2 Životni ciklus građevina 16
1.2.3 Struktura troškova životnog ciklusa građevina 18
1.2.4 Ciljevi i prednosti uporabe metode optimiziranja troškova životnog ciklusa 25
1.2.4 Ograničenja primjene metode optimiziranja troškova životnog ciklusa 29
2 DOSADAŠNJA ISTRAŽIVANJA O TROŠKOVIMA ODRŽAVANJA I UPORABE GRAĐEVINA 33
2.1 MODELI OPTIMIZIRANJA TROŠKOVA ODRŽAVANJA I UPORABE 36
2.2 SAŽETAK I UVOD U PROBLEMATIKU TROŠKOVA ODRŽAVANJA I UPORABE GRAĐEVINA SVEUČILIŠTA U OSIJEKU 45
3 PRIKUPLJANJE I OBRADA PODATAKA 47
3.1 UPITNIK 47
3.2 ODAZIV NA ANKETU I PRIKUPLJENI PODATCI 49
3.3 STATISTIČKA OBRADA PODATAKA 54
3.3.1 Deskriptivna statistika 54
3.3.2 Odabir statističke metode i varijabli modela 58
3.3.3 Metode validacije modela 66
4 RAZVOJ MODELA PROCJENE TROŠKOVA UPORABE GRAĐEVINA 71
4.1 MODELI PROCJENE TROŠKOVA UPORABE GRAĐEVINA 74
4.1.1 Model I procjene troškova uporabe građevina 74
4.1.2 Model II procjene troškova uporabe građevina 74
4.1.3 Model III procjene troškova uporabe građevina 75
4.1.4 Model IV procjene troškova uporabe građevina 75
4.3 VALIDACIJA MODELA PROCJENE TROŠKOVA UPORABE GRAĐEVINA NA TESTNOM UZORKU 76
4.3.1 Validacija modela I procjene troškova uporabe građevina 77
4.3.2 Validacija modela II procjene troškova uporabe građevina 78
4.3.3 Validacija modela III procjene troškova uporabe građevina 78
4.3.4 Validacija modela IV procjene troškova uporabe građevina 79

4.3.5 Izbor modela procjene troškova uporabe građevina 79
4.4 ANALIZA OSJETLJIVOSTI MODELA PROCJENE TROŠKOVA UPORABE GRAĐEVINA 80
4.4.1 Analiza osjetljivosti odabranog modela procjene troškova uporabe građevina 82
4.5 MODEL PROCJENE DISKONTIRANIH TROŠKOVA uporabe građevina 83
4.5.1 Diskontna stopa 86
4.5.2 Ekvivalentna godišnja vrijednost 91
4.5.3 Model procjene diskontiranih troškova uporabe građevina 92
4.6 PREDNOSTI I OGRANIČENJA MODELA PROCJENE TROŠKOVA UPORABE GRAĐEVINA 96
4.6.1 Prednosti modela procjene troškova uporabe građevina 96
4.6.2 Ograničenja modela procjene troškova uporabe građevina 97
5 RAZVOJ MODELA PROCJENE TROŠKOVA ODRŽAVANJA I UPORABE GRAĐEVINA 99
5.1 MODELI PROCJENE TROŠKOVA ODRŽAVANJA I UPORABE GRAĐEVINA 101
5.1.1 Model I procjene troškova održavanja i uporabe građevina 101
5.1.2 Model II procjene troškova održavanja i uporabe građevina 101
5.1.3 Model III procjene troškova održavanja i uporabe građevina 102
5.3 VALIDACIJA MODELA PROCJENE TROŠKOVA ODRŽAVANJA I UPORABE GRAĐEVINA NA TESTNOM UZORKU 103
5.3.1 Validacija modela održavanja i uporabe građevina 104
5.3.2 Izbor modela procjene troškova održavanja i uporabe 104
5.4 MODEL PROCJENE DISKONTIRANIH TROŠKOVA ODRŽAVANJA I UPORABE GRAĐEVINA 108
5.5 PREDNOSTI I OGRANIČENJA MODELA PROCJENE TROŠKOVA ODRŽAVANJA I UPORABE GRAĐEVINA 112
5.5.1 Prednosti modela procjene troškova održavanja i uporabe građevina 112
5.5.2 Ograničenja modela procjene troškova održavanja i uporabe građevina 112
6 SAŽETI PRIKAZ REZULTATA, ZAKLJUČAK I SMJERNICE ZA DALJNJA ISTRAŽIVANJA 114
6.1 SAŽETI PRIKAZ REZULTATA ISTRAŽIVANJA 114
6.1.1 Model procjene troškova uporabe građevina 114
6.1.2 Model procjene troškova održavanja i uporabe građevina 115
6.2 ZAKLJUČAK I SMJERNICE ZA DALJNJA ISTRAŽIVANJA 118
6.2.1 Zaključak 118
6.2.2 Smjernice za daljnja istraživanja 119
LITERATURA I IZVORI 120
PRILOZI 127
PRILOG 1:UPITNIK 128
PRILOG 2:PODATCI O TROŠKOVIMA 129
PRILOG 3:KORELACIJE NEOVISNIH I OVISNIH VARIJABLI 130

PRILOG 4:TEST KOLINEARNOSTI 131
PRILOG 5:DESKRIPTIVNA STATISTIKA 132
PRILOG 6: REZULTATI *STEPWISE* ANALIZE 133

POPIS SLIKA

Slika 1 Hijerarhija pravne regulative o troškovima životnog ciklusa u Europskoj Uniji [52] 10

Slika 2. Dijagram tijeka Zajedničke europske metodologije [62] 14

Slika 3 Različite vrste životnog vijeka građevine [35, 65] 16

Slika 4 Skupine podataka potrebnih za provedbu analize troškova životnog ciklusa [69] 17

Slika 5 Veza zastarjelosti i dotrajalosti [70] 18

Slika 6 Gornja razina troškova životnog ciklusa [72] 20

Slika 7 Struktura troškova nabave [72] 20

Slika 8 Struktura troškova održavanja [72] 21

Slika 9 Troškovi održavanja i zamjene istrošenih elemenata [22] 22

Slika 10 Struktura ukupnih životnih troškova i troškova životnog ciklusa [3] 23

Slika 11 Karakteristične troškovne stavke ukupnih životnih troškova i troškova životnog ciklusa [3] 24

Slika 12 Prednosti primjene metode troškova životnog ciklusa [17] 26

Slika 13 Ovisnost mogućnosti smanjenja troškova održavanja i uporabe te troškova implementacije promjena [3, 25] 27

Slika 14 Krug uzroka i posljedica neprimjenjivanja metode troškova životnog ciklusa [25] 31

Slika 15 Kategorije ukupnih troškova [1, 82] 35

Slika 16 Odaziv na istraživanje fakulteta Sveučilišta u Osijeku 49

Slika 17 Struktura valjanosti dostavljenih podataka 49

Slika 18 Struktura podataka prema broju godina za koje su dostavljeni podatci 50

Slika 19 Odaziv na istraživanje fakulteta izvan Sveučilišta u Osijeku 51

Slika 20 Struktura valjanosti podataka 51

Slika 21 Udio pojedinih skupina troškova u prosječnim godišnjim nominalnim troškovima održavanja 54

Slika 22 Udio pojedinih skupina troškova u prosječnim godišnjim nominalnim troškovima održavanja za sve građevine u istraživanju 54

Slika 23 Grafički prikaz kumulativnih nominalnih troškova uporabe za razdoblje od 1997. do 2008. godine 55

Slika 24 Grafički prikaz kumulativnih nominalnih troškova održavanja i uporabe za razdoblje od 1997. do 2008. godine 55

Slika 25 Grafički prikaz troškova uporabe podijeljenih s neovisnim varijablama funkcionalnih površina ... 56

Slika 26 Grafički prikaz troškova uporabe podijeljenih s neovisnim varijablama prosječnog broja djelatnika i studenata 56

Slika 27 Grafički prikaz troškova održavanja i uporabe podijeljenih s neovisnim varijablama funkcionalnih površina 57

Slika 28 Grafički prikaz troškova održavanja i uporabe podijeljenih s neovisnim varijablama prosječnog broja djelatnika i studenata 57

Slika 29 Srednje vrijednosti točnosti ($\overline{A_C}$) i ukupna točnost (A_m) svakog od modela procjene troškova uporabe za dani set građevina 69

Slika 30 Srednje vrijednosti točnosti ($\overline{A_C}$) i ukupna točnost (A_m) svakog od modela procjene troškova održavanja i uporabe za dani set građevina 70

Slika 31 Vrijednosti koeficijenta determinacije i pripadajuće vrijednosti sume kvadrata pogreške predviđanja modela procjene troškova uporabe 73

Slika 32. Maksimalne i minimalne vrijednosti neovisnih varijabli rabljenih za utvrđivanje vrijednosti regresijskih koeficijenata i vrijednosti istih varijabli testnog uzorka 77

Slika 33 Odstupanja procijenjenih troškova uporabe od stvarnih vrijednosti troškova uporabe svih modela troškova uporabe 79

Slika 34 Srednje vrijednosti točnosti modela, ukupne točnosti modela i standardne devijacije modela procjene troškova uporabe za građevine koje su sudjelovale u istraživanju i građevina za validaciju 80

Slika 35 Rezultati analize osjetljivosti – model 2 82

Slika 36. Promjena neto sadašnje vrijednosti u vremenu, ovisno o visini diskontne stope. 86

Slika 37 Neto sadašnja vrijednost troškova održavanja građevine [151] 89

Slika 38. Grafički prikaz kretanja stope inflacije i diskontne stope 91

Slika 39 Grafički prikaz usporedbe kumulativnih troškova uporabe dobivenih modelom i stvarnih kumulativnih vrijednosti troškova uporabe građevine 4 (F14) 94

Slika 40 Grafički prikaz usporedbe kumulativnih troškova uporabe dobivenih modelom i stvarnih kumulativnih vrijednosti troškova uporabe građevine 9 (F17) 94

Slika 41 Promjena vrijednosti troškova uporabe ovisno diskontnoj stopi za građevinu 4 95

Slika 42 Promjena vrijednosti troškova uporabe ovisno diskontnoj stopi za građevinu 9 96

Slika 43 Vrijednosti koeficijenta determinacije i pripadajuće vrijednosti sume kvadrata pogreške predviđanja modela procjene troškova održavanja i uporabe 100

Slika 44 Maksimalne i minimalne vrijednosti neovisnih varijabli rabljenih za utvrđivanje vrijednosti regresijskih koeficijenata i vrijednosti istih varijabli testnog uzorka 103

Slika 45 Srednje vrijednosti točnosti modela, ukupne točnosti modela i standardne devijacije modela procjene troškova održavanja i uporabe za građevine koje su sudjelovale u istraživanju i građevine za validaciju 105

Slika 46 Točnost modela na građevinama uzorka i građevini za validaciju 105

Slika 47 Usporedba procijenjenih troškova održavanja i uporabe građevina i neovisne varijable modela (površine komunikacija) 106

Slika 48 Odstupanja površina komunikacija od srednje vrijednosti površine komunikacija uzorka i točnosti modela na tim građevinama 107

Slika 49 Grafički prikaz usporedbe kumulativnih troškova održavanja i uporabe dobivenih modelom i stvarnih kumulativnih vrijednosti troškova održavanja i uporabe građevine 1 (F4) 110

Slika 50 Grafički prikaz usporedbe kumulativnih troškova održavanja i uporabe dobivenih modelom i stvarnih kumulativnih vrijednosti troškova održavanja i uporabe građevine 3 (F10) 110

Slika 51 Promjena vrijednosti troškova održavanja i uporabe ovisno diskontnoj stopi za građevinu 1 111

Slika 52 Promjena vrijednosti troškova održavanja i uporabe ovisno diskontnoj stopi za građevinu 3 111

POPIS TABLICA

Tablica 1 Direktive Europske Unije s utjecajem na troškove životnog ciklusa [13, 52, 58-61]..... 12
Tablica 2 Koraci i kratki opis Zajedničke europske metodologije [53] 15
Tablica 3 Građevine sastavnica Sveučilišta u Osijeku 48
Tablica 4 Nominalni prosječni godišnji i nominalni ukupni troškovi održavanja i uporabe..... 52
Tablica 5 Popis mogućih neovisnih varijabli modela procjene troškova održavanja i uporabe..... 53
Tablica 6 Baza podataka neovisnih i ovisnih varijabli..... 53
Tablica 7 Koeficijenti korelacije neovisnih i ovisnih varijabli..... 59
Tablica 8 Deskriptivna statistika uzorka..... 61
Tablica 9 Statistički značajne neovisne varijable za model troškova uporabe..... 64
Tablica 10 Statistički značajne neovisne varijable za model troškova održavanja i uporabe 64
Tablica 11 Prijedlog modela troškova uporabe za daljnju razradu..... 65
Tablica 12 Prijedlog modela troškova održavanja i uporabe za daljnju razradu 66
Tablica 13 Vrijednosti sume kvadrata pogreške predviđanja modela, korijena srednje vrijednosti kvadratne pogreške i koeficijenata determinacije 71
Tablica 14 Vrijednosti koeficijenata determinacije poredane od najmanjih prema najvećim vrijednostima 72
Tablica 15 Modeli procjene troškova uporabe s pripadajućim varijablama..... 74
Tablica 16 Konstanta i regresijski koeficijenti modela procjene troškova uporabe – model 1 74
Tablica 17 Konstanta i regresijski koeficijenti modela procjene troškova uporabe – model 2 75
Tablica 18 Konstanta i regresijski koeficijenti modela procjene troškova uporabe – model 3 75
Tablica 19 Konstanta i regresijski koeficijenti modela procjene troškova uporabe – model 4 76
Tablica 20 Rezultati validacije modela 1 uporabnih troškova na građevinama F17 i F20 78
Tablica 21 Rezultati validacije modela 2 uporabnih troškova na građevinama F17 i F20 78
Tablica 22 Rezultati validacije modela 3 uporabnih troškova na građevinama F17 i F20 78
Tablica 23 Rezultati validacije modela 4 uporabnih troškova na građevinama F17 i F20 79
Tablica 24 Prednosti i nedostatci metoda financijskog vrjednovanja 83
Tablica 25. Metode izračuna troškova životnog ciklusa i njihovi nedostatci [25]..... 84
Tablica 26. Diskontne stope i vremensko razdoblje [155]..... 88
Tablica 27. Weitzmanova klizna skala diskontnih stopa [156] 88
Tablica 28. Osnovna referentna i diskontna stopa u Republici Hrvatskoj [158] 90
Tablica 29. Prosječna godišnja stope inflacije u Republici Hrvatskoj od 1998. do 2011. godine [160-162] 90
Tablica 30 Srednje vrijednosti točnosti modela uporabe građevina 93
Tablica 31 Vrijednosti sume kvadrata pogreške predviđanja modela, korijena srednje vrijednosti kvadratne pogreške i koeficijenata determinacije 99

Tablica 32 Vrijednosti koeficijenata determinacije poredane od najmanjih prema najvećim vrijednostima 99

Tablica 33 Modeli procjene troškova održavanja i uporabe s pripadajućim varijablama..... 101

Tablica 34 Konstanta i regresijski koeficijenti modela procjene troškova održavanja i uporabe – model 1 101

Tablica 35 Konstanta i regresijski koeficijenti modela procjene troškova održavanja i uporabe – model 2 102

Tablica 36 Konstanta i regresijski koeficijenti modela procjene troškova održavanja i uporabe – model 3 102

Tablica 37 Rezultati validacije modela procjene troškova održavanja i uporabe na testnom uzorku..... 104

Tablica 38 Srednje vrijednosti točnosti modela održavanja i uporabe građevina 109

1 UVOD

1.1 OBRAZLOŽENJE TEME I OPRAVDANOST ISTRAŽIVANJA

1.1.1 Predmet istraživanja

Do prije nekoliko godina sva pažnja investitora, arhitekata i izvođača radova bila je usmjerena na smanjenje građevinskih troškova, a malo je sudionika posvećivalo pažnju smanjenju troškova održavanja i uporabe građevina ili, još važnije, smanjenju ukupnih troškova projekata [1].

Troškovi životnog ciklusa građevina su ukupni troškovi građevine ili njenih dijelova tijekom životnog vijeka, uključujući troškove planiranja, projektiranja, nabave, uporabe, održavanja i uklanjanja, umanjenih za preostalu vrijednost građevine [2].

Prema normi ISO 15686:5, troškovima životnog ciklusa smatraju se indirektni troškovi i prihodi koji zajedno s troškovima životnog ciklusa (izgradnja, uporaba, održavanje i uklanjanje) čine ukupne životne troškove građevina [3].

Sve više pažnje posvećuje se planiranju i smanjenju troškova uporabe i održavanja građevina [4]. Istraživanja su također pokazala kako se u fazi projektiranja može utjecati na 70% do 80% troškova održavanja i uporabe kao značajnih troškova životnog ciklusa budućih građevina [5].

Prema autoru *Nuttu* (1999), područje održavanja građevina još je uvijek u početnoj fazi razvoja i nije podržano odgovarajućom bazom znanja, razvoj nije podržan niti s praktične strane. *Chotipanich* (2004) smatra kako je potreban daljnji razvoj metoda i tehnika koje će omogućiti razvoj održavanja građevina [6].

Arhitekti i projektanti imaju na raspolaganju veliki broj različitih metoda za izračun troškova građenja, no metode za izračun troškova životnog ciklusa nepotpune su i neprecizne [7]. Izračun troškova životnog ciklusa je jedan od ključnih elemenata pri ugovaranju projekata javno-privatnog partnerstva (u daljnjem tekstu JPP) [8]. Ova činjenica je stavila u pravi plan planiranje troškova održavanja i uporabe i to već u fazi projektiranja. Planiranje troškova životnog ciklusa postaje ključna varijabla u ranoj fazi projektiranja koja osigurava zadovoljstvo klijenata i sprječava opadanje vrijednosti građevine [8].

Također, jedan od važnih preduvjeta za primjenu JPP projekata u Hrvatskoj je i izrada hrvatskog standarda za ukupne životne troškove projekata visokogradnje koji će definirati raščlambu svih troškova, uključujući i troškove održavanja i uporabe objekata visokogradnje u etapi eksploatacije objekta [9].

Metoda troškova životnog ciklusa danas se uglavnom koristi kao inženjerska metoda koja se primjenjuje u fazi projektiranja i nabave te kao proaktivna metoda za upravljanje i proračun troškova održavanja i uporabe građevina [10-11].

Promatrano sa stajališta održive gradnje, proračun uporabnih troškova ima veliku važnost, budući da su građevine jedan od najvećih potrošača energije i procjenjuje se kako su odgovorne za približno 40% ukupne potrošnje energije [12-14], a najveći dio potrošene energije u građevinama, 60%, odnosi se na toplinske potrebe. U Hrvatskoj su građevine odgovorne za 30% ukupne potrošnje energije, od čega se oko 70% utroši na potrebe grijanja i tople vode [15-16].

Sve navedeno posebno je značajno ako se stavi u kontekst neprestanog porasta potreba za energijom i sve manje raspoloživih resursa za proizvodnju energije. Potrebe potrošača za energijom uvjetovane su ekonomskim razvojem, energetskom učinkovitošću i porastom cijene energije, pri čemu ekonomski razvoj uzrokuje porast potrošnje, a ostala dva elementa smanjenje potrošnje. Međutim, vrlo je teško predvidjeti veličinu utjecaja navedenih faktora na potrošnju energije u budućnosti [16].

Kako troškove održavanja i uporabe javnih građevina za potrebe sveučilišta snosi javni sektor, važno je utjecati na smanjenje tih troškova, pri čemu je u obzir potrebno uzeti i posebnosti javnih građevina u odnosu na građevine privatnog sektora kao što su:

- nulta diskontna stopa koja odražava posebnost građevina javnog sektora na koje se gleda kao na socijalne, a ne kapitalne projekte
- dugi životni vijek projekata
- mali ili nikakav prihod tijekom životnog vijeka [17].

1.1.2 Svrha i ciljevi istraživanja

Istraživanjem su utvrđene dvije osnovne zapreke primjeni metode troškova životnog ciklusa - prva je nedostatak mjerodavnih ulaznih podataka, a druga ograničeno iskustvo u provedbi proračuna troškova životnog ciklusa [4]. Smatra se da šira uporaba metode ima dvije velike prepreke, a to su nedostatak pouzdanih podataka o povijesnim troškovima građevina i načinu uporabe, i nepostojanje učinkovite metode za kontrolu analize troškova [18]. Građevine su različite, izgrađene na raznim lokacijama i s različitim namjenama, stoga je prikupljanje i obrada podataka izuzetno otežano. Nadalje, ne postoje standardizirane metode prikupljanja i obrade podataka, što otežava kontrolu podataka dobivenih analizom [4, 18-19].

Neki od razloga neprimjenjivanja metode su sljedeći:

- rezultati dobiveni analizom su nepouzdani zbog nesigurnih ulaznih podataka
- nedostupnost pouzdanih i prikladnih ulaznih podataka o troškovima i životnim vjekovima materijala i konstrukcija
- nepostojanje zajedničke metodologije, pristupa i mjerenja
- poteškoće pri definiranju određenih troškova

- odvojenost proračuna za izgradnju i održavanje javnih građevina [20-23].

Literatura o troškovima životnog ciklusa uglavnom je konceptualna i postoji vrlo malo podataka o primjeni i opsegu primjene metode. Dostupna literatura uglavnom govori o potencijalnim koristima primjene metode i tehničkim pitanjima vezanima uz primjenu. U akademskim radovima razvijeni su brojni modeli visoke razine tehničke složenosti, ali prilično niske razine praktičnosti i primjenjivosti. Postoji veliki broj istraživanja vezanih za troškove životnog ciklusa, no praktična primjena nije raširena unatoč potporama vlada nekih zemalja [24-25].

Troškovi održavanja mogu ovisiti o nekim karakteristikama građevine, kao na primjer starosti, namjeni, lokaciji, veličini i visini građevine te vrsti konstrukcije, materijalima i načinu izvođenja. Istraživanjima je utvrđena povezanost starosti građevine i troškova održavanja, kao i utjecaj visine građevine na troškove održavanja [19].

Izvještaj *Life Cycle Costs in Construction* iz 2003. godine je definirao osnovne smjernice s područja proučavanja troškova životnog ciklusa. Dokument nije službeni dokument Europske komisije (iako je ona inicirala njegovo stvaranje) i nema status službenog ili pravnog dokumenta. Neke od smjernica su sljedeće [26]:

1. stvaranje Zajedničke europske metodologije za procjenu troškova životnog ciklusa građevina
2. prikupljanje podataka o troškovima kako bi se stvorila baza podataka koja bi omogućila usporedbe troškova
3. javno dostupni pokazatelji o troškovima životnog ciklusa javnih građevina
4. provedba proračuna troškova životnog ciklusa u fazi koncipiranja projekata.

Metodologija daje okvir za izračun troškova životnog ciklusa koji na sistematičan način omogućava izračun istih za sve zemlje članice Europske Unije, bez namjere da mijenja postojeće modele i pristupe koji uzimaju u obzir nacionalne posebnosti. Metodologija daje uvid u ključna razmatranja pri proračunu troškova životnog ciklusa u svakoj fazi životnog vijeka te daje praktične smjernice za primjenu metode [27].

Dosada je razvijeno nekoliko modela održavanja i uporabe građevina koji će biti ukratko opisani u radu sa svojim osnovnim karakteristikama i nedostatcima.

Pregledom literature zaključuje se kako je jedno od područja za daljnja istraživanja integracija teoretskog pristupa i metodologije troškova životnog ciklusa s praktičnim potrebama korisnika i stručnjaka, vodeći računa o pitanjima kao što su kvaliteta podataka, jednostavnost proračuna i način tumačenja i prikaza rezultata. Nadalje, pregledom literature zaključuje se kako nijedan od modela ne analizira povezanost karakteristika građevina (varijabli modela) i troškova uporabe i održavanja građevina.

U Hrvatskoj nikada nije provedeno istraživanje navedene problematike te ne postoje podatci, odnosno baze podataka o troškovima održavanja i uporabe građevina koje bi se mogle

statistički obraditi i uporabiti pri modeliranju budućih troškova održavanja i uporabe građevina. Građevine Sveučilišta Josipa Jurja Strossmayera u Osijeku (u daljnjem tekstu Sveučilišta u Osijeku) su specifične i zbog rasprostranjenosti na različitim lokacijama grada kao i starosti građevina koja varira od 10 do 300 godina. Trenutačno u Hrvatskoj ne postoji okvir, preporuke i metodologija izračuna troškova životnog ciklusa građevina, iako je u Europskoj Uniji usvojen ISO 15686 (V dio) koji regulira to područje. Postoje baze podataka o troškovima građenja, ali ne i one s podatcima o troškovima održavanja i uporabe i podatcima o uporabnom vijeku postojećih građevina.

The Space Management Group (SMG) 2006. godine provela je u Velikoj Britaniji istraživanje o troškovima i potrebama za prostorom građevina visokog školstva i došla do zaključka kako zbog promjena u edukacijskom sustavu neće doći do značajnih promjena u potrebama za prostorom, odnosno neki prostori neće više biti potrebni dok će neki zahtijevati proširenje [8]. Neke od preporuka za daljnja istraživanja na području troškova životnog ciklusa iz doktorske disertacije *Al-Hajj*-a su nastavak prikupljanja podataka o troškovima životnog ciklusa građevina, kao i razvoj okvira za sistematizaciju i prikupljanje podataka o troškovima [22].

S obzirom na navedeno, svrha ovog istraživanja je razvoj modela procjene troškova održavanja i uporabe građevina Sveučilišta u Osijeku koji će omogućiti procjenu troškova održavanja i uporabe u budućnosti te utvrđivanje statistički značajnih varijabli koje omogućuju procjenu tih troškova. Kako bi se razvio model, koristit će se podatci o povijesnim troškovima održavanja i uporabe građevina Sveučilišta u Osijeku.

Ciljevi ovog rada su:

- istražiti u kojoj mjeri je moguće prikupiti povijesne podatke o troškovima životnog ciklusa građevina
- istražiti utjecaj pojedinih skupina troškova na ukupne troškove
- istražiti mogućnosti stvaranja matematičkog modela predviđanja troškova održavanja i uporabe građevina za određeno životno razdoblje
- istražiti čimbenike koji doprinose porastu troškova održavanja i uporabe građevina
- utvrditi varijable kojima bi se mogli procijeniti troškovi održavanja i uporabe
- definirati prednosti i ograničenja takvog modela.

1.1.3 Metode istraživanja i kompozicija rada

Radne hipoteze istraživanja:

- moguće je stvaranje baze podataka o troškovima održavanja i uporabe građevina Sveučilišta u Osijeku koja će se temeljiti na prikupljenim podatcima o povijesnim troškovima građevina iste ili slične funkcionalne namjene;

- moguć je razvoj modela predviđanja troškova održavanja i troškove uporabe javnih građevina za potrebe Sveučilišta zasnovanih na povijesnim podatcima o troškovima

održavanja i uporabe građevina iste ili slične funkcionalne namjene, uz određenu točnost modela;

- moguće je utvrditi utjecaj pojedinih karakteristika građevine, odnosno varijabli modela na troškove održavanja i uporabe građevina

- predloženi model predviđanja troškova održavanja i uporabe građevina Sveučilišta u Osijeku omogućio bi usporedbu navedenih troškova na istoj osnovi.

Istraživanje će biti usmjereno na starije građevine zbog novih zakona i regulative na području uštede energije i činjenice kako postoji veliki broj građevina koji će se koristiti još dugo vremena, a za koje postoji vrlo malo ili nema podataka o troškovima i načinu planiranja troškova održavanja i uporabe. Proučit će se sva dostupna literatura.

U istraživačkom radu primijenit će se kombinacija kvalitativnog i kvantitavnog pristupa. Prvi dio rada biti će deduktivan te će se temeljiti na postojećim radovima. Deduktivni pristup karakterizira stvaranje novih teorija pregledom literature iz koje se postavljaju radne hipoteze. Načinit će se upitnici i intervjui o troškovima održavanja i uporabe građevina i bit će primijenjeni na građevine Sveučilišta u Osijeku. Radne hipoteze ispitat će se na testnom uzorku kako bi se postavljene teorije i hipoteze prihvatile ili odbacile. Istraživanje će biti induktivno na dijelu gdje će se od prikupljenih podataka stvarati model predviđanja troškova održavanja i uporabe građevina. Dobiveni rezultati ispitat će se i na građevinama izvan Sveučilišta u Osijeku kako bi se utvrdila njihova primjenjivost na građevine iste namjene, ali izvan Sveučilišta.

Predložena kombinacija deduktivnog i induktivnog pristupa koristit će se kako bi se otkrile nove zakonitosti i provjerile radne hipoteze istraživanja.

Radni plan

I. Analiza trenutačnog stanja na području primjene troškova održavanja i uporabe
   A. Proučavanje postojeće literature
   B. Postavljanje radnih hipoteza

II. Definiranje postupka prikupljanja podataka
   A. Izrada upitnika i anketa
   B. Prikupljanje podataka

III. Analiza prikupljenih podataka
   A. Obrada prikupljenih podataka
   B. Interpretacija dobivenih rezultata

IV. Izrada matematičkog modela predviđanja troškova održavanja i uporabe građevina Sveučilišta u Osijeku

V. Ispitivanje hipoteza na postavljenom matematičkom modelu

VI. Postavljanje zaključaka

Očekivani znanstveni doprinos:

Tijekom postupka istraživačkog rada na području troškova održavanja i uporabe građevina te prihvaćanju ili odbacivanju postavljenih hipoteza očekuje se znanstveni doprinos u:

- stvaranju baza podataka o troškovima održavanja i uporabe fakultetskih građevina koja će se temeljiti na prikupljenim povijesnim podatcima, a o kojima trenutačno nema podataka

- stvaranju modela predviđanja troškova održavanje i uporabe javnih građevina visokogradnje za potrebe znanstveno obrazovnih ustanova Sveučilišta u Osijeku postupkom statističke obrade podataka i primjenom regresijskih metoda

- definiranju troškova održavanja i uporabe prema definiranim varijablama (npr. ukupna površina, broj djelatnika i sl.) fakultetskih građevina baziranim na povijesnim podatcima

- mogućnosti planiranja proračuna troškova održavanja i uporabe na razini građevina Sveučilišta u Osijeku za određena vremenska razdoblja

- definiranju karakteristika građevine i načina uporabe koji utječu na troškove održavanja i uporabe, a time i definiranju informacija potrebnih za projektiranje novih građevina sličnog tipa s obzirom na racionalizaciju troškova održavanja i uporabe.

1.2 METODA TROŠKOVA ŽIVOTNOG CIKLUSA GRAĐEVINA

1.2.1 Povijesni pregled i definicije

Metoda troškova životnog ciklusa se razvila sredinom šezdesetih godina prošlog stoljeća u SAD-u u Ministarstvu obrane pri nabavi vojne opreme, a prvo spominjanje pojma troškova životnog ciklusa zabilježeno je 1965. godine u dokumentu „*Life Cycle Costing and Equipment Procurement*“ [28]. Sedamdesetih godina prošlog stoljeća metoda se počinje koristiti za procjenu i usporedbu varijantnih rješenja projektiranja i izvođenje građevina s obzirom na moguće energetske uštede [29-31].

Sedamdesetih godina prošlog stoljeća u SAD-u se javlja nova vrsta menadžmenta, *facility management*, odnosno gospodarenje građevinama. Posljedica je to recesije koja se javila u to vrijeme, a gospodarenje građevinama javlja se kao odgovor na potrebu smanjenja ukupnih troškova i rasipnosti pri izvođenju projekata [32].

Gospodarenje građevinama kao disciplina proizašla je iz integracije sljedećih aktivnosti:

- upravljanja imovinom (nekretninama)
- održavanja i uporabe imovinom
- administracije [33].

Gospodarenje građevinama potrebno je promatrati unutar konteksta sljedećih čimbenika:

- političkih
- ekonomskih
- socijalnih
- tehnoloških
- ekoloških čimbenika [34].

Jedna od najstarijih definicija troškova životnog ciklusa datira iz 1977. godine, gdje Ministarstvo gospodarstva Ujedinjenog Kraljevstva definira metodu troškova životnog ciklusa kao koncept spajanja velikog broja disciplina – inženjerstva, računovodstva, matematike i statistike – kako bi se u obzir uzeli svi troškovi koji se javljaju kao posljedica vlasništva nad imovinom. Metoda se bavi kvantificiranjem varijantnih rješenja sa svrhom izbora optimalne varijante te omogućava iznalaženje kompromisnog rješenja između troškova životnog ciklusa i troškova pojedinih elemenata tijekom životnog vijeka, što omogućava zamjene i izbor najpovoljnijih elemenata [31, 35].

Krajem sedamdesetih godina prošlog stoljeća (1979.) metoda troškova životnog ciklusa definira se kao postupak sinteze analize troškova i projektiranja s ciljem razvoja infrastrukturnih sustava koji će zadovoljiti potrebne tehničke zahtjeve koji odražavaju zahtjeve korisnika tijekom najkraćeg životnog vijeka [36]. Sama definicija implicira provedbu analize troškova u svim fazama projektiranja i izvođenja građevine. Od 1978. sve građevine u SAD-u vrjednuju se u odnosu na troškove životnog ciklusa sukladno Nacionalnom zakonu o očuvanju energije [37].

Početkom devedesetih godina prošlog stoljeća *British Standard Institute* (BS3843) definira troškove životnog ciklusa kao troškove koji su vezani uz nabavu, uporabu, brigu i otpis imovine, uključujući troškove studija izvodivosti, razvoja i istraživanja, projektiranja, proizvodnje, održavanja, zamjene i uklanjanja, ali i troškove podrške, obuke osoblja i posljedica nastalih uporabom, održavanjem i izmjenama elemenata građevine [32, 35, 38].

Početkom ovog stoljeća metoda troškova životnog ciklusa se definira kao matematička metoda koja se koristi kako bi se oblikovala i podržala odluka pri većem broju predloženih mogućnosti. To je jasan financijski sustav vrjednovanja više međusobno isključivih mogućnosti koji omogućava promicanje financijski poželjnih i eliminaciju nepoželjnih mogućnosti (2001) [39-40].

U nastavku su nabrojane neke od definicija troškova životnog ciklusa tijekom vremenskog razdoblja od 1997. do 2008. godine.

”*British Standard Glossary of Maintenance Management Terms in Terotechnology* (BSI, 1984) definira troškove životnog ciklusa kao tehniku razmatranja ukupnih troškova vlasništva predmeta ili imovine uzimajući u obzir troškove nabave, obučavanja osoblja, izmjena i

uklanjanja, a sve sa svrhom odlučivanja o potrebnim izmjenama ili nabavi novog dobra koji će ispunjavati potrebne zahtjeve, te kao sustav kontrole održavanja postojećih i novih dobara“ [41].

„Troškovi životnog ciklusa su ukupni troškovi građevine ili njezinih dijelova tijekom životnog vijeka, uključujući troškove planiranja, projektiranja, nabave, uporabe, održavanja i uklanjanja, umanjeno za preostalu vrijednost“ [2].

„Postupak troškova životnog ciklusa je tehnika koja omogućuje usporednu procjenu troškova za određeni životni vijek građevina, pri čemu u obzir uzima sve relevantne ekonomske faktore kapitalnih troškova i troškova uporabe. U osnovi, to je ekonomska procjena svih relevantnih novčanih prihoda i izdataka tijekom razdoblja analize, izraženih u novčanim jedinicama“ [2, 37, 42-43].

„Postupak troškova životnog ciklusa ključni je faktor trenutačnih nastojanja za dobivanjem što veće vrijednosti imovine koju posjedujemo i koristimo. Vlade zemalja sve se više usredotočuju na dobivanje što veće vrijednosti imovine u njihovu posjedu, pri čemu se pokazalo kako se veća vrijednost imovine ne postiže nižim kapitalnim troškovima. Pozornost se sve više usmjerava na procjenu i smanjenje troškova građevina tijekom životnog vijeka kao i na smanjenje negativnih utjecaja na okoliš“ [27].

„Metodu troškova životnog ciklusa se definira kao pokušaj optimiziranja troškova nabave, vlasništva i upravljanja imovinom tijekom životnog vijeka, na način da se utvrde i kvantificiraju svi troškovno značajni elementi uporabom metode neto sadašnje vrijednosti“ [43].

„Troškovi životnog ciklusa imovine definiraju se kao ukupni troškovi imovine tijekom njezina životnog vijeka uključujući troškove nabave i sve ostale naknadne troškove koji će se javiti, a glavne stavke tih troškova su:

- početni troškovi (inicijalni ili kapitalni troškovi)
- troškovi uporabe
- troškovi održavanja
- troškovi rekonstrukcije“ [44].

„Britanski standard definira održavanje kao kombinaciju tehničkih i administrativnih aktivnosti potrebnih za održavanje (ili obnovu) stanja građevine ili nekog njezinog dijela kako bi ispunila svoju očekivanu namjenu. Postoje dva tipa održavanja:

- plansko održavanje (programirano, preventivno i cikličko)
- neplansko održavanje (reaktivno, normalna i žurna reakcija)“ [45-46].

„Norma ISO 15686, dio 1. (Service Life Planning), definira procjenu ukupnih troškova projekata kao tehniku koja omogućava komparativnu procjenu troškova tijekom definiranog vremenskog trajanja, uzimajući u obzir sve relevantne faktore koji utječu i na inicijalne kapitalne i

na buduće operativne troškove projekata [3, 35, 47-48]. Metoda je jednako primjenjiva kako na postojeće građevine, tako i na elemente građevina“ [49].

Općenita definicija kaže kako su troškovi životnog ciklusa suma svih vanjskih i unutarnjih troškova vezanih uz proizvod, proces, projekt ili aktivnost tijekom cijelog životnog vijeka građevine, uključujući troškove istraživanja, projektiranja, razvoja, nabave materijala, proizvodnje, ispitivanja, pakiranja, nabave i dostave, naknadnih usluga i garancija, izmjena i nadogradnji, povlačenja proizvoda, reciklaže i uklanjanja [31].

Ukupni životni troškovi uključuju sistematizirano razmatranje svih troškova i prihoda povezanih s nabavom, uporabom, održavanjem i uklanjanjem građevine. Analiza ukupnih životnih troškova omogućuje razmatranje ukupnih financijskih implikacija nabave građevina za njihove vlasnike i korisnike tijekom predviđenog vijeka trajanja građevina (2002) [50].

U literaturi se često koriste dva pojma, troškovi životnog ciklusa (*Life Cycle Cost, LCC*) i ukupni životni troškovi (*Whole Life Costing, WLC*). Norma ISO 15686 (1. i 5. dio) međutim daje definicije za oba pojma kako slijedi:

- *Troškovi životnog ciklusa su ukupni troškovi građevine ili njezinih dijelova tijekom životnog ciklusa, a obuhvaćaju troškove planiranja, projektiranja, nabave, izvođenja, održavanja, uporabe i uklanjanja, umanjenih za preostalu vrijednost.*

- *Ukupni životni troškovi definiraju se kao ekonomska procjena koja uzima u obzir sve troškove životnog ciklusa, ali i sve indirektne troškove projekta i relevantne novčane tijekove izraženih novčano za razdoblje analize [3].*

U Zakonu o gradnji održavanje se definira (članak 2. st. 8.) na sljedeći način: “Održavanje građevine jest praćenje i očuvanje namjene građevine te poduzimanje mjera nužnih za sigurnost i mehaničku otpornost i stabilnost građevine te za život ljudi”. Pojam rekonstrukcije, koji također znači radove na građevini, u istom članku Zakona (st. 3.) se definira: “Rekonstrukcija jest izvođenje građevnih radova na postojećoj građevini ili poduzimanje mjera radi uspostave primjerenog stanja građevine, ako se tim radovima i mjerama utječe na bitne zahtjeve za građevinu”. U Zakonu se za radove održavanja ne traži ishođenje građevne dozvole, dok se za rekonstrukciju traži. U kontekstu ovog rada rekonstrukciju je moguće odrediti kao zahvat kojim se podiže razina služnosti postojećeg objekta [51].

U Europskoj Uniji u većini zemalja trenutačno nema zakonske regulative koja zahtijeva uzimanje u obzir troškova životnog ciklusa pri postupku nabave, međutim postoji opcija primjene unutar postojećih propisa i postupaka javne nabave [26]. Osim toga, postoje razni oblici i strukture prikaza troškova životnog ciklusa, ali nema propisanog i općeg okvira na razini Europske Unije [20].

Važnost pravne regulative zemalja članica Europske Unije koja se odnosi na troškove životnog ciklusa prikazana je na slici 1 [52].

Slika 1 Hijerarhija pravne regulative o troškovima životnog ciklusa u Europskoj Uniji [52]

Razvoj metode troškova životnog ciklusa omogućit će stvaranje naprednijeg EMAT (*Economically Most Advantageous Tender,* odnosno ekonomski najpovoljnija ponuda) sustava nabave i bit će osnovni kriterij ocjenjivanja ponuda [26].

Europska komisija ugovorila je sa skupinom *Davis Langdon Management Consulting* iz Londona istraživanje koje će pomoći stvaranje i razvoj Zajedničke europske metodologije proračuna troškova životnog ciklusa građevina. Istraživanje je provedeno tijekom 2006. i 2007. godine [53-54]. Razvijena metodologija je usklađena djelomično i usklađuje se s normom ISO 15686 [20].

Ciljevi tog istraživanja su sljedeći [53] i [20]:

- analiza i vrjednovanje metoda troškova životnog ciklusa koje se koriste u zemljama Europske Unije
- razvoj zajedničkog pristupa metodi proračuna troškova životnog ciklusa u obliku zajedničke metodologije dostupne svim zemljama Unije
- podrška novoj metodologiji prikladnim smjernicama i analizama slučaja primjene metode u praksi s posebnim naglaskom na javni sektor
- unaprjeđenje konkurentnosti građevinske industrije
- unaprjeđenje svijesti industrije o utjecaju na okoliš
- unaprjeđenje načina nabave
- unaprjeđenje načina optimiziranja i predviđanja troškova

- unaprjeđenje pouzdanosti informacija o projektu, metoda predviđanja i procjena rizika pri procesu nabave
- stvaranje zajedničke baze podataka o troškovima životnog ciklusa zemalja članica EU.

U istraživanje su bile uključene Velika Britanija, Njemačka, Nizozemska, Švedska, Finska, Norveška, Irska, Španjolska, Grčka, Češka, Belgija i Francuska [20].

Istraživanjem su ostvareni sljedeći rezultati:

- konačno izvješće o istraživanju s rezultatima, zaključcima i preporukama
- pregled literature
- Zajednička europska metodologija zasnovana na rezultatima istraživanja
- dokument sa smjernicama koje podupiru Metodologiju
- skupina analiza slučaja koja objašnjava primjenu metode u praksi
- okvir za razvoj računalnog programa za proračun troškova životnog ciklusa [53].

Metodologija daje okvir za izračun troškova životnog ciklusa koji je zajednički i dosljedan za sve zemlje članice Europske Unije, bez namjere da mijenja postojeće modele i pristupe koji uzimaju u obzir nacionalne posebnosti. Metodologija daje uvid u ključna razmatranja pri proračunu troškova životnog ciklusa u svakoj fazi životnog vijeka te daje praktične smjernice za primjenu metode [27].

Zaključeno je kako je potrebno uložiti još dosta napora na području stvaranja Zajedničke europske metodologije kako bi se omogućila usporedba rezultata i izlaznih vrijednosti te normalizacija podataka postojećih izvora u zemljama članicama. Također je potrebno kontinuirano provoditi ažuriranje podataka. Međutim, postoji istraživanje o normalizaciji podataka koje provodi CEEC (*The European Council of Construction Economist*), radna skupina koja radi na stvaranju općeg okvira za razmjenu podataka na visokoj razini, što će omogućiti primjenu nacionalnih posebnosti. CEEC kodeks (*The Code of Measurement for Cost Planning*) daje osnovu strukture troškova i način izmjere površina potrebnih za planiranje troškova građenja i uporabe građevina te usporedbu i analizu prikupljenih podataka [55-56].

Na strateškoj razini, Zajednička europska metodologija usmjerena je na:

- unaprjeđenje konkurentnosti graditeljstva
- unaprjeđenje svijesti industrije o utjecaju na okoliš
- unaprjeđenje svojstava sustava nabave
- unaprjeđenje optimiziranja troškova
- unaprjeđenje pouzdanosti informacija o projektu, metoda predviđanja i procjena rizika projekta
- stvaranje usporedivih informacija bez stvaranja međunacionalnih prepreka [57].

U tablici 1 prikazane su ključne Direktive Europske Unije koje imaju utjecaj na troškove životnog ciklusa [13, 52, 58-61].

Tablica 1 Direktive Europske Unije s utjecajem na troškove životnog ciklusa [13, 52, 58-61]

Direktiva	Zakon	Datum stupanja na snagu	Konačni datum implementacije za zemlje članice
Direktiva o građ. Proizvodima	Direktiva 89/106/EEC	27.12.1998.	27.06.1991.
	Direktiva 93/68/EEC	02.08.1993.	02.08.1993.
Direktiva o energetskim karakteristikama zgrada	Direktiva 2002/91/EC	04.01.2003.	04.01.2006.
Okvirna direktiva o vodama	Direktiva 200/60/EC	22.12.2000.	22.12.2003.
	Odluka 2455/2001/EC	16.12.2001.	-
Okvirna direktiva o postupanju s otpadom	Odluka 96/350/EC	28.05.1996.	
	Direktiva 96/59/EC	16.09.1996.	
Integralno sprječavanje i upravljanje zagađivanjem	Direktiva 96/61/EC	30.10.1996.	30.10.1999.
Direktiva o koordinaciji postupaka za dodjelu ugovora o javnim radovima, ugovora o javnim opskrbama te ugovora o pružanju javnih usluga	Direktiva 2004/18/EC	21.04.2004.	31.01.2006.
Direktiva o usklađivanju postupaka nabave subjekata koji djeluju u sektoru vodnog gospodarstva, energetskom i prometnom sektoru te sektoru poštanskih usluga	Direktiva 2004/17/EC	31.04.2004.	31.01.2006.

Na slici 2 prikazan je dijagram tijeka Zajedničke europske metodologije, a u tablici 2 su prikazane ukratko aktivnosti i kratki opis Metodologije [53].

Slika 2 prikazuje ključne faze pri izračunu troškova životnog ciklusa građevina i daje jasan slijed istih. Opisane su ključne aktivnosti koje je potrebno provesti za uspješno izvršenje svake od faza, kao i ishodi izvršenja svake od njih. Kako je i samo projektiranje iterativan postupak kojim se različita rješenja ispituju, vrjednuju i unaprjeđuju, tako je i prikazani postupak izračuna troškova životnog ciklusa iterativan. Prikazana Metodologija omogućava razvoj i implementaciju različitih projektnih rješenja uz povećanje točnosti predviđanja troškova životnog ciklusa u svim fazama projekta od projektiranja, građenja do uporabe građevine [62]. Dijagram tijeka Metodologije prikazan na slici 2 može se prikazati i tablično, gdje je vidljivo kako je Metodologija strukturirana na nizu koraka, a za svaki od njih definirani su ishodi izvršenja. Koraci označeni sivom bojom predstavljaju neobavezne korake, odnosno prepuštene slobodnom izboru, a vezani su uz analizu rizika [53].

Prikazana Zajednička europska metodologija trebali bi:

- pomoći klijentima pri utvrđivanju
  - svojih potreba i ograničenja
  - uloge u procesu i
  - faze projekta u kojoj će se metoda početi primjenjivati;
- pomoći utvrđivanju opće osnove za usporedbu građevina (ako je usporedba potrebna);
- pomoći pri uvidu u ekološke implikacije projekta i razinu koja će se uvažiti pri proračunu troškova životnog ciklusa, te pomoći pri odabiru mjerodavnih metoda i tehnika;
- omogućiti izbor najprihvatljivijeg financijskog modela, analizu osjetljivosti, procjenu rizika i izbor potrebnih metoda;
- omogućiti provedbu i dokumentiranje metode;
- omogućiti stvaranje jedinstvenih izvještaja
- omogućiti utvrđivanje najprikladnijeg projektnog rješenja uključujući optimalno
  - troškovno rješenje
  - tehnološko rješenje
  - ekološko rješenje [63].

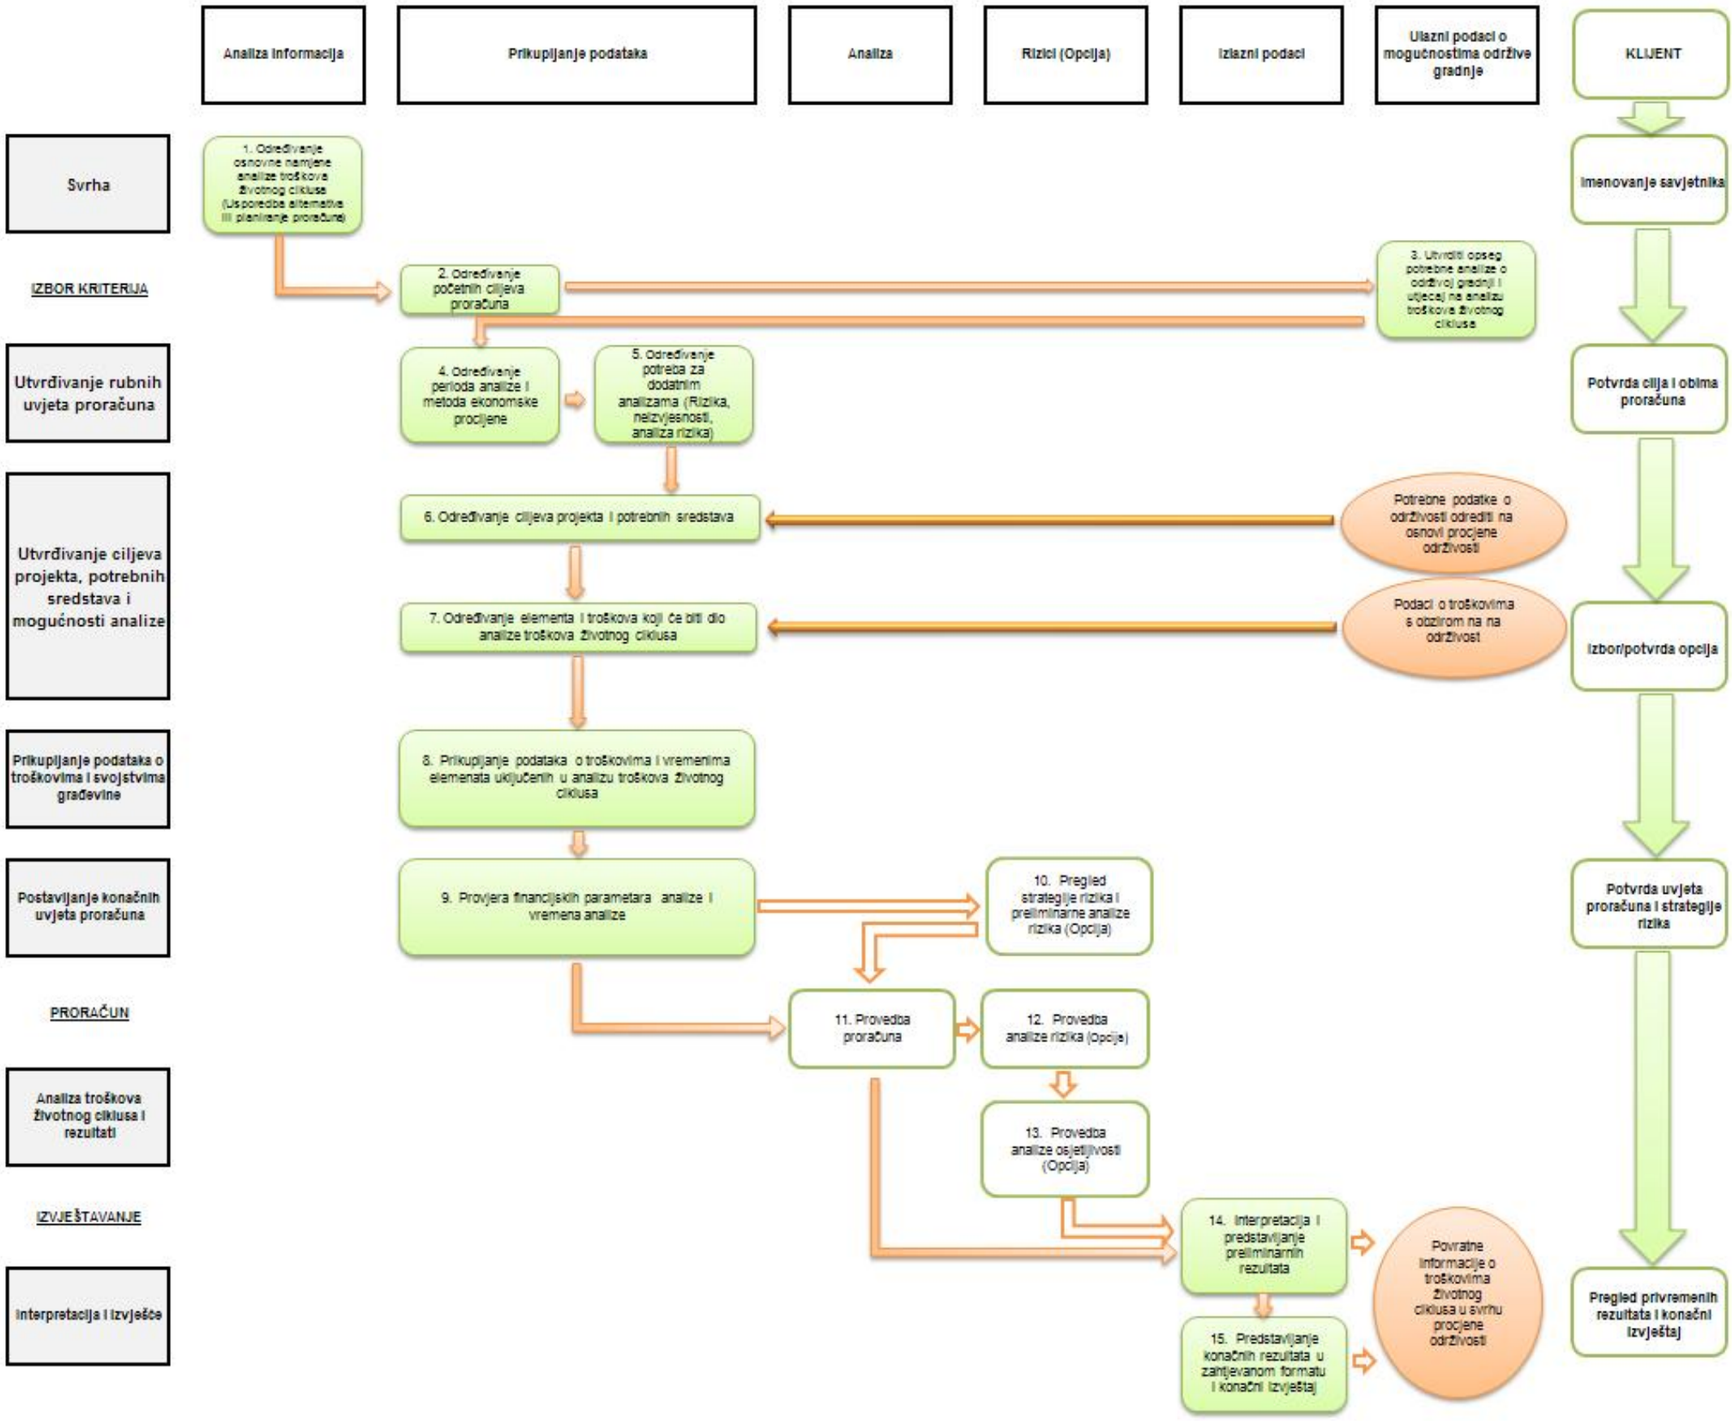

Slika 2. Dijagram tijeka Zajedničke europske metodologije [62]

Tablica 2 Koraci i kratki opis Zajedničke europske metodologije [53]

BROJ	KORAK	ISHODI / IZVRŠENJE CILJA				
1	Određivanje osnovne namjene analize troškova životnog ciklusa (Usporedba alternativa ili planiranje proračuna)	Izvještaj o namjeni analize	Pretpostavka o prikladnoj metodi primjene analize troškova životnog ciklusa i očekivannim ishodima			
2	Određivanje početnih ciljeva proračuna	Pretpostavljanje razine primjene metode	Pretpostavke o periodu na koji će se primijeniti analiza	Pretpostavke o relevantnim ciljevima i ishodima	Izvještaj o zahtijevima klijenta	
3	Utvrditi opseg potrebne analize o održivoj gradnji i utjecaj na analizu troškova životnog ciklusa	Poznavanje veze između procijene održivosti i analize životnih troškova	Utvrđivanje ishoda procijene održivosti koji će biti ulazni podaci za analizi troškova životnog ciklusa	Utvrđivanje ishoda analize troškova životnog ciklusa koji će biti povratna informacija za procijenu održivosti		
4	Određivanje perioda analize i metoda ekonomske procijene	Određivanje perioda analize i čimbenika koji ga određuju	Određivanje primjerenih metoda za procijenu opcija investicije			
5	Određivanje potreba za dodatnim analizama (Rizika, neizvjesnosti, analiza rizika)	Završetak preliminarnih procjena rizika/nesigurnosti	Procjena potrebe o planu za upravljanje rizicima	Odluka o rizicima koji će se uzeti u obzir i/ili stvaranja registra rizika		
6	Određivanje ciljeva projekta i potrebnih sredstava	Definiranje ciljeva projekta i ključni značajki resursa	Izvještaj o ograničenjima projekta (Rubnim uvijetima)	Definiranje relevantnih zahtjeva o svojstvima i kvaliteti	Potvrda o proračunu projekta i vremenskim ograničenjima	Smještanje analize u vremenski plan projekta
7	Određivanje elementa i troškova koji će biti dio analize troškova životnog ciklusa	Definiranje elemenata koji će biti dio analize	Izbor jedne ili više opcija za svaki analizirani element	Definiranje troškova		
8	Prikupljanje podataka o troškovima i vremenima elemenata uključenih u analizu troškova životnog ciklusa	Određivanje troškova relevantnih za analizu	Vrijednost svakog troška	Dodatni troškovi	Ulazni podaci ovisni o vremenu, npr podaci o održavanju	
9	Provjera financijskih parametara analize i vremena analize	Potvrđen period analize	Potvrđene primjerene vrijednosti financijskih parametara	Razmotreni podaci o porezima	Odluka o primjeni financijskih parametara unutar troškovne strukture	
10	Pregled strategije rizika i preliminarne analize rizika (Opcija)	Potvrđen vremenski raspored rizika	Provedena kvalitativna analiza rizika - registar ažuriran	Potvrđena razina i ciljevi procijene rizika		
11	Provedba proračuna	Analiza troškova životnog ciklusa provedena	Rezultati pripremljeni za 14 korak			
12	Provedba analize rizika (Opcija)	Provedena kvantitativna analiza rizika	Tumačenje rezultata			
13	Provedba analize osjetljivosti (Opcija)	Provedena analiza osjetljivosti	Tumačenje rezultata			
14	Interpretacija i predstavljanje preliminarnih rezultata	Preliminarni rezultati pregledani i interpretirani	Rezultati predstavljeni u prikladnom formatu	Utvrđena potreba za daljnjim iteracijama metode		
15	Predstavljanje konačnih rezultata u zahtjevanom formatu i konačni izvještaj	Konačni rezultati	Svi podaci izraženi prema ISO 15686 dio 3			

1.2.2 Životni ciklus građevina

Procjena troškova životnog ciklusa izvodi se tijekom cijelog životnog vijeka nekog proizvoda ili građevine. Na početku projekta prvo se razmatraju troškovi projekta, nadalje se razmatraju različita varijantna projektna rješenja kako bi se došlo do optimalnog, a u konačnici i odluka o uklanjanju ili zamjeni se temelji na procjeni troškova uporabe [64].

Čimbenici koji utječu na troškove održavanja mogu se podijeliti u pet skupina:

- karakteristike građevine
- utjecaj korisnika
- utjecaj održavanja
- politički čimbenici
- ostali čimbenici [19].

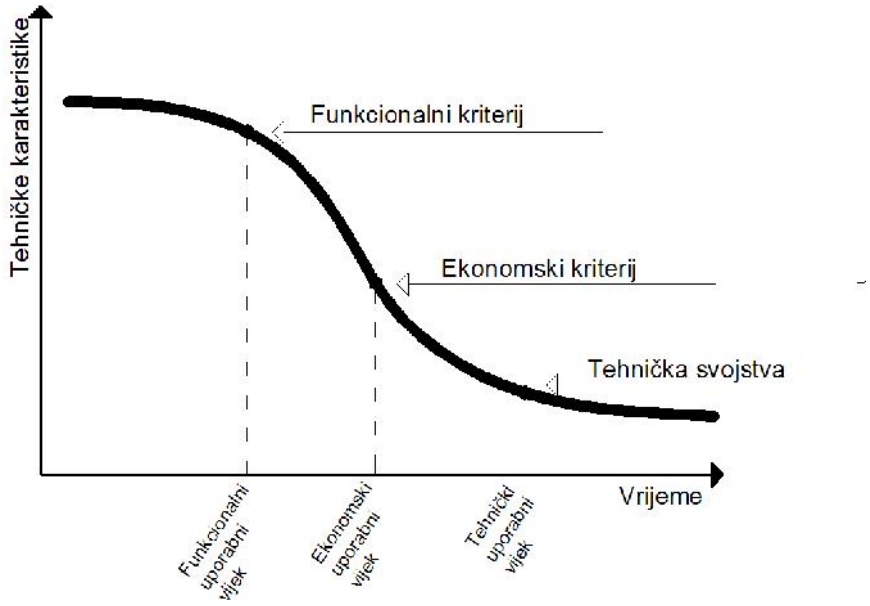

Slika 3 Različite vrste životnog vijeka građevine [35, 65]

Troškovi životnog ciklusa su u izravnoj vezi s trajanjem, odnosno životnim vijekom nekog proizvoda. Neki autori smatraju da proizvod može dosegnuti više različitih tipova kraja životnog vijeka kao što su npr. kraj tehničkog, ekonomskog, ekološkog, estetskog, funkcionalnog ili psihološkog vijeka. ISO norma razlikuje tri kraja uporabnog vijeka: tehničkog, ekonomskog i funkcionalnog uporabnog vijeka. Nakon što se odredi uporabni vijek građevine i njezinih pojedinih dijelova, moguće je pristupiti planiranju održavanja i procjenjivanju vrijednosti građevine [3, 65-66]. U SAD-u se javne građevine vrjednuju za vremensko razdoblje od 25 godina [67].

Na slici 3 su prikazani različiti uporabni vjekovi građevine, ovisno o kriteriju definiranja uporabnog vijeka. Tehnički uporabni vijek je onaj uporabni vijek nakon kojega proizvod više ne

ispunjava predviđene karakteristike, odnosno nakon kojega gubi pretpostavljena svojstva. Ekonomski uporabni vijek građevine završava nakon što se pojavi proizvod koji može zadovoljiti predviđenu funkciju uz manje troškove ili uz iste troškove, ali rezultira boljim karakteristikama. Funkcionalni uporabni vijek završava kada proizvod ne ispunjava zahtjeve korisnika ili kada se određena funkcija više ne zahtijeva. Ova tri uporabna vijeka definiraju razdoblje analize ukupnih životnih troškova [35, 65].

Razdoblje analize se definira kao vrijeme kroz koje se promatra investicija, pri čemu to razdoblje ovisi o različitim faktorima, a najčešće se definira kao:

- predvidljivo razdoblje uporabe građevine (ovo je najpoželjnije razdoblje analize, ali ne i obvezno)
- razdoblje definirano ugovorom
- standardno investicijsko razdoblje analize definirano unutar organizacije
- razdoblje analize od 100 godina koje se rabi za građevine koje će biti u uporabi duže od 100 godina, jer se smatra kako se nakon tog razdoblja rezultati analize ionako značajnije ne mijenjanju [3, 52, 68].

Podatci potrebni za provedbu analize troškova mogu se svrstati u pet skupina i prikazani su na slici 4. Svaki od njih na različit način i u različitom razdoblju utječe na troškove životnog ciklusa projekta [69].

Slika 4 Skupine podataka potrebnih za provedbu analize troškova životnog ciklusa [69]

Kada se govori o održavanju građevina i njezinih dijelova, tada je potrebno razlikovati dva vrlo slična pojma, zastarjelost i dotrajalost. Zastarjelost je proces koji nije jednostavno nadzirati, nasumičan je i ne može se predvidjeti. Zastarjelost može biti tehnološka, funkcionalna, ekonomska, socijalna i regulatorna. S druge strane, dotrajalost se može nadzirati, kontinuirana je i predvidljiva komponenta. Događa se zbog raznih oštećenja i fizičkog propadanja materijala. Reakcije na zastarjelost su obnova, modernizacija i usklađivanje s novim tehnologijama (npr. uvođenje energetski učinkovitih uređaja), a reakcije na dotrajalost su rekonstrukcija, popravci i održavanje [3, 70-71]. Obje pojave utječu na smanjenje vrijednosti kapitala vlasnika imovine. Veza zastarjelosti i dotrajalosti grafički je prikazana na slici 5 [70].

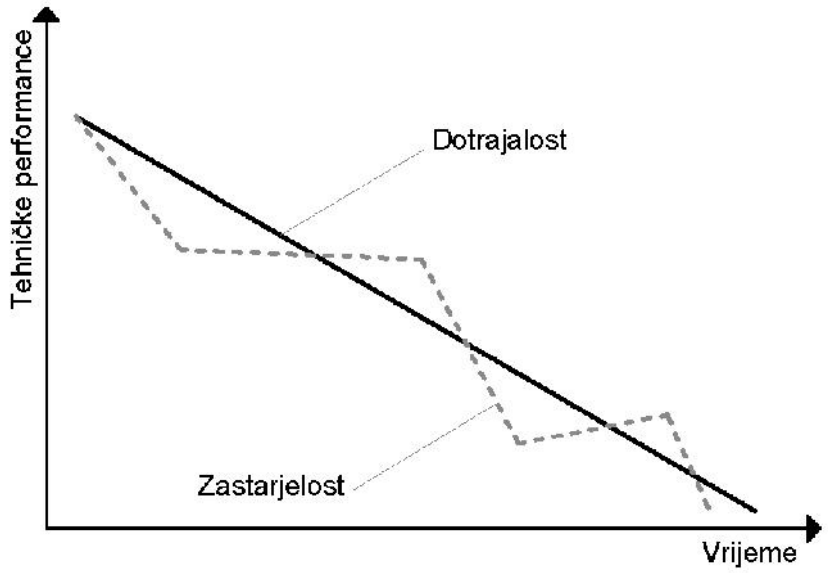

Slika 5 Veza zastarjelosti i dotrajalosti [70]

1.2.3 Struktura troškova životnog ciklusa građevina

Predloženo je nekoliko struktura baza podataka o troškovima životnog ciklusa, kao npr. *"building maintenance cost information service data"*, te PSA (*Property Services Agency*) "troškovi pri uporabi objekata", no niti jedna nije generalno prihvaćena u graditeljstvu. Bez razvoja strukture koja će obuhvatiti sve podatke za procjenu i analizu ukupnih troškova projekata, nemoguća je i djelotvorna povratna veza između tima odgovornog za upravljanje održavanjem i uporabom izgrađenih ili renoviranih građevina i tima odgovornog za planiranje i projektiranje građevina [1].

Troškovi životnog ciklusa mogu se promatrati kroz četiri osnovne kategorije troškova [44]:

1. Inicijalni troškovi

To su troškovi investitora nastali izravno iz samog projekta, a uključuju troškove zemljišta, nabave roba i usluga, usluga projektiranja, raščišćavanja terena i pripreme gradilišta, građenja itd.

2. Troškovi uporabe
   Mogu se definirati kao troškovi povezani uz samu uporabu građevine, oni uključuju troškove čišćenja, energije, osiguravanja, administracije itd.
3. Troškovi održavanja
   Ove troškove i aktivnosti vezane uz njih potrebno je redovito kontrolirati kako bi se time osigurala prikladna razina uslužnosti građevine, a uključuju troškove popravaka i zamjene dotrajalih materijala i elemenata građevina.
4. Preostala vrijednost
   To je vrijednost građevine na kraju ekonomskog životnog vijeka, ili u onome trenutku kada građevina više ne može ispunjavati svoju namjenu.

Kirk i *Dellisola* (1995.) proširuju ove četiri skupine troškova sljedećim vrstama troškova koje je potrebno uzeti u obzir:

- troškovi financiranja – svi troškovi vezani uz početne kapitalne troškove
- troškovi zamjene istrošenih materijala i elemenata
- troškovi poreza, kredita i amortizacije i
- pridruženi troškovi koji se vezuju uz troškove osoblja, materijala, osiguravanja i prekida uporabe zbog održavanja [37].

U većini organizacija podatci o troškovima životnog ciklusa se skupljaju zbog:

- potreba računovodstva kako bi se dokazalo raspolaganje novčanim sredstvima
- potreba upravitelja građevina kako bi se lakše organizirali potrebni radovi
- promatranja utjecaja popravaka na stanje građevine i uporabu, te zbog usporedbe građevina [22].

Kao primjer udjela pojedinih troškova u ukupnim životnim troškovima, navodi se istraživanje *Joint Center for Land Development Studies*. Utvrđeno je da troškovi životnog ciklusa poslovnih građevina mogu poprimiti tijekom životnog ciklusa sljedeće vrijednosti:

- 7-30% troškovi održavanja
- 15-45% troškovi energije
- 5-40% troškovi čišćenja
- 5-45% troškovi financiranja (kamate)
- 2-20% troškovi osiguranja
- 0-10% troškovi upravljanja i osiguravanja.

Svi navedeni podatci odnose se na godišnje troškove jednako distribuirane tijekom uporabe građevine i izražene kao postotci od ukupne vrijednosti troškova održavanja [37].

Barringer i ostali predlažu strukturu troškova prikazanu na slikama 6,7 i 8, autori smatraju kako su troškovi nabave i troškovi održavanja povezani, odnosno ne isključuju se međusobno [72].

Slika 6 Gornja razina troškova životnog ciklusa [72]

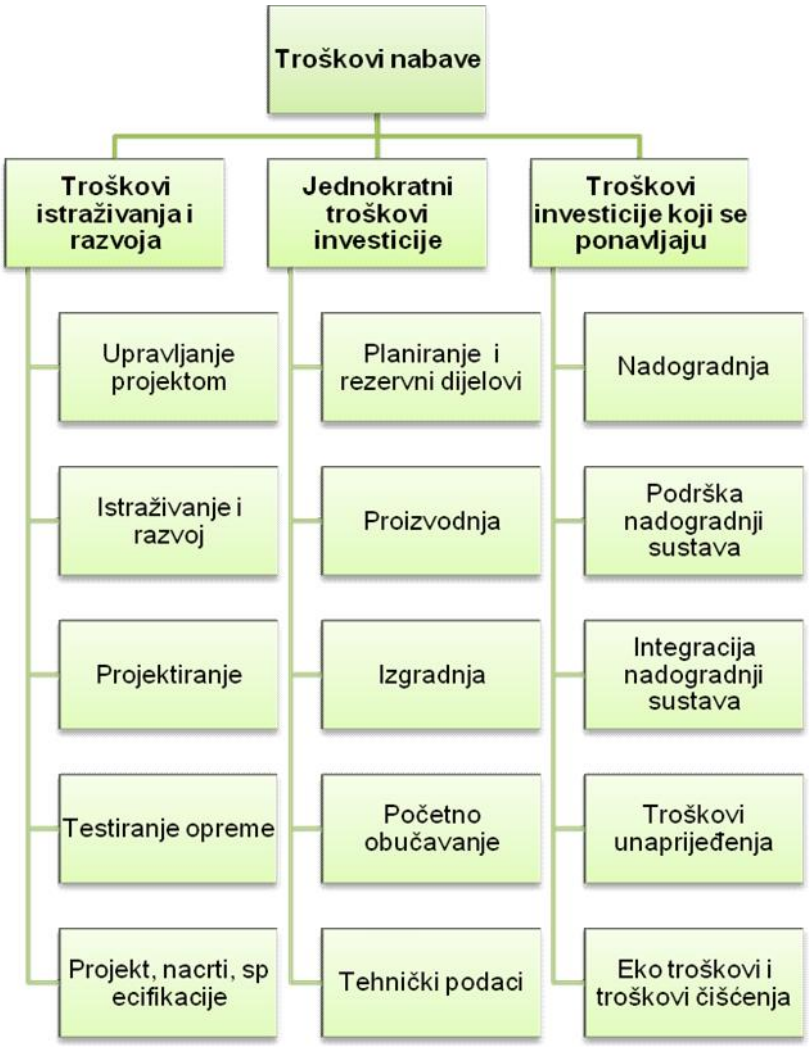

Slika 7 Struktura troškova nabave [72]

Slika 8 Struktura troškova održavanja [72]

Troškovi održavanja i zamjene istrošenih elemenata slijede istu strukturu koja se rabi za podjelu građevinskih radova, kao što je prikazano na slici 9. Takva struktura omogućuje svim sudionicima u projektu da se povežu i koriste iste podatke i informacije tijekom svih etapa projekta.

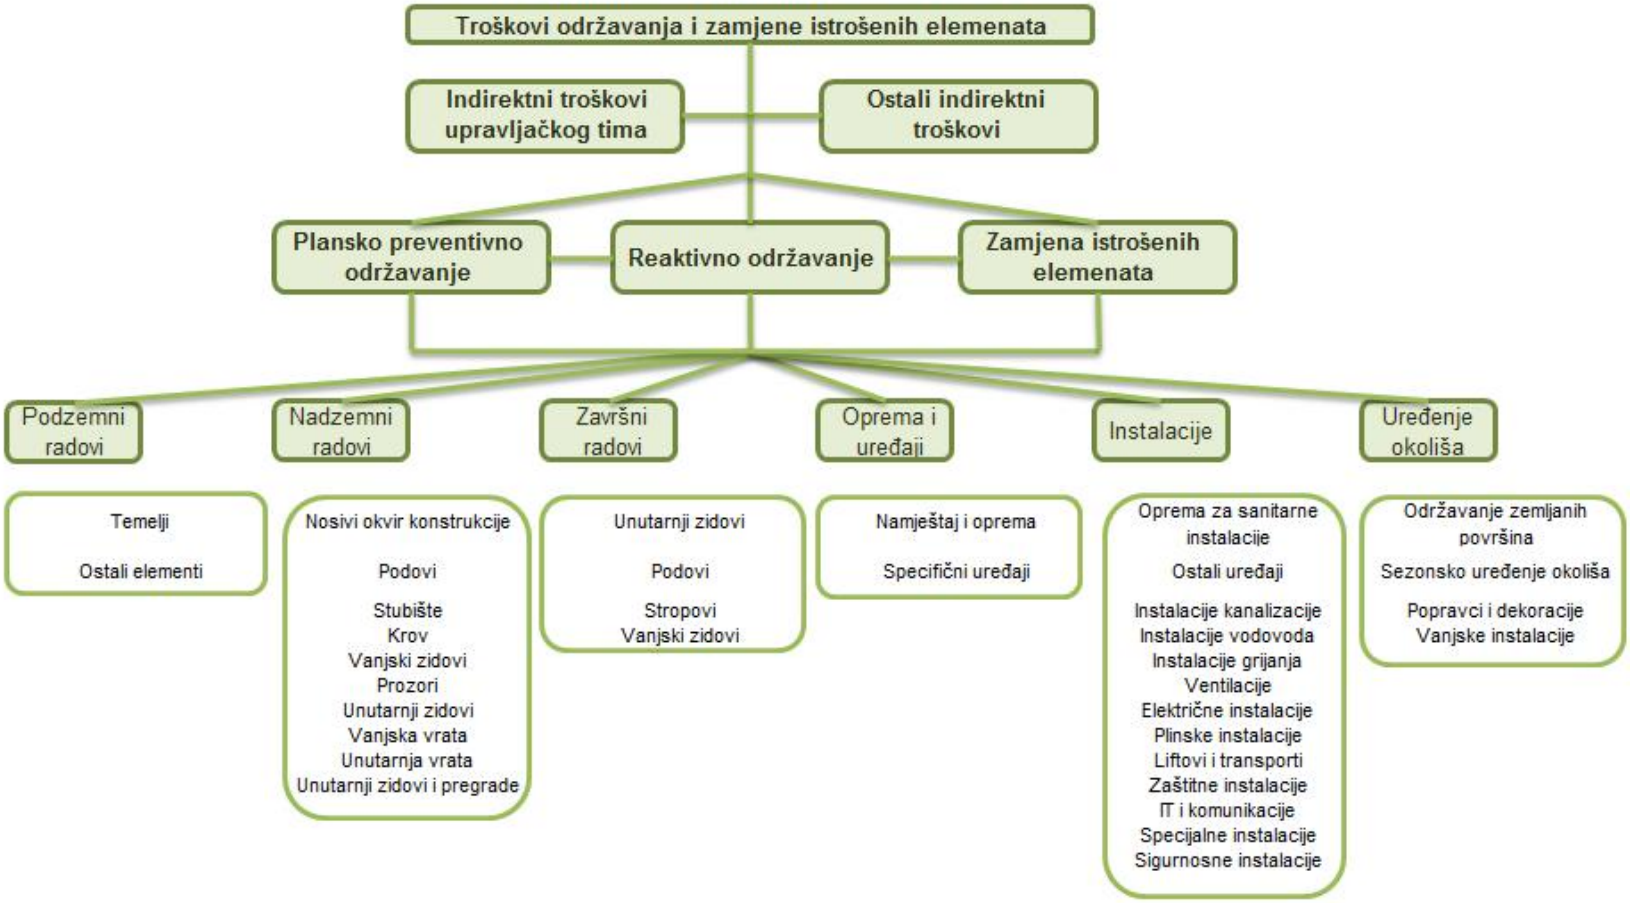

Slika 9 Troškovi održavanja i zamjene istrošenih elemenata [22]

Na slici 10 prikazana je struktura ukupnih životnih troškova i troškova životnog ciklusa elemenata prema normi ISO 15686:5 [3]. Grafički su prikazani troškovi koji se smatraju troškovima životnog ciklusa i ostali troškovi (nekonstrukcijski troškovi i prihodi) koji zajedno s troškovima životnog ciklusa (izgradnja, uporaba, održavanje i uklanjanje) čine ukupne životne troškove.

Slika 10 Struktura ukupnih životnih troškova i troškova životnog ciklusa [3]

Na slici 11 prikazana je opća struktura troškova koja je osnova za proračun troškova životnog ciklusa i usporedbu mogućih rješenja. Prikazana struktura je prilagodljiva lokalnim posebnostima te nije potrebno uzeti u obzir sve predložene skupine troškova, ali je dopušteno uvrstiti dodatne skupine, ovisno o specifičnosti pojedinih projekata. Smisao prikazane strukture troškova je da se strukture troškova koje sadrže nacionalne posebnosti mogu uklopiti u predloženu strukturu troškova Zajedničke europske metodologije [3].

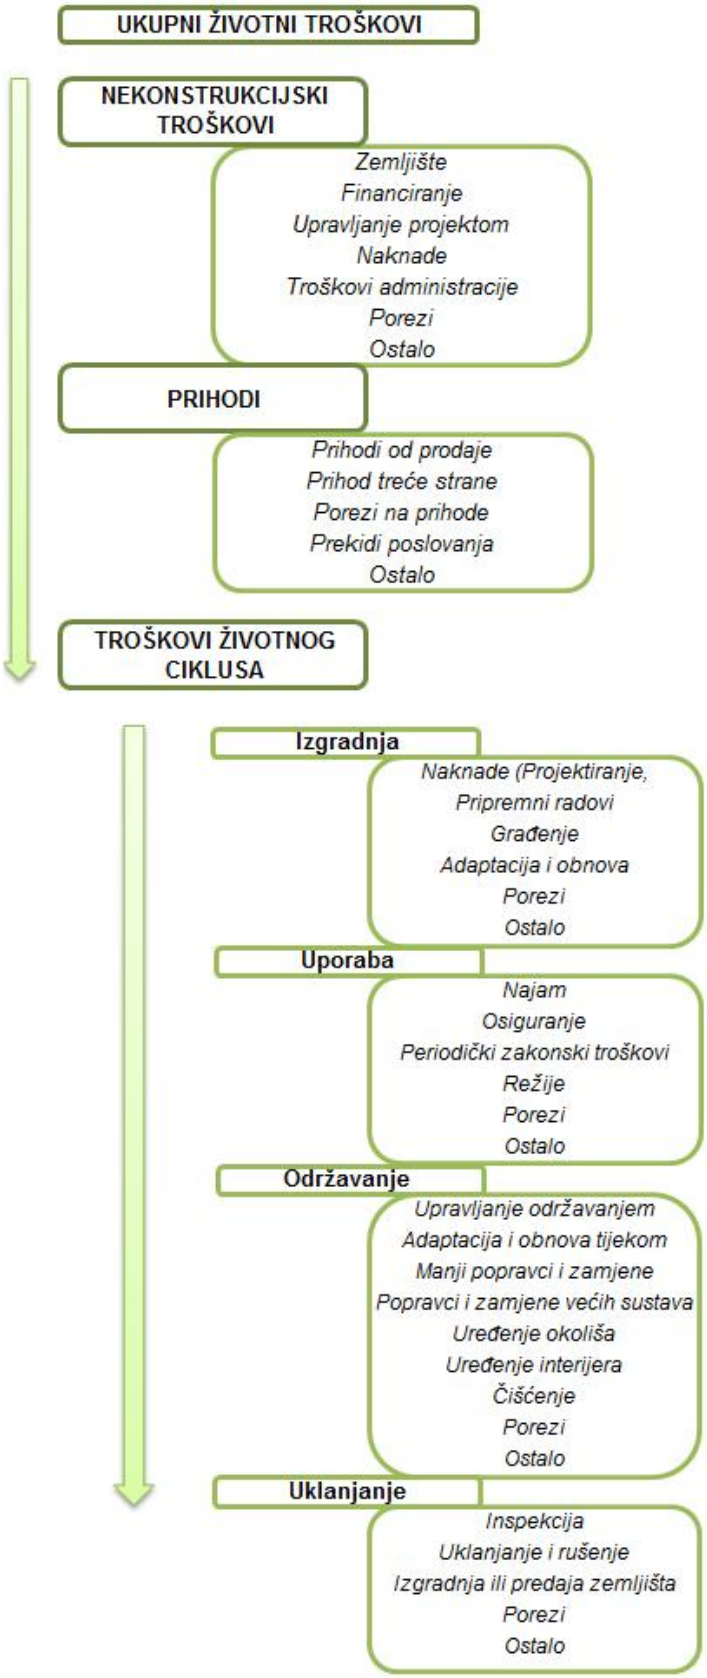

Slika 11 Karakteristične troškovne stavke ukupnih životnih troškova i troškova životnog ciklusa [3]

1.2.4 Ciljevi i prednosti uporabe metode optimiziranja troškova životnog ciklusa

Cilj metode troškova životnog ciklusa je utvrditi troškovno učinkovitu varijantu nekog projekta radi ostvarenja, dugoročno gledano, najnižih troškova vlasništva nad nekim dobrom [72]. Prije i za vrijeme izvođenja građevinskih projekata investitori su uglavnom usmjereni na kratkoročne troškove, zanemarujući pritom troškove koji će se javiti nakon što građevina bude puštena u uporabu što može biti vrlo nerazborito [22].

Izračun troškova životnog ciklusa jedan je od ključnih elemenata pri ugovaranju JPP projekata. Kako je potrebno osigurati uporabivost građevine pod točno definiranim uvjetima, važno je unaprijed razmišljati prilikom projektiranja. Ova činjenica je stavila je u prvi plan planiranje troškova životnog ciklusa, i to već u fazi projektiranja. Planiranje troškova životnog ciklusa postaje ključna varijabla u ranoj fazi projektiranja koja osigurava zadovoljstvo klijenata i sprječava opadanje vrijednosti građevine [8]. Također, jedan od važnih preduvjeta za primjenu JPP projekata u Hrvatskoj je i izrada hrvatskog standarda za ukupne troškove projekata visokogradnje koji će definirati raščlambu svih troškova, uključujući i troškove održavanja i uporabe objekata visokogradnje u etapi uporabe [9].

Metoda troškova životnog ciklusa se danas koristi kao [10-11]:

1. učinkovita inženjerska metoda koja se primjenjuje u fazi projektiranja i nabave (ovo je bila i početna ideja uporabe metode)
2. proaktivna metoda za upravljanje i proračun troškova
3. projektna i inženjerska metoda koja služi ekološkim svrhama.

Prednosti primjene metode za pojedine sudionike u procesu prikazane su na slici 12 [17].

Slika 12 Prednosti primjene metode troškova životnog ciklusa [17]

Normom ISO 15686 su utvrđeni sljedeći ciljevi uporabe metode:

- utvrđivanje terminologije i zajedničke metodologije primjene metode troškova životnog ciklusa
- praktična primjena metode kako bi postala općeprihvaćena u građevinskoj industriji
- primjena metode pri postupcima nabave
- pomoć pri odlučivanju o izboru projekta i vrjednovanju projekata u svim njihovim fazama
- upućivanje na nesigurnosti i rizike kako bi se poboljšala pouzdanost metode
- učiniti metodu i osnovne pretpostavke transparentnima i jasnima
- postavljanje osnovnih načela, uputa i definicija modela i načina izvještavanja
- osiguranje dosljednog okvira za predviđanje troškova životnog ciklusa
- uspostava zajedničke osnove za proračun troškova tijekom projektiranja i građenja i troškova tijekom uporabe građevine
- definiranje razlike između ukupnih životnih troškova i troškova životnog ciklusa
- definiranje opće strukture troškova koja će biti sposobna za uvažavanje nacionalnih posebnosti i struktura troškova
- otkrivanju prave vrijednosti primjene metode planiranjem životnog vijeka građevina [3, 24].

Karakteristične prednosti primjene metode troškova životnog ciklusa su sljedeće:

- transparentnost budućih troškova održavanja i uporabe
- mogućnost detaljnijeg planiranja troškova održavanja i uporabe
- uvid u podatke o ukupnim životnim troškovima građevina
- mogućnost izmjene i optimiziranja troškova u ranoj fazi projektiranja
- postizanje veće vrijednosti novca
- usklađivanje sa zahtjevima javne nabave
- odabir optimalne strategije nabave
- mogućnost ocjene novih materijala i tehnologija
- utvrđivanje troškovno značajnih stavki troškova životnog ciklusa
- usporedba troškova i postignutih svojstava građevina [5, 27-28, 35, 37].

Osnovna namjena primjene metode troškova životnog ciklusa je omogućavanje izbora optimalne varijante pri izboru projekta s obzirom na troškove životnog ciklusa. Primjena je moguća u bilo kojoj fazi projekta, ali najučinkovitija je ipak ako se primijeni u ranoj fazi. Nakon što je građevina predana krajnjem korisniku, izmjena troškova uporabe gotovo je nemoguća ili iziskuje pretjerana ulaganja [25, 54]. Smatra se kako je 80% do 90% troškova održavanja definirano izradom projektne dokumentacije [25]. Na slici 13 prikazana je ovisnost mogućnosti uštede na životnim troškovima građevine i troškova implementacije promjene [3, 25].

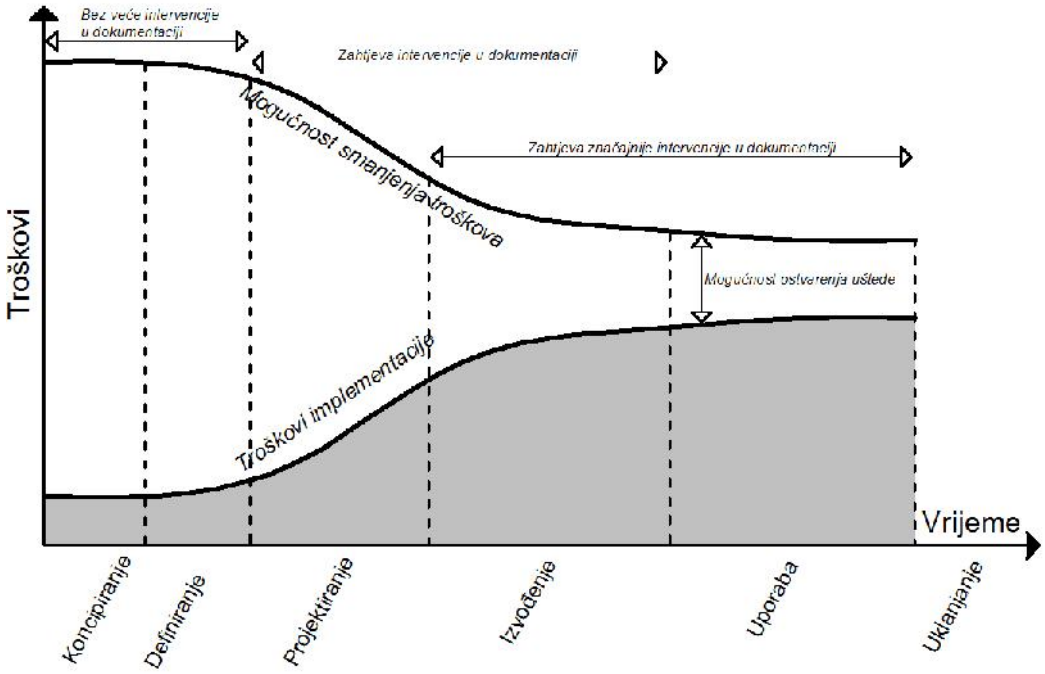

Slika 13 Ovisnost mogućnosti smanjenja troškova održavanja i uporabe te troškova implementacije promjena [3, 25]

Četiri su faze u kojima je moguće analizirati ukupne životne troškove i troškove životnog ciklusa građevine:

1. u fazi koncipiranja i definiranja projekta
2. u fazi projektiranja i izvođenja

3. u fazi uporabe građevina
4. na kraju životnog ciklusa [3].

Metoda troškova životnog ciklusa primjenjuje se u fazi uporabe u sljedećim situacijama kada:

- se jave visoki troškovi uporabe
- poraste potrošnja energije
- dođe do zastarjelosti (kao npr. tehnološka ili fizička)
- dođe do promjene namjene uporabe građevine i
- komponente ili elementi građevine dosegnu kraj životnog vijeka [17].

Pri upravljanju projektima postavljaju se tri pitanja [73]:

- Kojim mjerama je moguće osigurati uporabivost, trajnost i pouzdanost građevine?
- Kada i na koji način se procjenjuje stanje elemenata i građevine u cjelini?
- Kada, u kojem opsegu i koje radove održavanja treba izvoditi kako bi se osigurala ekonomičnost građevine?

Kod tradicionalnog načina ustupanja radova, osnovni kriterij odabira izvođača radova je, uz potrebne reference za izvođenje istih, i najniža cijena izvođenja radova. U takvim okolnostima naručitelj radova plaća izvedene radove, shodno odredbama ugovora. Problem nastaje u etapi uporabe građevine, kada naručitelj preuzima obvezu održavanja i uporabe iste, a naročito istekom ugovornih obveza i jamstvenog razdoblja. Posljedice svih nedostataka u projektiranju, izvođenju ili održavanju snosi naručitelj, odnosno porezni obveznici ako se radi o javnim građevinama. U konačnici to rezultira vrlo visokim troškovima ukupnog vlasništva [74].

Metoda optimiziranja troškova životnog ciklusa najčešće se koristi za nove građevine ili pri većim rekonstrukcijama. Može se primijeniti na cijelu građevinu, dio građevine ili opremu. Metoda se može koristiti i za:

- ocjenu različitih prilika investiranja
- izbor između različitih projektnih rješenja građevina ili njihovih dijelova
- izbor između različitih projektnih rješenja opreme
- usporedbu i vrjednovanje prethodnih analiza
- procjenu budućih troškova radi planiranja proračuna [3].

Zanemarivanjem, odbijanjem i odgađanjem održavanja građevina, gube se sve potencijalne prednosti za vlasnike građevina. Potencijalne prednosti sa stajališta povijesno vrijednih građevina mogu se svrstati u pet skupina:

- prednosti koji ostvaruje vlasnik građevine očituju se u očuvanju vrijednosti građevine i zaštiti investicije
- u socijalnom pogledu prednosti su smanjenje troškova i planiranje mogućih prekida odvijanja djelatnosti zbog većih kvarova i rekonstrukcija
- u ekološkom pogledu redovitim održavanjem smanjuje se količina materijala i energije potrebnih za održavanje građevina, a samim time i nepotrebno rasipanje energije kao i stvaranje otpada

- u kulturalnom pogledu se postiže očuvanje povijesne baštine i očuvanje povijesnih materijala koje ne bi bilo moguće pri većim i razornijim zahvatima
- u ekonomskom pogledu ostvaruju se uštede na troškovima održavanja [75].

1.2.4 Ograničenja primjene metode optimiziranja troškova životnog ciklusa

Unatoč činjenici kako su tehnike i metode proračuna troškova životnog ciklusa razvijene, primjena u građevinskom sektoru i dalje je ograničena [29]. Istraživanje na Novom Zelandu (*Donn* et al. 1995.) pokazalo je kako projektanti i izvođači smatraju kako su klijentima važniji niži kapitalni od troškova životnog ciklusa [37]. U prilog tome ide i tvrdnja autora *Haberechta* i *Bennetta* iz 1999. da se vlasništvo nad obiteljskim kućama na Novom Zelandu mijenja u prosjeku svakih sedam godina. Iz navedenog se može zaključiti kako primjena metoda ovisi o namjeni i vlasništvu nad nekom građevinom, ali i vremenu uporabe građevine, što najbolje ilustrira sljedeći podatak - diskontiraju li se troškovi životnog ciklusa klasičnih obiteljskih kuća stopom od 5%, tada raspodjela troškova poprima sljedeće postotke:

- 56% inicijalni troškovi (troškovi izgradnje)
- 16% troškovi održavanja
- 28% troškovi grijanja i rasvjete [37].

Usprkos relativno dužem razdoblju od same pojave metode troškova životnog ciklusa, ona i dalje nije zaživjela u suvremenom načinu projektiranja. Razlozi su brojni, od ljudskih do tehnoloških čimbenika kao što su:

- općeniti nedostatak motivacije za uporabu
- brojni kontekstualni čimbenici koji ograničavaju uporabu
- mnoštvo metodoloških zapreka i ograničenja
- pristup pouzdanim podatcima [29].

Metoda troškova životnog ciklusa izrazito je ovisna o pretpostavkama i procjenama načinjenima tijekom prikupljanja podataka. Iako je dio njih moguće otkloniti prikupljanjem povijesnih podataka i primjenom statističkih metoda, uvijek ostaje određeni stupanj nesigurnosti vezan uz pretpostavke i procjene [43].

U slučaju kada se metoda troškova životnog ciklusa koristi, uglavnom je usmjerena na sustav instalacija (grijanje, ventilacija i hlađenje), a ne na građevinu kao cjelinu [4].

Zapreke primjeni metode troškova životnog ciklusa mogu se svrstati u sljedeće skupine:

- nedostatak prikladnih podataka o trajnosti građevine i njezinih dijelova, troškovima i potrošnji energije
- izvori financiranja projekta, izvori novca za građenje i održavanje obično se razlikuju, odnosno vode ih različite službe te na taj način nema podataka o ukupnim životnim troškovima građevina
- zanimanje naručitelja za kratkoročne troškove, većinu naručitelja obično ne zanimaju troškovi koji će se javiti u budućnosti već samo oni koji se javljaju u bliskoj budućnosti

- otežano je provoditi metode troškova životnog ciklusa dok se ne izmijeni trenutačna praksa po kojoj projektantima i arhitektima pripada naknada za projektiranje kao određeni postotak od troškova građenja, te je stoga otežano promovirati pristup različitim rješenjima koja će optimizirati odabir materijala s obzirom na ukupne životne troškove građevina
- porezni problemi [76].

Autor *Macedo* i ostali utvrdili su sljedeće izvore nesigurnosti:

- razlika između stvarnog i očekivanog ponašanja sustava ili nekog podsustava
- promjena pretpostavki o uporabi građevine koje se javljaju zbog promjena u ponašanju korisnika
- tehnološki napredak kojim nastaju jeftinije varijante koje samim time skraćuju trajanje ekonomskog životnog vijeka predložene varijante
- promjena cijene važnih resursa kao što su energija i ljudski rad
- pogreške pri procjeni veze između cijena pojedinih resursa i inflacije [77].

Pri proračunu troškova životnog ciklusa postoje određene ključne varijable uz koje je vezana veća ili manja nesigurnost, najčešće zbog neodgovarajućih ulaznih podataka. Pitanje je koliko su osjetljivi izlazni podatci na varijacije ulaznih varijabli i nesigurnosti [43]. Brojni ulazni podatci potrebni za analizu troškova životnog ciklusa nisu pouzdani i ovise o procjeni kao što su npr. duljina životnog vijeka, uporaba, troškovi planiranog i neplaniranog održavanja [4].

Kao neki od glavnih razloga neprimjenjivanja metode često se navode sljedeći razlozi:

- povećanje kapitalnih troškova ne mora nužno značiti i smanjenje troškova održavanja i uporabe
- rezultati dobiveni analizom su nepouzdani zbog nesigurnih ulaznih podataka i
- neke aspekte građevine nemoguće je troškovno iskazati, kao što je npr. izgled [22].

Istodobno, navedenim razlozima na strani neprimjenjivanja metode možemo pridružiti sljedeće argumente na strani primjene metode troškova životnog ciklusa:

- niži kapitalni troškovi ne znače nužno manje troškove uporabe
- uporabom metode može se utjecati na smanjenje troškova koji nastaju zbog dotrajalosti
- odluke tijekom izrade projekta imaju dugoročni utjecaj na troškove životnog ciklusa građevina
- investiranjem u kapitalne troškove utječe se na troškove uporabe [22].

Široj primjeni metode kao zapreka se javlja nedostatak podataka i neprikladnost istih te je stoga ova metoda u povezanom krugu uzroka i posljedica, kao što je prikazano na slici 14 [25].

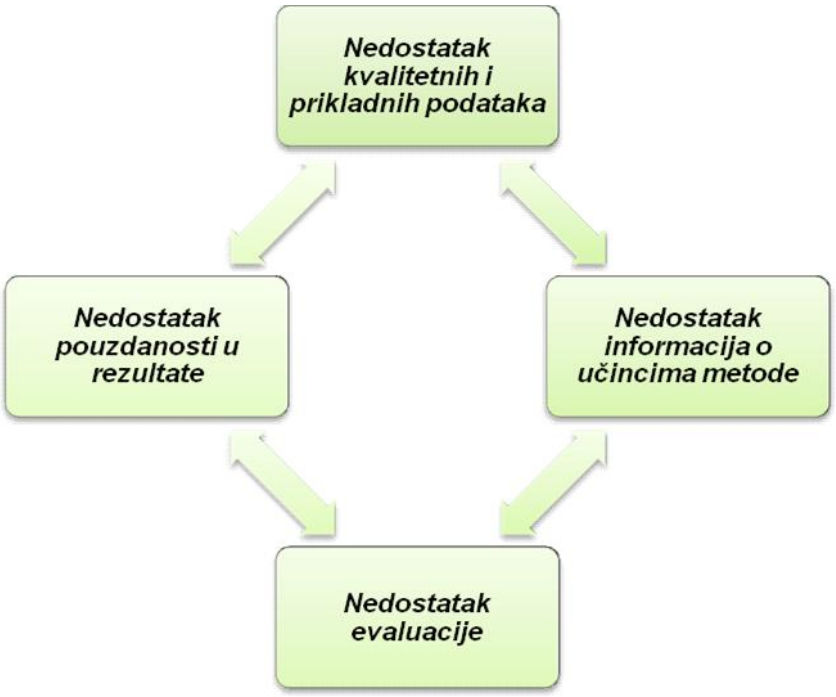

Slika 14 Krug uzroka i posljedica neprimjenjivanja metode troškova životnog ciklusa [25]

Osnovni preduvjet za širu primjenu metode troškova životnog ciklusa je postupno smanjenje rizika vezanih uz metodu, što je moguće ostvariti:

- prikupljanjem pouzdanijih informacija o troškovima životnog ciklusa
- razvojem pouzdanijih modela predviđanja troškova i
- razvojem metoda koje će omogućiti kvantifikaciju rizika [26].

Kako bi se smanjila nesigurnost predviđanja troškova i rizici prema normi ISO 15686, potrebno je više razumijevanja za ključne zapreke široj primjeni metode troškova životnog ciklusa, a to su:

- neodlučnost oko uključivanja i/ili isključivanja pojedinih stavki iz proračuna
- mnoštvo metoda i modela financijskog vrjednovanja
- nedostatak detaljnih podataka o projektu na samom početku projekta
- pojava novih tehnologija i proizvoda i informacije o njihovoj trajnosti
- povezanost kapitalnih i uporabnih troškova tijekom životnog vijeka građevine
- vrste ugovora o realizaciji građevina
- nedostatak stručnjaka na području analiza i optimiziranja troškova životnog ciklusa [3].

Tijekom istraživanja na projektu *Life Cycle Costing as a Contribution to Sustainable Construction* uočeno je kako postoji znatan otpor pri otkrivanju stvarnih troškova životnog ciklusa građevina. Ovi podatci uglavnom su smatrani komercijalno osjetljivim. Stoga bi i neka od daljnjih istraživanja trebalo usmjeriti na taj problem.

Očito je nepodudaranje u teoriji i praksi kada se govori o metodi troškova životnog ciklusa pri projektiranju građevina, zbog čega je razvijeno nekoliko strategija za širu primjenu Ističu se dva pristupa navedenoj problematici:

- bolja ilustracija osnovnih značajki metode
- unaprjeđivanje baze podataka o troškovima [29].

Istraživanjem su utvrđene i prepreke za šire usvajanje metode troškova životnog ciklusa:

- nedostupnost pouzdanih i prikladnih ulaznih podataka o troškovima i životnim vjekovima materijala i konstrukcija
- nepostojanje zajedničke metodologije, pristupa i mjerenja
- poteškoće pri definiranju određenih troškova
- ograničena suradnja između kupaca i dobavljača
- loša kvaliteta podataka dobavljača i nedostatak iscrpnih podataka o uporabnim uvjetima proizvoda
- troškovno i vremenski zahtjevna metoda
- zahtjevan posao prikupljanja podataka za analizu
- odvojenost proračuna za izgradnju i održavanje u javnom sektoru
- nedostatak znanja naručitelja
- nedostatak potpore javnog sektora
- nedostatak pouzdanih povijesnih podataka [20-21, 28, 37].

Unatoč navedenim ograničenjima i rizicima, primjena metode svakako je opravdana, posebno ako se u obzir uzme činjenica kako troškovi održavanja i uporabe kontinuirano rastu i čine veliki dio troškova životnog ciklusa građevina [4, 78].

Troškovi održavanja mogu ovisiti o nekim karakteristikama građevine, kao na primjer starosti, namjeni, lokaciji, veličini, visini, vrsti konstrukcije, materijalima i načinu izvođenja. Istraživanjima je utvrđena povezanost starosti građevine i troškova održavanja, kao i utjecaj visine građevine na troškove održavanja [19].

Nedostatak podataka o troškovima uporabe građevina prvenstveno je vezan uz ograničenu mogućnost predviđanja događaja u budućnosti i njihovih posljedica na troškove uporabe te nedostatak pouzdanih povijesnih podataka o troškovima građevina [4].

Istraživanje koje je provedeno u ovom radu usmjereno je na već postojeće građevine Sveučilišta u Osijeku čija starost se kreće u rasponu od 10 do 300 godina te stoga nije moguće obuhvatiti istraživanjem podatke o troškovima građenja. Budući da se uglavnom radi o zaštićenim građevinama koje su kulturno dobro i ne predviđa se njihovo uklanjanje, istražit će se troškovi održavanja i uporabe građevina Sveučilišta u Osijeku koji su sastavni i vrlo važan dio ukupnih životnih troškova.

2 DOSADAŠNJA ISTRAŽIVANJA O TROŠKOVIMA ODRŽAVANJA I UPORABE GRAĐEVINA

Troškovi održavanja građevina obuhvaćaju troškove potrebnog rada, materijala i ostale povezane troškove koji se javljaju pri održavanju definirane razine služnosti neke građevine, a obuhvaćaju troškove korektivnog, preventivnog i reaktivnog održavanja cijele građevine ili njezinih dijelova. Operativni troškovi definiraju se kao troškovi nastali kao posljedica uporabe i gospodarenja nekom građevinom, a obuhvaćaju poreze, najam, kamate, troškove energije, čišćenja i ostalih potrebnih usluga, ovisno o funkciji građevine te inspekcijskih pregleda [3].

Financijski pokazatelji investicijskih ulaganja razvijenih zemalja u stambeni fond pokazuju da sredstva uložena u održavanje postojećih zgrada sve više premašuju sredstva uložena u izgradnju novih zgrada. Stoga je potrebno sustavno predviđati i planirati trošenje sredstava za održavanje [51].

Istraživanja u SAD pokazala su sljedeće:

- godišnji troškovi uporabe pojedinih građevina mogu premašiti troškove izgradnje istih i za 10%
- troškovi uporabe nestambenih građevina su porasli za 25% od 2003. godine
- prosječna stopa porasta troškova uporabe je iznosila 4.50% godišnje [79].

Prema podatcima iz 2002. godine, od ukupnih investicija vrijednosti vezanih uz graditeljstvo u Švedskoj, 37% odnosi se na održavanja građevina [78], dok u Velikoj Britaniji taj postotak, prema podatcima iz 1995. godine, iznosi 50% [71].

Johansson i *Öberg* su 2001. godine, istraživanjem stambenih građevina izgrađenih u Švedskoj između 1994. i 1998. godine, utvrdili za vremensko razdoblje od 60 godina i diskontnu stopu od 2,50% sljedeće:

- 23% do 34% ukupnih troškova građevina odnosi se na troškove energije
- 25% do 37% ukupnih troškova građevina odnosi se na troškove održavanja građevina.

Slično istraživanje, ali na stambenim građevinama izgrađenim između 1924. i 1972. godine i uz razdoblje od 50 godina i diskontnu stopu od 4%, proveli su u Švedskoj *Bejrum* i ostali i utvrdili kako troškovi uporabe čine 25%, a troškovi održavanja 10% ukupnih životnih troškova navedenih građevina [49].

Ciljevi održavanja građevina su sljedeći:

- osiguranje sigurnosnih zahtjeva građevine i pripadajućih usluga
- osiguranje prikladnosti građevine za uporabu
- osiguranje ispunjenja zahtjeva građevine s obzirom na zakonske propise
- izvođenje neophodnih poslova održavanja radi očuvanja vrijednosti imovine
- izvođenje neophodnih poslova održavanja radi očuvanja kvalitete građevine [80].

Iz svega navedenog proizlazi potreba definiranja bitnih pojmova u vezi s održavanjem građevina. Najprije je potrebno definirati dopustive granice razina služnosti i utvrditi tzv. standarde održavanja elemenata zgrade. Standardima se određuje donja dopustiva kvaliteta zbog trošenja ili starenja koju element, sklop i zgrada mogu imati, tako da budu zadovoljeni svi bitni zahtjevi zgrade (stabilnost, zaštita od požara, zaštita od buke, zaštita od gubitka topline i drugi), svi bitni funkcionalni uvjeti za upotrebu (svjetlo, grijanje, hlađenje, čišćenje), te estetski uvjeti (izgled poda, zidova, stropova, kvaliteta pojedinih elemenata) [51].

Održavanje građevina može se podijeliti na neke od sljedećih strategija:

- reaktivno održavanje
- preventivno održavanje, cikličko održavanje vezano uz stvarno stanje građevine
- unaprjeđenje i sanacija kao posljedica novih zakona i propisa [19, 81].

Prema ISO normi 15686, postoji više vrsta održavanja građevine:

- preventivno održavanje
- planirano održavanje
- korektivno održavanje
- održavanje temeljeno na stanju elemenata
- hitno, nepredvidivo održavanje
- održavanje temeljeno na predviđanju
- odgođeno održavanje
- izravno i neizravno održavanje [3].

Prema ISO normi 15686, troškovi održavanja i uporabe obuhvaćaju sljedeće vrste troškova:

- kamata
- osiguranja
- energetskih potreba
- režija
- gospodarenja građevinom
- čišćenja
- zaštite građevine
- godišnjih inspekcijskih pregleda
- održavanja
- naknadnih troškova [3].

Slika 15 prikazuje kategorije ukupnih životnih troškova građevine [1, 82].

U troškove inspekcijskog održavanja ubrajaju se troškovi zakonom propisanih periodičnih pregleda koji predstavljaju niz aktivnosti koje su propisane važećim zakonima i propisima sa svrhom poduzimanja mjera neophodnih za sigurnost, zdravlje i život ljudi. To su različita ispitivanja i pregledi pojedinih dijelova građevine, uređaja i instalacija.

Troškovi uporabe građevine su značajna stavka ukupnih troškova građevina. U pogonske troškove ubrajamo troškove energenata – struja i toplinska energija, troškovi

opskrbe pitkom vodom, odvoza komunalnog otpada i otpadnih voda, troškovi telefona i interneta, te troškovi održavanja higijene objekta i okoliša (materijal za čišćenje, spremačice i domar).

Troškovi preventivnog održavanja uključuju one aktivnosti koje se ponavljaju u relativno istim vremenskim intervalima radi zadržavanja definirane razine služnosti građevine.

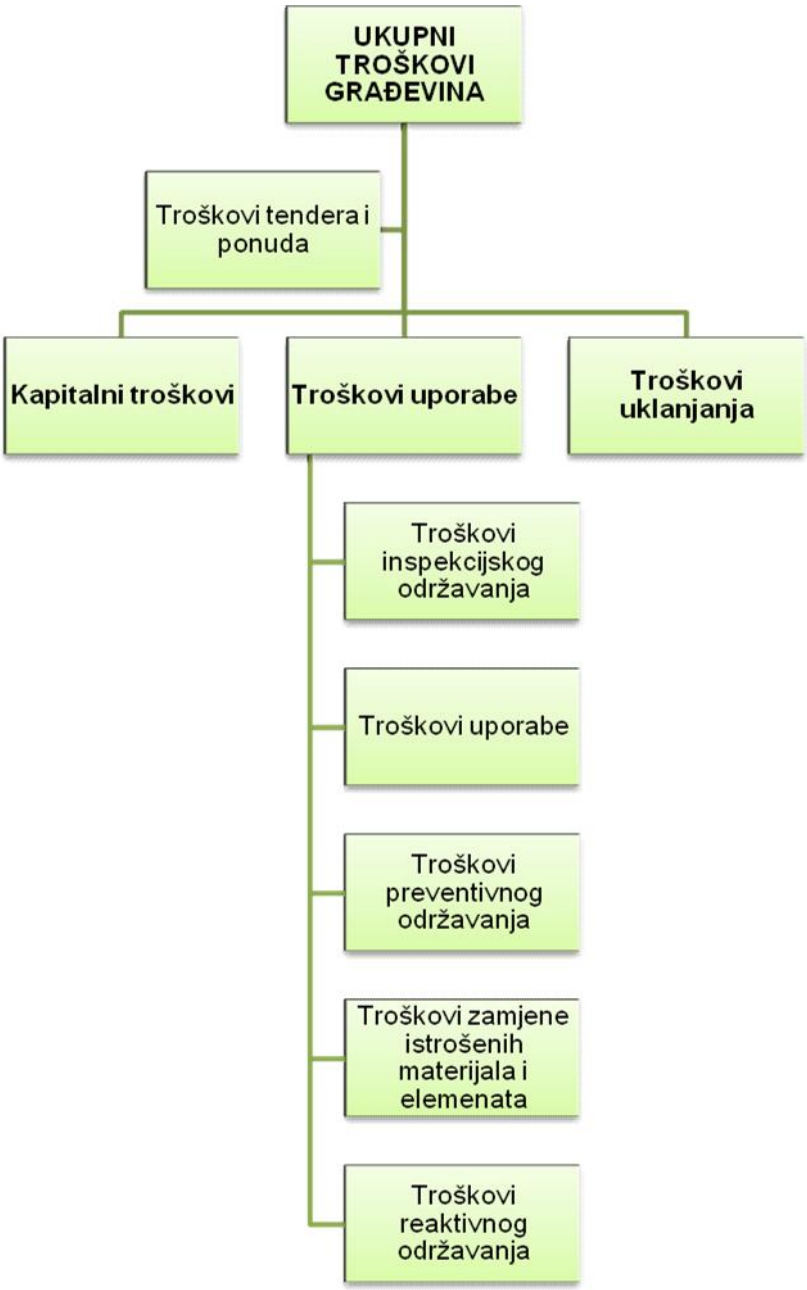

Slika 15 Kategorije ukupnih troškova [1, 82]

Troškovi zamjene istrošenih materijala i elemenata obuhvaćaju troškove aktivnosti baziranih na ostvarenim izmjenama pojedinih dotrajalih materijala i elemenata građevine.

Raspon troškova reaktivnog održavanja je nepredvidiv budući da je gotovo nemoguće predvidjeti sve moguće kvarove. Broj tih aktivnosti je velik, jer obuhvaća popravke i zamjene elemenata i materijala u sklopu intervencija u trenutku kada dođe do kvarova i oštećenja.

2.1 MODELI OPTIMIZIRANJA TROŠKOVA ODRŽAVANJA I UPORABE

Više je razloga za nepostojanje jedinstvenog modela izračuna troškova životnog ciklusa, neki od njih su svakako postojanje različitih sustava prikupljanja i obrade podataka o troškovima održavanja i uporabe građevine te postojanje vrlo različitih uređaja, sustava i opreme za koje se računaju troškovi životnog ciklusa [28]. Većina postojećih modela za izračun troškova životnog ciklusa građevina kao i troškova održavanja i uporabe građevina ima dva glavna nedostatka, a to su niska razina točnosti i mogućnost primjene samo u određenoj fazi životnog ciklusa građevine [83].

Najjednostavnija podjela ovih modela je na opće i posebne modele, opći modeli nisu vezani uz neki određeni sustav ili opremu, dok su posebni modeli uglavnom matematički modeli namijenjeni isključivo sustavu ili opremi [28].

Većina prikazanih modela obuhvaća svojom strukturom sve troškove koji se javljaju tijekom životnog vijeka građevine, a neki od njih orijentirani su na troškove održavanja i uporabe. Različiti autori u svojim modelima obuhvaćaju različite troškove, ovisno o prihvaćenoj strukturi troškova, pri čemu je u nekim modelima moguće izdvojiti i troškove održavanja i uporabe, a u nekima ne.

U nastavku će biti prikazani neki od postojećih matematičkih modela troškova životnog ciklusa i troškova održavanja i uporabe od kojih je većina zasnovana na metodi neto sadašnje vrijednosti, a razlika je u nomenklaturi i strukturi troškova.

Model koji je razvilo udruženje ASTM-a [22, 25] (*The American Society for Testing and Materials*, 1983.) jedinstven je po tome što od troškova održavanja izdvaja troškove energije, što omogućava primjenu različitih diskontnih stopa koje odražavaju različite stope inflacije. Izraz za model glasi:

$$NPV = C + R - S + A + M + E \tag{1}$$

gdje su:

- *C* troškovi investicije
- *R* troškovi zamjene
- *S* preostala vrijednost na kraju životnog vijeka
- *A* troškovi održavanja, uporabe i popravaka koji se javljaju svake godine
- *M* troškovi održavanja, uporabe i popravaka koji se javljaju periodično tijekom životnog vijeka
- *E* troškovi energije.

Model koji su razvili *Bromilow* i *Pawsey* (1987.) [22, 25, 35] klasificira troškove održavanja na one koji se javljaju kontinuirano i periodično tijekom životnog vijeka. Izraz za model glasi:

$$NPV = C_{0i} + \sum_{i=1}^{n} \sum_{t=1}^{T} C_{it}(1+r_{it})^{-t} + \sum_{j=1}^{m} \sum_{t=1}^{T} C_{it}(1+r_{jt})^{-t} - d \cdot (1+r_d)^{-T} \tag{2}$$

gdje su:

- C_{0i} troškovi nabave u trenutku t=0, uključujući troškove koncipiranja, definiranja i izvođenja kao i sve ostale troškove koji se mogu javiti tijekom postupka nabave
- C_{it} godišnji troškovi u trenutku *t* (0≤t≤T) funkcije *i* (0≤i≤n) kao što su održavanje, čišćenje, troškovi energije i slični troškovi, a javljaju se kontinuirano svake godine
- C_{jt} diskontinuirani troškovi funkcije *j* (0≤j≤m) kao što su bojanja i zamjena komponenti u određeno vrijeme tijekom životnog vijeka
- r_{it} *i* r_{jt} diskontne stope funkcija *i* i *j*
- *d* vrijednost građevine na kraju životnog vijeka umanjena za troškove uklanjanja
- r_d diskontna stopa u trenutku uklanjanja građevine.

Osnovna karakteristika ovoga modela je podjela aktivnosti održavanja na one koje se javljaju redovitim godišnjim ritmom i one koje se javljaju svakih nekoliko godina.

Mnogi znanstvenici koriste najjednostavniju formulu za izračun troškova životnog ciklusa (*Flanagan* i ostali, 1989.) [25, 84] koja glasi:

$$NPV = \sum_{i=0}^{T} \frac{C_t^i}{(1+r)^t} \tag{3}$$

Kako bi se ovaj izraz mogao primijeniti, potrebno je svaki trošak izraziti preko ekvivalentnih kretanja troškova tijekom razdoblja analize. Nedostatak metode je što je računski složena, a osim toga nije moguće utvrditi udio pojedinih skupina troškova u ukupnim životnim troškovima.

Sobanjo (1999) [25, 85] predlaže model izračuna troškova životnog ciklusa na *fuzzy set* teoriji, ovaj model pretpostavlja da svi troškovi javljaju godišnje i to je ujedno i nedostatak modela. Izraz za izračun glasi:

$$NPV = \sum C_0 + \sum FA(1+r)^{-t} + \sum A \frac{\left(1-(1+r)^{-t}\right)}{r} \tag{4}$$

gdje su:

- C_0 troškovi nabave u trenutku t=0
- *FA* količina novčanih sredstava u budućnosti
- *A* troškovi održavanja, uporabe i popravaka koji se javljaju svake godine.

Model koji su razvili *Kishk* i *Al-Hajj* (2000) [18, 25, 85] računa troškove životnog ciklusa mogućnosti „*i*“ kao neto sadašnju vrijednost svih troškova i vrijednosti nakon uklanjanja prema izrazu:

$$NPV_i = C_{0i} + PWA \sum_{j=1}^{nar_i} A_{ij} + \sum C_{ik} \cdot PWN_{ik} - PWS \cdot SV_i \tag{5}$$

gdje su:

- C_{0i} troškovi nabave u trenutku t=0
- *PWA* sadašnja vrijednost anuiteta
- *A* troškovi održavanja, uporabe i popravaka koji se javljaju svake godine mogućnosti *i*
- *C* troškovi mogućnosti *i* koje se javljaju diskontinuirano
- *PWS* sadašnja vrijednost jedne uplate u trenutku *t*
- *SV* vrijednost nakon uklanjanja
- nar_i broj troškova koji se javljaju svake godine
- PWN_{ik} diskontni faktor za troškove koji se ne javljaju svake godine.

Ova metoda ima tri posebnosti, prva je da je diskontni faktor izražen na način da uzima u obzir i troškove koji se ne javljaju u kontinuiranom godišnjem ritmu i to prema izrazu:

$$PWN_{ik} = \frac{1-(1+r)^{-n_{ik} f_{ik}}}{(1+r)^{f_{ik}} - 1} \tag{6}$$

Druga je posebnost postavljanje izraza za broj pojava takvih troškova:

$$n_{ik} \begin{cases} \text{int}\left(\dfrac{T}{f_{ik}}\right) & \text{postavljen tako je } \text{rem}\left(\dfrac{T}{f_{ik}}\right) \neq 0 \\ \dfrac{T}{f_{ik}} - 1 \end{cases} \tag{7}$$

gdje su:

- *T* razdoblje analize
- *r* diskontna stopa
- n_{ik} broj ponavljanja troškova koji se ne javljaju svake godine
- f_{ik} učestalost pojave troškova koji se ne javljaju svake godine [86-87].

Izrazom 7 se u obzir ne uzimaju diskontinuirani troškovi (troškovi koji se ne javljaju godišnjim ritmom) koji se javljaju na kraju posljednje godine životnog vijeka.

Treća posebnost je da su godišnji troškovi suma nar_i komponenti A_j, kao što su troškovi održavanja i uporabe.

Prikazani model autori su dalje razvili i dali izraz za izračun troškova životnog ciklusa mogućnosti različitog životnog vijeka preko ekvivalentnih godišnjih troškova. Prednosti modela ostale su iste kao i kod prethodnog, a izraz glasi:

$$EAC_i = \sum_{j=1}^{nar_i} A_{ij} + AEI_i \cdot C_{0i} + \sum_{m=1}^{nno_i} F_{im} \cdot AEO_i + \sum_{k=1}^{nnr_j} C_{ik} AEN_{ik} - AES_i \cdot SV_i \tag{8}$$

Ovdje su *AES*, *AEI*, *AEO* i *AEN* jednoliki godišnji faktori ekvivalencije preostale vrijednosti nakon uklanjanja inicijalnih (početnih) troškova koji se javljaju jednokratno i troškova koji se ne javljaju svake godine, a računaju se prema izrazima:

$$AEI_i = \frac{r}{1-(1+r)^{-T_i}} \tag{9}$$

$$AEN_{ik} = \frac{r(1-(1+r)^{-n_{ik} f_{ik}})}{(1-(1+r)^{-T_i})((1+r)^{f_{ik}}-1)} \tag{10}$$

$$AES_i = \frac{1}{(1+r)^{T_i}-1} \tag{11}$$

$$AEO_{im} = \frac{r(1+r)^{-t_{im}}}{(1+r)^{-T}-1} \tag{12}$$

gdje su:

- T_i životni vijek mogućnosti *i* u godinama
- t_{im} vrijeme pojave jednokratnog troška mogućnosti *i*
- F_{im} jednokratni trošak mogućnosti *i*
- c_{ik} trošak mogućnosti *i* koji se ne javlja svake godine
- noo_i broj jednokratnih troškova koji se ne ponavljaju
- nnr_i broj troškova koji se ponavljaju, ali ne svake godine [86].

Kirkham (2002) predlaže sljedeći stohastički model za izračun troškova životnog ciklusa bolničkih građevina [35, 88]:

$$WLCC = \sum_{n=1}^{i} \frac{FM_C + E_C + M_C + F_C + R_C}{(1+r)^i} \tag{13}$$

gdje su:

- *WLCC* ukupni troškovi životnog ciklusa
- FM_c troškovi gospodarenja građevinom
- E_c troškovi energije
- M_c troškovi održavanja
- F_c troškovi financiranja
- R_c preostala vrijednost
- *r* diskontna stopa
- *i* broj godina.

Prema samom autoru, nedostatak ovog modela je taj što je isti primjenjiv samo za bolničke građevine [35].

Marenjak i ostali razvili su (2002.) [1] model proračuna ukupnih životnih troškova projekta prema sljedećem izrazu:

$$UTP_P = Ti_p + Tfm_p \pm Tr_p \tag{14}$$

$$Tfm_p = \sum_{i=1}^{e} Tfm_e + \sum_{i=1}^{z} Tfm_z \tag{15}$$

$$Ti_p = \sum_{i=1}^{e} Ti_e + \sum_{i=1}^{z} Ti_z \tag{16}$$

gdje su:

- UTP_p ukupni troškovi projekta (npr. bolnice, škole itd.)
- Ti_p inicijalni (kapitalni) troškovi projekta
- Ti_z ostali inicijalni troškovi kao što su troškovi zemljišta, projektiranja i dr.
- Tfm_p troškovi "*facility managementa*" na razini projekta
- Tfm_z troškovi "*facility managementa*" koji se ne odnose na fizičke elemente građevine (npr. troškovi osiguranja projekta, troškovi potrošnje električne energije i dr.)
- Tr_p troškovi rušenja, na razini projekta.

Predloženi model i struktura prikupljanja i analize ukupnih troškova projekta omogućuje generiranje različitih rješenja projekta, a samim time i minimiziranje financijskih i tehničkih rizika [1].

El-Haram i ostali predlažu (2002.) [47, 50] model izračuna troškova životnog ciklusa mogućnosti svih elemenata građevine prema izrazu:

$$WLC = C_c + \left(\sum_{i=1}^{n} \left(\sum_{j=1}^{m} Oc_j \right) + \sum_{i=1}^{n} \left(\sum_{j=1}^{m} Mc_j \right) + \sum_{i=1}^{k} Rc_i \right) \pm Dc \tag{17}$$

gdje su:

- *WLC* ukupni troškovi životnog ciklusa
- *Cc* troškovi izgradnje
- *Oc* troškovi uporabe
- *Mc* troškovi održavanja (reaktivnog i preventivnog)
- *Rc* troškovi zamjene istrošenih materijala i elemenata
- *Dc* troškovi uklanjanja
- *N* broj godina (očekivani životni vijek ili broj godina analize)
- *m* broj aktivnosti vezanih uz uporabu i održavanje
- *k* broj izmjena.

Predloženi model primjenjiv je na elemente građevine kao i za procjenu troškova cijele građevine, pri čemu je potrebno u obzir uzeti i ostale troškove kao što su troškovi zemljišta, naknade u etapi pripreme projekata i slično [47, 50].

Općeniti izraz za izračun troškova životnog ciklusa građevina dala je autorica *Sterner* u svojoj doktorskoj disertaciji 2002. godine i on glasi:

$$LCC = I_0 + \sum_{t=0}^{N} O \cdot PV_{sum} + \sum_{t=0}^{N} M \cdot PV_{sum} - S \cdot PV \tag{18}$$

gdje je:

$$PV_{sum} = \frac{(1+r)^t - 1}{r(1+r)^t} \tag{19}$$

$$PV = \frac{1}{(1+r)^t} \tag{20}$$

gdje su:

- *LCC* ukupni troškovi životnog ciklusa
- I_0 troškovi izgradnje kojima su obuhvaćeni troškovi zemljišta, projektiranja, izgradnje, financiranja i slično
- *O* troškovi uporabe kojima su obuhvaćeni godišnji troškovi energije, čišćenja, osiguravanja i slično
- *M* troškovi održavanja kojima su obuhvaćene izmjene i popravci građevine i njezinih dijelova
- *S* preostala vrijednost građevine po prestanku uporabe
- PV_{sum} suma troškova izraženih preko neto sadašnje vrijednosti
- *N* dužina trajanja studije slučaja
- *t* vremenska varijabla
- *r* diskontna stopa.

Adeli i *Sarma* (2006.) razvili su model za proračun troškova životnog ciklusa čeličnih konstrukcija koji nije moguće iskoristiti za optimiziranje ukupnih troškova životnog ciklusa zbog nedostatka statističkih podataka za ostale kategorije troškova. Prema modelu, troškovi životnog ciklusa mogu se izračunati prema sljedećem izrazu [89]:

$$C_{Lifecycle} = C_{Initial} + \sum \frac{1}{(1+i)^{y_{n1}}} C_{Maintenance} + \sum \frac{1}{(1+i)^{y_{n2}}} C_{Inspection} + \sum \frac{1}{(1+i)^{y_{n3}}} C_{Repair} + \\ + \sum \frac{1}{(1+i)^{y_{n4}}} C_{Operating} + \frac{1}{(1+i)^{y_{n5}}} C_{Failure} + \frac{1}{(1+i)^{y_{n6}}} C_{Dismantel} \tag{21}$$

gdje su:

- $C_{Lifecycle}$ ukupni troškovi životnog ciklusa
- $C_{Initial}$ početni troškovi
- $C_{Maintenance}$ troškovi održavanja

- $C_{Inspection}$ troškovi pregleda
- C_{Repair} troškovi popravaka
- $C_{Operating}$ troškovi uporabe
- $C_{Failure}$ troškovi uklanjanja kvarova
- $C_{Dismantle}$ troškovi demontaže.

Diskontna stopa obilježena je s *i*, a godina u kojoj se trošak pojavi je $y_{n1}, \ldots, y_{n6}$.

Za razliku od prikazanih modela, postoje i oni koji su orijentirani na troškove održavanja i uporabe građevina. U nastavku će biti prikazani modeli koji se isključivo odnose na ukupne troškove održavanja i/ili troškove uporabe građevina.

Al-Hajj i *Horner* su proveli 1991. godine istraživanje o troškovima održavanja jedanaest studenskih domova, šest predavaonica i tri laboratorija tijekom osamnaest godina, počevši od 1972. godine. Istraživanjem su došli do zaključka kako je moguće odrediti troškovno značajne stavke na način da se u obzir uzmu samo stavke čiji su troškovi veći od prosječnih. Zaključeno je da otprilike 15% svih stavki daje oko 85% ukupnih troškova održavanja. Istraživanja su pokazala da se povijesni podatci o troškovima projekata mogu koristiti kako bi se razvio model praćenja i predviđanja troškova održavanja istraživanih građevina [41].

Očita dosljednost odnosa V_V/N i N_V/N gdje su:

- V ukupni trošak, a V_V ukupni trošak stavke čija je vrijednost veća od prosječne
- N ukupni broj stavki, a N_V broj stavki čiji su troškovi veći od prosječne vrijednosti

omogućava razvoj modela za predviđanje troškova održavanja građevine prema izrazu [25, 41]:

$$T_C = \frac{1}{CMF}\sum_{i=1}^{n} CSI_i \tag{22}$$

gdje su:

- T_c ukupni troškovi
- *CMF* faktor modela troškova (omjer troškova troškovno značajnih stavki i ukupnih troškova)
- CSI_i troškovi *i-te* troškovno značajne stavke.

Za mjerodavni faktor modela troškova (*CMF*) odabran je onaj s najmanjim koeficijentom varijacije. Izraz za model može se raspisati i na sljedeći način:

$$R_C = \frac{1}{CMF}\sum_{i=1}^{n}\left[(c_1+c_2)+(e_1+e_2+e_3)+(a_1+a_2)+(o_1+o_2)+(m_1+m_2)\right]_i \tag{23}$$

gdje su:

- R_c ukupni troškovi održavanja

- *CMF* faktor modela troškova (0.87)
- *n* broj godina
- c_1 troškovi čišćenja, c_2 troškovi praonice rublja
- e_1 troškovi plina, e_2 troškovi struje, e_3 troškovi loživog ulja
- a_1 troškovi upravljanja (naknade), a_2 troškovi zaštitarskih službi i nadzora
- m_1 troškovi unutarnjeg uređenja, m_2 troškovi popravaka krova.

Točnost modela računata je kao postotak razlike troškova predviđenih modelom i stvarnih troškova kao:

$$A_C = \left[\frac{PC - AC}{AC}\right] \cdot 100\% \tag{24}$$

gdje su:

- A_c točnost izračunatih troškova
- *PC* troškovi predviđeni modelom i
- *AC* stvarni troškovi.

Srednja vrijednost točnosti modela za seriju ispitivanja računa se kao aritmetička sredina točnosti prema izrazu:

$$\overline{A}_C = \frac{\sum_{i=1}^{n} A_C}{n} \tag{25}$$

gdje su:

- A_c točnost izračunatih troškova na danom setu podataka za validaciju modela
- *n* broj setova podataka.

Ukupna točnost modela definirana je disperzijom pojedinačnih točnosti pojedinih kategorija građevina. Ova disperzija predstavlja se standardnom devijacijom. Ukupna točnost modela *Am* se tada definira kao:

$$A_m = \overline{A}_C - \text{std of } A_C \tag{26}$$

Točnost koju su naveli autori *Al-Hajj* i *Horner* od ±5% tijekom razdoblja od jedne do osamnaest godina kritizirala je *Young* (1992.) u svom doktoratu i zaključila kako do većih odstupanja dolazi zbog sljedeća tri razloga [25]:

1. način vođenja podataka o troškovima jednog od izvora za stvaranje modela drugačiji je od ostalih
2. model u obzir ne uzima različitost materijala i komponenti između građevina koje su sudjelovale u istraživanju
3. pojava povremeno visokih troškova pojedinih troškovno značajnih stavki.

Sami autori prva dva razloga naveli su kao ograničenja modela, a treći razlog pokušali su otkloniti metodom kliznih prosjeka (*moving averages*). Međutim, postoje još četiri zamjerke modelu [25]:

1. kod troškovne značajnosti stavki pretpostavlja se linearni odnos, što ne mora uvijek biti slučaj;
2. izvori podataka za stvaranje modela su ograničeni;
3. metoda zanemaruje neke od važnijih karakteristika građevina kao što su starost građevine, lokacija, uporabni uvjeti itd.;
4. dobiveni su povijesni podatci koji su bili dostupni, a ne oni koji bi slijedili definiranu strukturu troškova.

Uz sve navedene nedostatke, ovo je jedna od jednostavnijih metoda predviđanja troškova održavanja građevina koja ne zahtijeva velike setove podataka kako bi se predvidjeli troškovi održavanja u budućnosti [41].

Kirkham i ostali (1999.) su razvili model za proračun troškova energije sportskih centara uz pomoć regresijske metode s dvije nezavisne ulazne varijable, površinom građevina i brojem korisnika. Osnovno ograničenje modela je ograničenost na sportske građevine i troškove energije. Model ima dva oblika [24]:

$$C_E = 1.203 + 0.97 \cdot \text{površina} \tag{27}$$

$$C_E = 1.217 + 0.642 \cdot \text{površina} + 0.206 \cdot \text{korisnici} \tag{28}$$

Primjenom navedenog modela moguće je izračunati troškove energije sportskih građevina uporabom samo dvije varijable, površine građevina i broja korisnika. Oba izraza koriste se za izračun troškova energije, ali s različitim regresijskim koeficijentima i brojem varijabli.

2.2 SAŽETAK I UVOD U PROBLEMATIKU TROŠKOVA ODRŽAVANJA I UPORABE GRAĐEVINA SVEUČILIŠTA U OSIJEKU

U prva dva poglavlja rada pregledom literature utvrđene su osnovne zapreke, ograničenja i prednosti primjene metode troškova životnog ciklusa, kao i važnost troškova održavanja i uporabe građevina koji čine veliki dio ukupnih životnih troškova građevina. Dan je pregled na osnovi dostupne relevantne literature vezane za područja interesa.

Prikazan je povijesni razvoj i definicije metodologije troškova životnog ciklusa građevina uz detaljan pregled postojećih modela troškova životnog ciklusa građevina.

Pregledom literature s područja troškova životnog ciklusa građevina i postojećih modela troškova održavanja i uporabe građevina, može se zaključiti sljedeće:

- najveći dio ukupnih životnih troškova građevina čine troškovi održavanja i uporabe građevina
- postojeći modeli troškova životnog ciklusa i modeli održavanja i uporabe građevina većinom se ne temelje na povijesnim podatcima o troškovima građevina
- modeli koji se i temelje na povijesnim podatcima o troškovima građevina uglavnom su razvijeni na osnovi dostupne strukture troškova, a ne na osnovi definirane strukture troškova
- ne postoje baze podataka o troškovima koje bi se mogle rabiti za buduća istraživanja ili ažurirati radi unaprjeđenja postojećih modela
- ne postoji okvir za sistematizaciju podataka
- nepostojanje jednostavnih modela koji pri izračunu troškova održavanja i uporabe uzimaju u obzir neke od karakteristika građevine ili načina uporabe.

S obzirom na navedeno, istraživanje u ovom radu bit će usmjereno na fakultetske građevine Sveučilišta u Osijeku. Te su građevine posebne iz nekoliko razloga:

- nepostojanje podataka o troškovima građenja
- građevine su uglavnom spomenici kulturne baštine i nije predviđeno njihovo uklanjanje
- građevine stare uglavnom više od 50 godina
- javne građevine čije se održavanje i uporaba financira sredstvima iz proračuna
- poseban način uporabe koji karakterizira veliki broj korisnika tijekom godine, ali i kratko razdoblje tijekom godine kada je broj korisnika izuzetno mali.

Za potrebe ovog istraživanja izrađeni su upitnici o karakteristikama građevina i uporabi građevina te upitnici o troškovima održavanja i uporabe tih građevina. Upitnici su poslani svim sastavnicama Sveučilišta u Osijeku radi prikupljanja potrebnih podataka. Podatci su prikupljeni za vremensko razdoblje od 1998. do 2009. godine uz unaprijed definiranu strukturu troškova. Nakon statističke obrade podataka pristupilo se izradi regresijskih modela predviđanja troškova održavanja i uporabe građevina Sveučilišta u Osijeku. Radi validacije dobivenih modela, prikupljeni su podatci o troškovima održavanja i uporabe građevina izvan Sveučilišta u Osijeku kako bi se utvrdila primjenjivost modela i na ostalim sveučilištima.

Razvijena metodologija će omogućiti:

1. evidenciju stvarnih povijesnih troškova ovih građevina
2. stvaranje baze podataka o troškovima održavanja i uporabe s mogućnošću ažuriranja
3. analizu prikupljenih podataka koji će omogućiti predviđanje budućih troškova održavanja i uporabe građevina
4. analizu informacija o troškovima održavanja i uporabe pri projektiranju novih građevina iste namjene
5. kontrolu troškova održavanja i uporabe fakultetskih građevina.

3 PRIKUPLJANJE I OBRADA PODATAKA

Cilj disertacije je razvoj modela procjene troškova održavanja i uporabe fakultetskih građevina Sveučilišta u Osijeku. To je moguće ostvariti prikupljanjem podataka o troškovima održavanja i uporabe za određeno vremensko razdoblje, ali i prikupljanjem podataka o karakteristikama građevina. Povijesni podatci o troškovima projekata mogu se i već su se koristili u različitim istraživanjima kako bi se razvio model praćenja i predviđanja svojstava, ali i troškova [90-91].

Nameće se pitanje po čemu su građevine namijenjene obavljanju znanstveno-istraživačkog rada i edukacije različite od ostalih građevina javne namjene? Prije svega to su građevine koje se koriste već dulji niz godina i predviđa se njihova uporaba u narednom duljem vremenskom razdoblju. Ove građevine financiraju se proračunskim sredstvima, specifične su i po tome što rade uglavnom u dvije smjene, a postoji razdoblje tijekom godine (mjesec i pol do dva mjeseca) kada je broj korisnika izrazito smanjen u odnosu na ostatak godine.

Kako bi se istražila veza troškova i varijabli koje utječu na njih, potrebno je stvaranje baze podataka iz koje će se ta veza moći definirati regresijskom analizom. Regresijskom analizom moguće je pronalaženje analitičko-matematičkog oblika veze između jedne ovisne (troškovi održavanja i uporabe) i jedne ili više neovisnih varijabli (podatci o funkcionalnim površinama građevine, starost građevine, broj godina uporabe građevine, podatci o korisnicima i smjenama).

3.1 UPITNIK

Radi stvaranja baze podataka o troškovima održavanja i uporabe fakultetskih građevina koja bi omogućila definiranje matematičkog modela procjene troškova održavanja i uporabe, svim sastavnicama Sveučilišta u Osijeku poslana je zamolba za pristup potrebnim podatcima za razdoblje od 1997. do 2008. godine.

Kao početna godina za koju su se tražili podatci uzeta je 1997. godina kako se troškovima održavanja i uporabe ne bi obuhvatili i troškovi nastali zbog ratnih razaranja i obnove, odnosno kako bi se utjecaj tih troškova sveo na što je moguće manju mjeru. Kao posljednja godina za koju su traženi podatci analizirana je 2008. godina, jer su upitnici poslani tijekom 2009. godine pa za nju podatci o troškovima nisi bili dostupni u cijelosti. U zamolbi je navedeno kako će se podatci koristiti isključivo za potrebe istraživanja.

Uz zamolbu fakultetima poslan je i upitnik koji se sastojao od četiri dijela u kojima su se tražili sljedeći podatci:

1. Opći podatci o građevini
   Traženi su podatci o starosti građevine, vremensko razdoblje u kojem se građevina koristi te podatci o ukupnoj površini građevine i površini parcele na kojoj se nalazi.
2. Planiranje održavanja građevine

Cilj ovog upitnika bio je ispitati planiranje održavanja građevina, odnosno postojanje plana i osobe odgovorne za održavanje, plana nadogradnje i rekonstrukcija i postojanje strategija o broju korisnika za buduća vremenska razdoblja.

3. Podatci o uporabi građevine
   Ovim upitnikom dobiveni su podatci o funkcionalnim površinama građevina, broju smjena ustanova te podatci o broju korisnika, djelatnika i studenata tijekom vremenskog razdoblja od 1997. do 2008. godine.
4. Tablični prikaz troškova održavanja i uporabe
   Troškovi održavanja i uporabe razvrstani su u pet skupina kako je i prikazano u poglavlju 2, a za svaku skupinu dan je prijedlog vrste troškova, ali je ostavljena mogućnost unosa novih ako neka vrsta troškova nedostaje. Prikupljani su podatci za sljedeće skupine troškova:
   1. *troškovi periodičnih pregleda građevine*
   2. *troškovi zamjene istrošenih materijala i elemenata građevine*
   3. *troškovi periodičnih radova i popravaka na građevini*
   4. *troškovi reaktivnog održavanja*
   5. *troškovi uporabe*
   6. *ukupni troškovi održavanja i uporabe kao ukupni iznos svih prethodno navedenih skupina.*

Upitnik koji je poslan i na osnovi kojeg su prikupljeni potrebni podatci nalazi se u prilogu 1.

Tablica 3 prikazuje popis građevina sastavnica Sveučilišta u Osijeku kojima su poslane zamolbe za pristup potrebnim podatcima tijekom 2009. godine.

Tablica 3 Građevine sastavnica Sveučilišta u Osijeku

RB	NAZIV
1	Ekonomski fakultet
2	Elektrotehnički fakultet
3	Građevinski fakultet
4	Katolički bogoslovni fakultet
5	Medicinski fakultet
6	Poljoprivredni fakultet
7	Rektorat
8	Pravni fakultet
9	Prehrambeno-tehnološki fakultet
10	Strojarski fakultet
11	Filozofski fakultet
12	Učiteljski fakultet
13	Odjel za matematiku i fiziku
14	Odjel za biologiju i kemiju
15	Umjetnička akademija

3.2 ODAZIV NA ANKETU I PRIKUPLJENI PODATCI

Podatci su prikupljani tijekom 2009. i 2010. godine, a odaziv na upitnik prikazan je na slici 16. Među fakultetima koji su dostavili podatke (13 fakulteta) bilo je i onih podataka koji su bili nepotpuni, odnosno podatci o troškovima nisu bili dani ili su dani samo za neku od ponuđenih skupina troškova. Prema tim podatcima određeno je koje građevine se mogu koristiti pri definiranju baze podataka o troškovima održavanja i uporabe. Osnovi uvjet koji je morao biti zadovoljen da bi podatci bili valjani bio je potpunost podataka. Struktura valjanosti podataka građevina koje su sudjelovale u istraživanju je prikazana na slici 17.

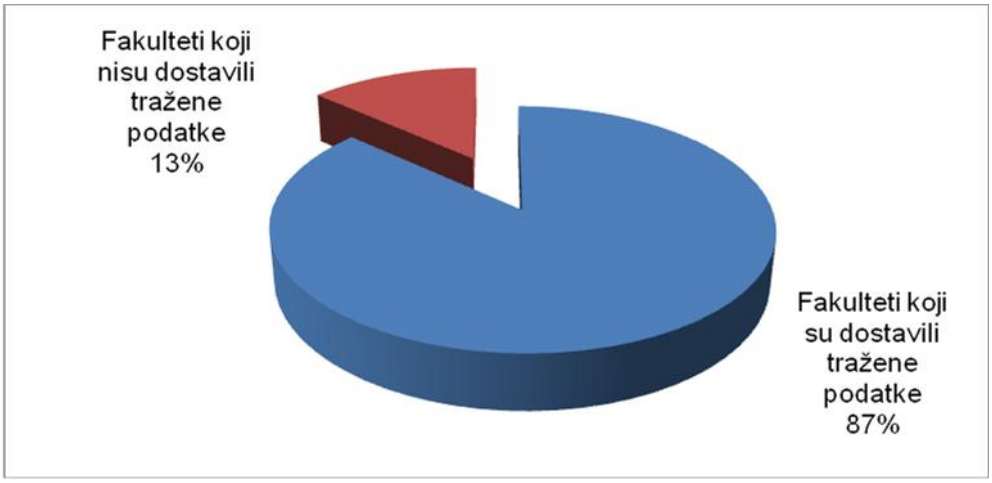

Slika 16 Odaziv na istraživanje fakulteta Sveučilišta u Osijeku

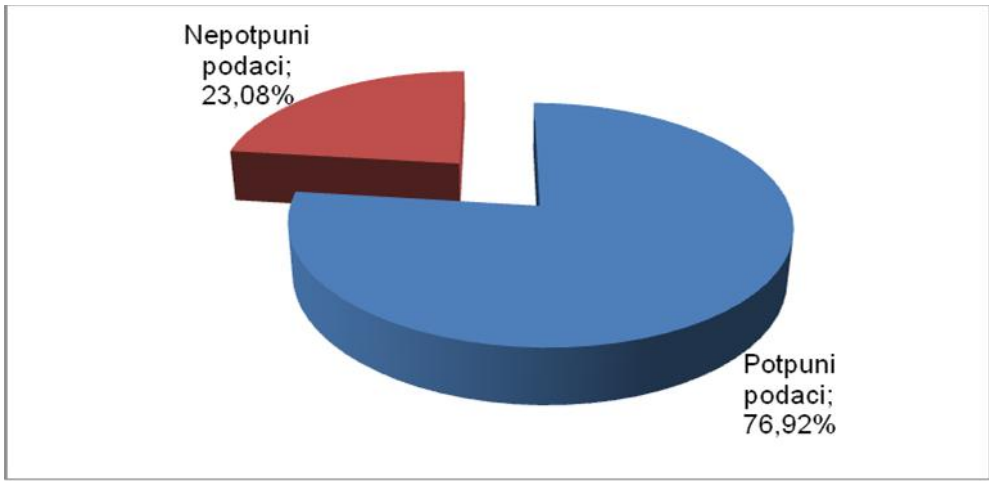

Slika 17 Struktura valjanosti dostavljenih podataka

Nakon prikupljanja i obrade podataka javili su se sljedeći problemi: u nekim građevinama djelatnost obavljaju i dva fakulteta, neki fakulteti imaju i dislocirane studije izvan Osijeka te problem kod fakulteta kod kojih se djelatnost odvija u nekoliko građevina.

Prvi problem riješen je na način da su se podatci o troškovima i korisnicima oba fakulteta zbrajali, jer je područje interesa bila građevina kao cjelina, pri čemu su i podatci o

funkcionalnim prostorima bili jednaki za obje građevine te je u nastavku istraživanja takva građevina promatrana kao jedinstvena.

Drugi problem riješen je tako što se nisu uzimali podatci o troškovima dislociranih građevina.

Treći problem kod nekih građevina bilo je jednostavno riješiti, jer su neka računovodstva bila u mogućnosti dostaviti odvojene troškove po lokacijama. Kod dva fakulteta ovo nije bilo moguće, ali se radilo o građevinama koje se nalaze u neposrednoj blizini jedna drugoj i približno su jednake starosti. Ovaj problem riješio se zbrajanjem funkcionalnih površina i broja korisnika za koje je prikupljena samo jedna struktura troškova održavanja i uporabe.

S obzirom na navedeno i činjenicu kako neki od fakulteta dijele istu građevinu, u konačnici je ostalo osam građevina (uzoraka) za formiranje baze podataka o troškovima održavanja i uporabe.

Broj godina za koje su dostavljeni podatci kretao se od 4 do 12 godina, a podatak o broju godina za koje su dostavljeni podatci nazvan je referentno razdoblje. Struktura podataka prema broju godina za koju su dostavljeni traženi podatci za 8 građevina koje su ušle u izbor za definiranje baze podataka prikazani su na slici 18.

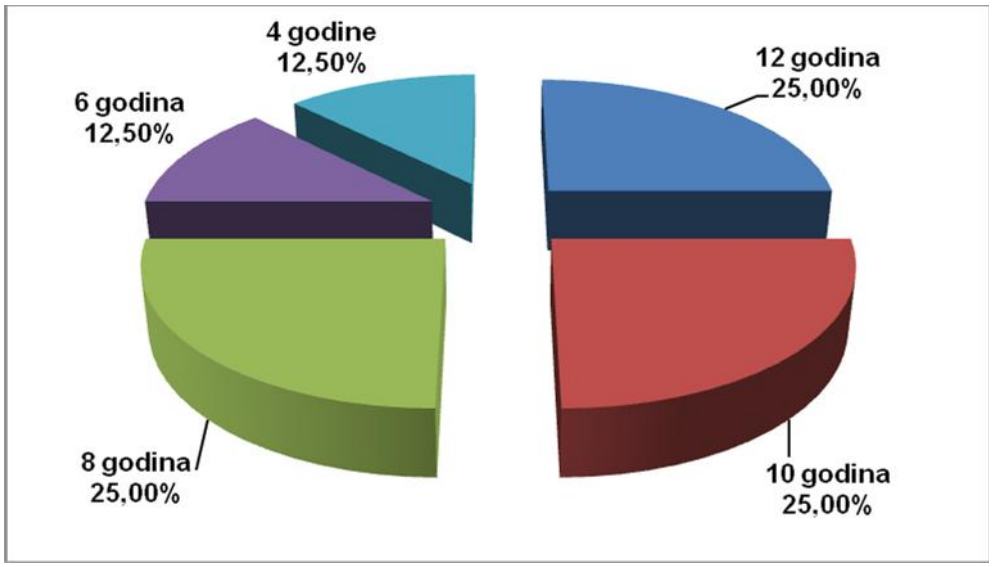

Slika 18 *Struktura podataka prema broju godina za koje su dostavljeni podatci*

Ista zamolba i upitnik koja je poslana sastavnicama Sveučilišta u Osijeku poslana je i na dva fakulteta u Zagrebu te po jedan fakultet u Rijeci i Vukovaru. Prikupljanje podataka o troškovima održavanja i uporabe građevina izvan Osijeka trebalo je omogućiti validaciju modela i definiranje ograničenja primjene modela izvan područja grada Osijeka, odnosno izvan Sveučilišta u Osijeku.

Odaziv na istraživanje bio je daleko manji od onoga na Sveučilištu J. J. Strossmayera, što još jednom potvrđuje činjenicu kako se ovi podatci uglavnom smatraju tajnim i komercijalno osjetljivim [92], unatoč činjenici kako se radi o javnim građevinama.

Odaziv fakulteta kao i valjanost prikupljenih podataka prikazana je na slikama 19 i 20.

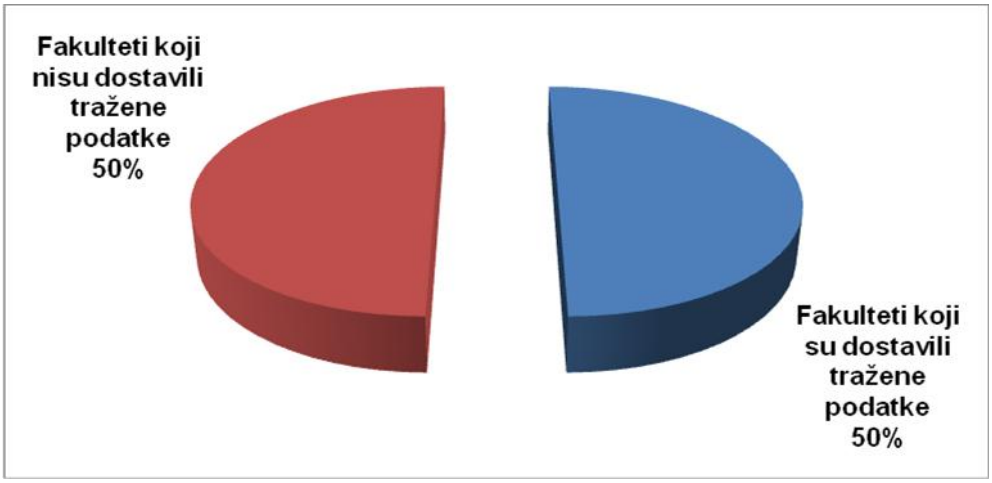

Slika 19 Odaziv na istraživanje fakulteta izvan Sveučilišta u Osijeku

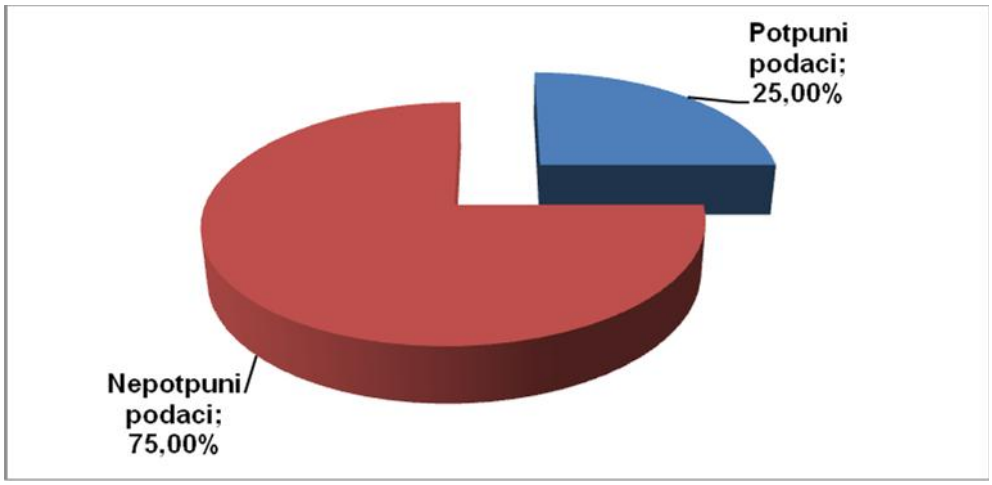

Slika 20 Struktura valjanosti podataka

Iz prikupljenih podataka o troškovima izračunate su godišnje vrijednosti troškova održavanja i uporabe kao i ukupna vrijednost troškova održavanja pojedinih skupina troškova tijekom referentnog razdoblja. U prilogu 2 nalaze se podatci o svim troškovima.

Kako bi se dobili prosječni godišnji nominalni troškovi održavanja i uporabe građevina, ukupna nominalna vrijednost troškova održavanja i uporabe podijeljena je s referentnim razdobljem. Isto je učinjeno i s podatcima o prosječnom broju djelatnika i prosječnom broju studenata. Ostale neovisne varijable kao što su površine, katnost i broj smjena nisu se mijenjale tijekom referentnog razdoblja. Ovaj princip obrade podataka usvojio je i *Al-Hajj* u svojoj doktorskoj disertaciji [22].

U tablici 4 prikazane su vrijednosti prosječnih godišnjih nominalnih troškova održavanja i uporabe za sve građevine koje su prema prethodno navedenim kriterijima odabrane za definiranje baze podataka o troškovima. Pokraj rednog broja u zagradi nalaze se šifre građevina.

Tablica 4 Nominalni prosječni godišnji i nominalni ukupni troškovi održavanja i uporabe

GRUPA TROŠKOVA	UKUPNI NOMINALNI TROŠKOVI ODRŽAVANJA I UPORABE	PROSJEČNI GODIŠNJI NOMINALNI TROŠKOVI ODRŽAVANJA I UPORABE
GRAĐEVINA 1 (F4)		
TROŠKOVI UPORABE	2.909.628	363.703
TROŠKOVI ODRŽAVANJA I UPORABE	4.688.107	586.013
GRAĐEVINA 2 (F9)		
TROŠKOVI UPORABE	4.240.202	424.020
TROŠKOVI ODRŽAVANJA I UPORABE	7.922.043	792.204
GRAĐEVINA 3 (F10)		
TROŠKOVI UPORABE	4.194.322	349.527
TROŠKOVI ODRŽAVANJA I UPORABE	7.704.934	642.078
GRAĐEVINA 4 (F14)		
TROŠKOVI UPORABE	1.584.626	396.157
TROŠKOVI ODRŽAVANJA I UPORABE	5.210.091	1.302.523
GRAĐEVINA 5 (F18)		
TROŠKOVI UPORABE	2.983.156	372.894
TROŠKOVI ODRŽAVANJA I UPORABE	17.445.461	2.180.683
GRAĐEVINA 6 (F8)		
TROŠKOVI UPORABE	5.567.085	463.924
TROŠKOVI ODRŽAVANJA I UPORABE	7.329.090	610.758
GRAĐEVINA 7 (F16)		
TROŠKOVI UPORABE	6.451.920	645.192
TROŠKOVI ODRŽAVANJA I UPORABE	19.610.441	1.961.044
GRAĐEVINA 8 (F6)		
TROŠKOVI UPORABE	4.322.720	720.453
TROŠKOVI ODRŽAVANJA I UPORABE	5.094.829	849.138

Na osnovi pregleda literature i prijašnjih istraživanja slične problematike, utvrđene su neovisne varijable koje se mogu smatrati relevantnim za definiranje modela procjene troškova održavanja i uporabe. Iz upitnika o općim podatcima o građevini, planiranju održavanja građevine i upitnika o podatcima o uporabi građevine bilo je moguće definirati bazu podataka neovisnih varijabli. Popis neovisnih varijabli je dan u tablici 5.

Tablica 5 Popis mogućih neovisnih varijabli modela procjene troškova održavanja i uporabe

VARIJABLA	OPIS VARIJABLE	JEDINICA MJERE
var1	Starost građevine	Godina
var2	Broj godina u uporabi za fakultetsku funkciju	Godina
var3	Refernetno razdoblje (Godine za koje su prikupljeni podaci o troškovima)	Godina
var4	Broj etaža	br
var5	Površina predavaonica	m^2
var6	Površina kabineta	m^2
var7	Površina komunikacija	m^2
var8	Površina sanitarija	m^2
var9	Površina ureda	m^2
var10	Površina knjiznica	m^2
var11	Površina laboratorija	m^2
var12	Ostale funkcionalne površine	m^2
var13	Ukupna površina građevine	m^2
var14	Prosječni broj djelatnika u referentom periodu	br
var15	Prosječni broj studenata u referentom periodu	br
var16	Broj smjena u kojima se odvija nastava	br

Iz navedenih podataka definirana je baza podataka koja je korištena za statističku obradu i koja je prikazana u tablici 6. U tablici se nalaze vrijednosti neovisnih varijabli koje su dobivene anketiranjem i vrijednosti ovisnih varijabli, odnosno prosječni godišnji nominalni troškovi uporabe i troškovi održavanja i uporabe građevina.

Tablica 6 Baza podataka neovisnih i ovisnih varijabli

GRAĐEVINE	Građevina 1	Građevina 2	Građevina 3	Građevina 4	Građevina 5	Građevina 6	Građevina 7	Građevina 8
Starost građevine	49	293	56	110	115	108	243	10
Broj godina u uporabi za fakultetsku funkciju	9	13	23	4	8	33	13	10
Refernetno razdoblje	8	10	12	4	8	12	10	6
Broj etaža	5	3	5	3	3	4	4	5
Površina predavaonica	284	890	1100	1039	965	991	954	550
Površina kabineta	223	661	810	690	804	1013	1170	510
Površina komunikacija	467	957	140	602	1712	1039	2193	620
Površina sanitarija	72	200	680	109	105	214	277	120
Površina ureda	234	344	170	298	357	140	755	400
Površina knjiznica	80	103	120	43	144	89	108	0
Površina laboratorija	219	386	1560	0	533	0	567	510
Ostale funkcionalne površine	795	513	100	1099	183	290	1323	380
Ukupna površina građevine	2375	4573	4680	3881	4803	3775	7345	3090
Prosječni broj djelatnika u referentom periodu	38	87	75	45	59	71	178	170
Prosječni broj studenata u referentom periodu	349	648	448	189	518	2540	858	757
Broj smjena u kojima se odvija nastava	2	2	2	2	2	2	2	1
PROSJEČNI GODIŠNJI NOMINALNI TROŠKOVI UPORABE	363.703,46	424.020,17	349.526,83	396.156,57	372.894,48	463.923,76	645.192,00	720.453,33
PROSJEČNI GODIŠNJI NOMINALNI UKUPNI TROŠKOVI ODRŽAVANJA I UPORABE	586.013,41	792.204,25	642.077,83	1.302.522,79	2.180.682,58	610.757,51	1.961.044,10	849.138,10

3.3 STATISTIČKA OBRADA PODATAKA

3.3.1 Deskriptivna statistika

Na temelju prikupljenih podataka napravljena je deskriptivna analiza. Prvo se pristupilo izračunu udjela pojedinih skupina troškova održavanja u ukupnim troškovima održavanja i uporabe. Svrha ove analize bila je utvrditi udjele pojedinih skupina troškova prije razvoja modele procjene troškova održavanja i uporabe. Na slici 21 prikazani su udjeli pojedinih skupina troškova u prosječnim godišnjim nominalnim troškovima održavanja, a prikazani su rezultati na bazi osam analiziranih građevina Sveučilišta u Osijeku.

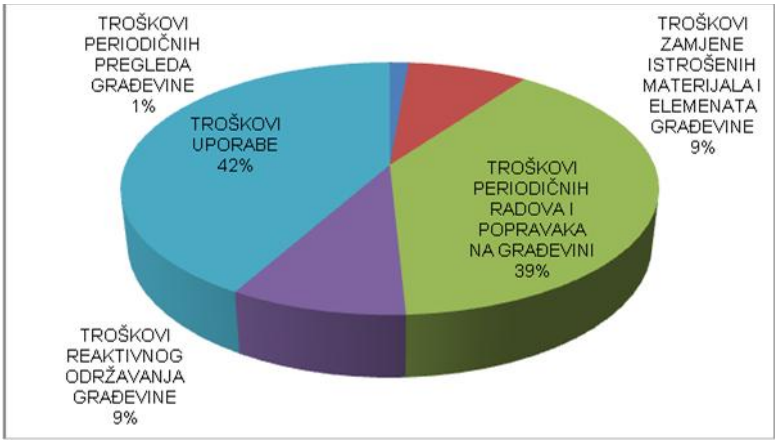

Slika 21 Udio pojedinih skupina troškova u prosječnim godišnjim nominalnim troškovima održavanja

Udjeli pojedinih skupina troškova za pojedinačne građevine ne podudaraju se s onima za sve građevine, što se može objasniti činjenicom kako su podatci dobiveni za različita referentna razdoblja. Na slici 22 prikazani su udjeli pojedinih skupina troškova za sve građevine i to za prosječne godišnje troškove.

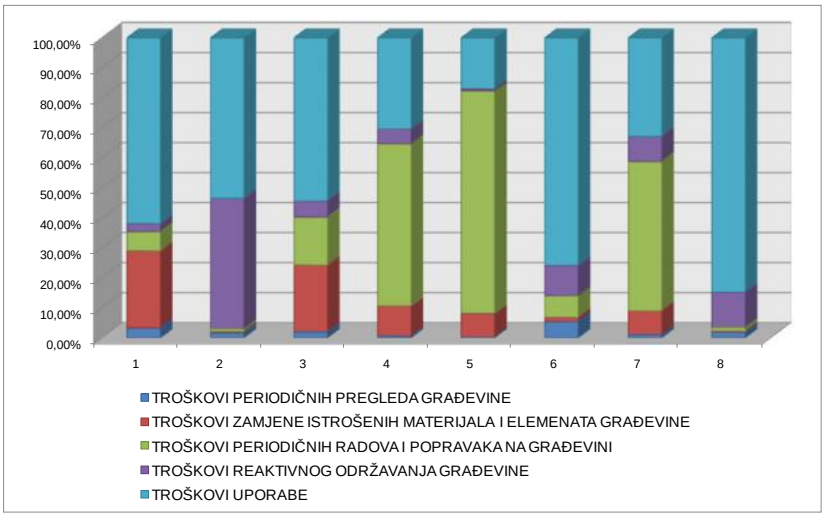

Slika 22 Udio pojedinih skupina troškova u prosječnim godišnjim nominalnim troškovima održavanja za sve građevine u istraživanju

Na slici 23 prikazani su kumulativni nominalni troškovi uporabe za razdoblje od 12 godina.

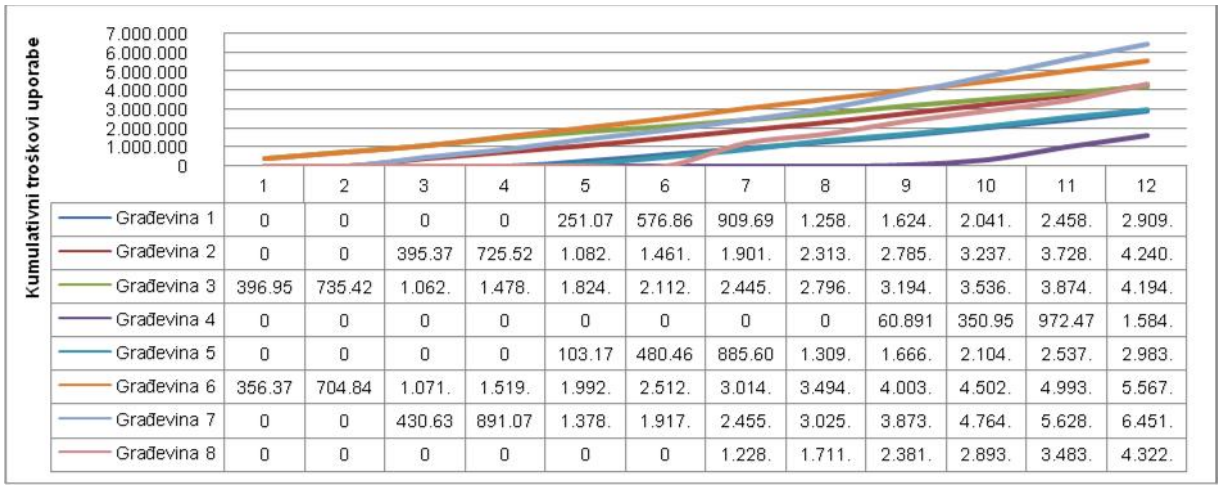

	1	2	3	4	5	6	7	8	9	10	11	12
Građevina 1	0	0	0	0	251.07	576.86	909.69	1.258.	1.624.	2.041.	2.458.	2.909.
Građevina 2	0	0	395.37	725.52	1.082.	1.461.	1.901.	2.313.	2.785.	3.237.	3.728.	4.240.
Građevina 3	396.95	735.42	1.062.	1.478.	1.824.	2.112.	2.445.	2.796.	3.194.	3.536.	3.874.	4.194.
Građevina 4	0	0	0	0	0	0	0	0	60.891	350.95	972.47	1.584.
Građevina 5	0	0	0	0	103.17	480.46	885.60	1.309.	1.666.	2.104.	2.537.	2.983.
Građevina 6	356.37	704.84	1.071.	1.519.	1.992.	2.512.	3.014.	3.494.	4.003.	4.502.	4.993.	5.567.
Građevina 7	0	0	430.63	891.07	1.378.	1.917.	2.455.	3.025.	3.873.	4.764.	5.628.	6.451.
Građevina 8	0	0	0	0	0	0	1.228.	1.711.	2.381.	2.893.	3.483.	4.322.

Slika 23 Grafički prikaz kumulativnih nominalnih troškova uporabe za razdoblje od 1997. do 2008. godine

Analogno prethodnom primjeru, isto je napravljeno i za troškove održavanja i uporabe što je prikazano na slici 24.

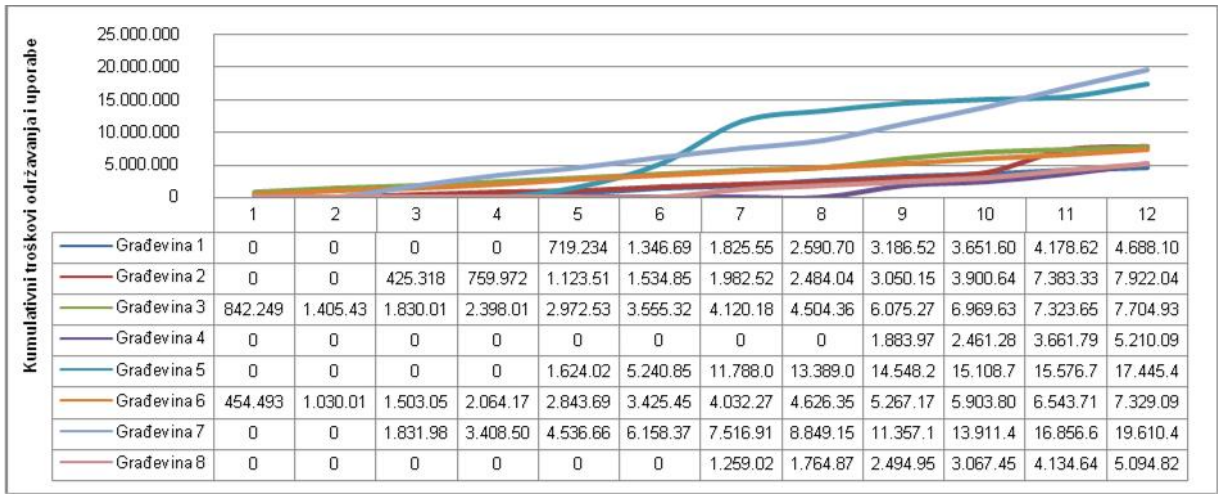

	1	2	3	4	5	6	7	8	9	10	11	12
Građevina 1	0	0	0	0	719.234	1.346.69	1.825.55	2.590.70	3.186.52	3.651.60	4.178.62	4.688.10
Građevina 2	0	0	425.318	759.972	1.123.51	1.534.85	1.982.52	2.484.04	3.050.15	3.900.64	7.383.33	7.922.04
Građevina 3	842.249	1.405.43	1.830.01	2.398.01	2.972.53	3.555.32	4.120.18	4.504.36	6.075.27	6.969.63	7.323.65	7.704.93
Građevina 4	0	0	0	0	0	0	0	0	1.883.97	2.461.28	3.661.79	5.210.09
Građevina 5	0	0	0	0	1.624.02	5.240.85	11.788.0	13.389.0	14.548.2	15.108.7	15.576.7	17.445.4
Građevina 6	454.493	1.030.01	1.503.05	2.064.17	2.843.69	3.425.45	4.032.27	4.626.35	5.267.17	5.903.80	6.543.71	7.329.09
Građevina 7	0	0	1.831.98	3.408.50	4.536.66	6.158.37	7.516.91	8.849.15	11.357.1	13.911.4	16.856.6	19.610.4
Građevina 8	0	0	0	0	0	0	1.259.02	1.764.87	2.494.95	3.067.45	4.134.64	5.094.82

Slika 24 Grafički prikaz kumulativnih nominalnih troškova održavanja i uporabe za razdoblje od 1997. do 2008. godine

U svrhu preliminarnog utvrđivanja veličine utjecaja pojedinih neovisnih varijabli na ovisne varijable, troškove održavanja i uporabe i troškove uporabe, nominalne vrijednosti troškova svih građevina podijeljene su s vrijednostima neovisnih varijabli za funkcionalne površine i broj korisnika.

Dobiveni rezultati su prikazani grafički na slikama 25 i 26 za troškove uporabe.

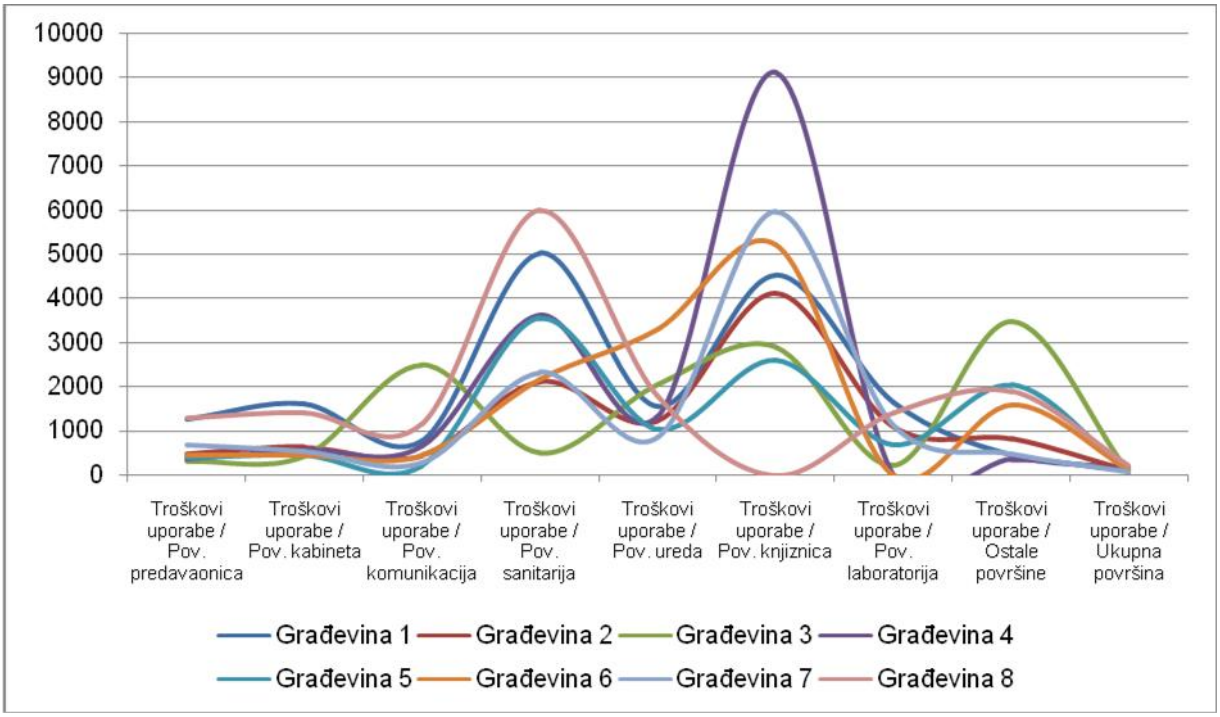

Slika 25 Grafički prikaz troškova uporabe podijeljenih s neovisnim varijablama funkcionalnih površina

Grafičkim prikazom omjera uporabnih troškova i različitih funkcionalnih površina uočava se postojanje određene povezanosti ovih varijabli kod svih građevina koje su sudjelovale u istraživanju, a samim time može se očekivati kako će neke od ovih površina biti varijable konačnog modela procjene troškova uporabe građevina. Isti postupak učinjen je i za prosječni broj djelatnika i studenata, rezultati su prikazani na slici 26. Vidljivo je kako su troškovi uporabe osjetljiviji na broj djelatnika zbog većeg rasipanja omjera troškova uporabe i broja djelatnika.

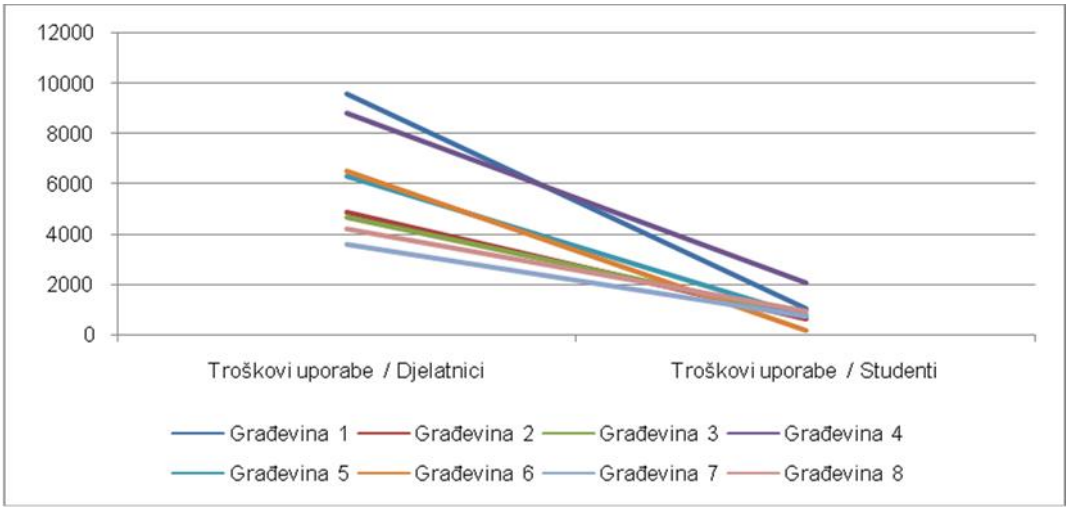

Slika 26 Grafički prikaz troškova uporabe podijeljenih s neovisnim varijablama prosječnog broja djelatnika i studenata

Analogno prethodnom, učinjeno je isto i za troškove održavanja i uporabe, a rezultati su prikazani na slikama 27 i 28.

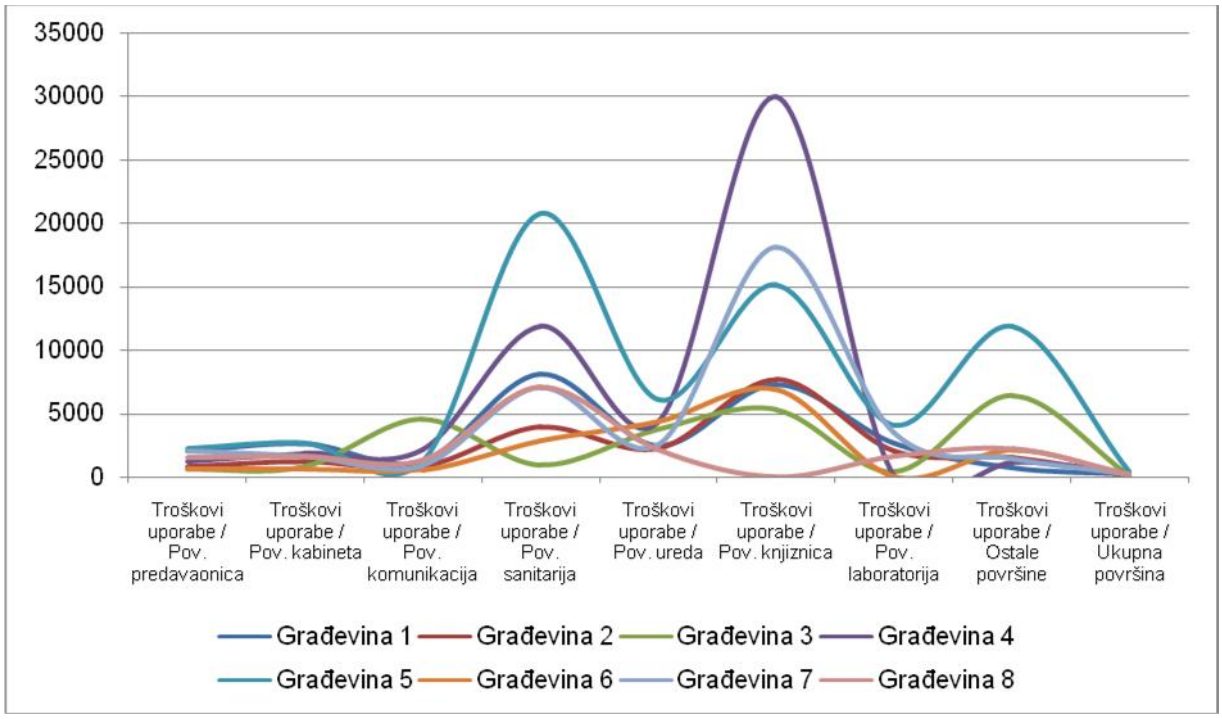

Slika 27 Grafički prikaz troškova održavanja i uporabe podijeljenih s neovisnim varijablama funkcionalnih površina

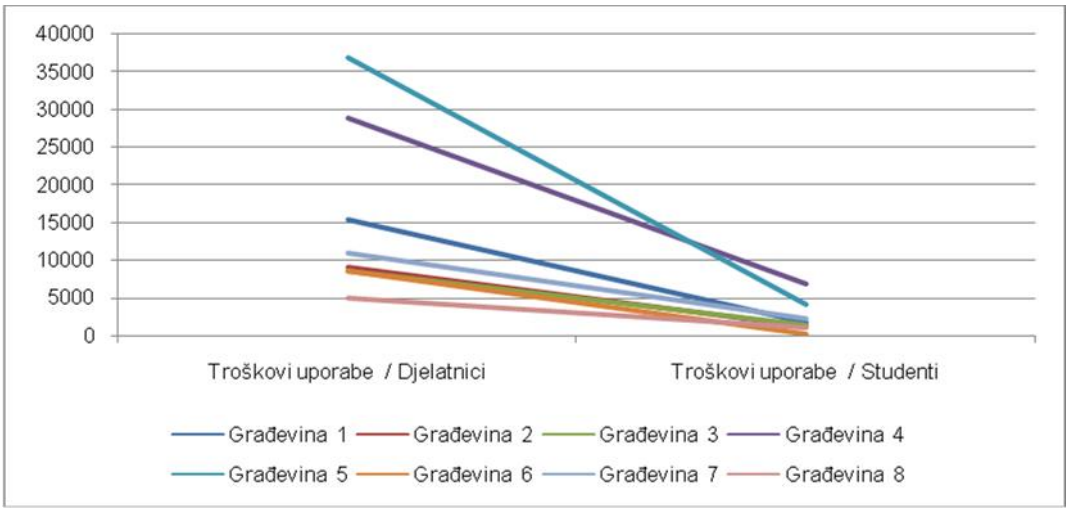

Slika 28 Grafički prikaz troškova održavanja i uporabe podijeljenih s neovisnim varijablama prosječnog broja djelatnika i studenata

Zaključci na osnovi prethodne dvije slike jednaki su onima kod troškova uporabe, s tim da je ovdje uočljivo još veće rasipanje rezultata, odnosno veća je standardna devijacija omjera troškova i navedenih neovisnih varijabli. Ovo govori kako će i dobiveni model vrlo vjerojatno imati veća odstupanja procijenjenih vrijednosti troškova od stvarnih.

3.3.2 Odabir statističke metode i varijabli modela

U statističkim analizama se često u danom skupu mogu promatrati dva ili više obilježja. Postavlja se pitanje međusobne povezanosti tih obilježja, a ako postoji takva povezanost, nastoji se naći matematička formulacija kojom se ta povezanost izražava [93]. Zadaća regresijske analize je pronalaženje analitičko-matematičkog oblika veze između jedne ovisne i jedne ili više neovisnih varijabli [94-95].

Nekoliko je razloga za uporabu regresijskih metoda, a to su:

- deskriptivnost, regresijske metode prikazuju odnos između ishoda i ulaznih podataka
- usklađivanje, koje je moguće za nezavisne varijable i/ili vanjske varijable u korelaciji (pozitivnoj ili negativnoj) s neovisnim i ovisnim varijablama
- analiza neovisnih varijabli, na način da se utvrde rizične varijable s obzirom na ishod
- ponekad prikupljanje vrijednosti ovisnih varijabli može biti izuzetno skupo ili nemoguće ako se radi o vrijednostima koje će se javiti u budućnosti
- predviđanje (predikcija), koja omogućuje kvantifikaciju novih slučajeva [96-97].

Postoje brojni problemi u kojima su dvije ili više varijabli međusobno povezane, a predmet istraživanja i modeliranja je utvrđivanje veze među njima. Problem je općenito postavljen s jednom ovisnom varijablom *y* ili odgovorom koji ovisi o *k* neovisnih varijabli ili prediktora, kao na primjer $x_1, x_2, \ldots, x_k$. Veza između navedenih varijabli opisana je matematičkim modelom koji se naziva regresija. Regresijski modeli koriste se za analizu podataka neplaniranih pokusa proizašlih iz opažanja i nekontroliranih pojava ili povijesnih zapisa [98-99].

Svaki model ima slučajnu varijablu ε koja upućuje da veze između pojava u praksi nisu funkcionalne već statističke ili stohastičke [94]. Općenito, zavisna varijabla *y* može se izraziti preko *k* prediktornih varijabli pa model tada glasi [98-100]:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \ldots + \beta_k x_k + \varepsilon \tag{29}$$

Navedeni izraz predstavlja višestruki linearni regresijski model s *k* prediktornih varijabli. Parametri βj, $j=0,1,\ldots,k$ nazivaju se regresijski koeficijenti. Postupak proračuna parametara regresijske analize naziva se često i podešavanje modela (*model fitting*), a metoda najmanjih kvadrata najčešće se koristi s tom svrhom [98].

Metode viševarijabilne regresijske analize koriste se, kada govorimo o troškovima životnog ciklusa, za izradu modela procjene uporabnih troškova, troškova održavanja i utvrđivanja veze između prediktornih varijabli i troškova [101].

Pri predviđanju varijable *y* potrebno je voditi računa o tome da vrijednosti varijable *x* koje se koriste za predviđanje nisu izvan granica varijabli *x* koje su se koristile za utvrđivanje regresijskih koeficijenata, u protivnom je moguće dobiti potpuno netočne rezultate [102].

Analizom korelacije mjeri se jakost veza između varijabli i izražava se koeficijentom korelacije. Pojava korelacije između dvije ili više varijabli je fenomen koji se u statistici naziva kolinearnost i govori koliko su dvije varijable povezane, odnosno s kolikom je vjerojatnošću moguće predvidjeti vrijednost neke varijable ako znamo vrijednost druge varijable koja je s njom u korelaciji [103-104]. Kolinearnost je problem u mnogim regresijskim analizama. Jednostavna kolinearnost se pojavljuje kada su dvije varijable u visokoj korelaciji (obično iznad 0.90). Multikolinearnost se odnosi na međusobnu povezanost više varijabli. U literaturi prevladava termin kolinearnost, ali neki autori upotrebljavaju termin "*blizu kolinearnosti*" da naglase kako korelacija nije potpuna. Neki autori razlikuju termin *multikolinearnost* koji upotrebljavaju kada se radi o više nezavisnih varijabli [105-106].

Ako je broj neovisnih varijabli mali i nisu značajno kolinearne, tada je regresijska metoda najprimjerenija za uporabu, međutim ako i jedan od ova dva uvjeta nije ispunjen, primjena metode nije preporučljiva [107]. U tablici 7 prikazani su koeficijenti korelacije (r, R, ili Pearsonov koeficijent korelacije) za uzorak. Iz tablice 7 vidljivo je kako postoji kolinearnost između pojedinih neovisnih varijabli što govori kako nije preporučljivo modeliranje klasičnom regresijskom metodom, odnosno nije niti moguće!

Tablica 7 Koeficijenti korelacije neovisnih i ovisnih varijabli

	Starost gradjevine	Brog godine uporabe	Ref. period	Etaze	Pov. predavaonica	Pov. kabineta	Pov. komunikacija	Pov. sanitarija	Pov. ureda	Pov. knjiznica	Pov. laboratorija	Ostale povrsine	Ukupna povrsina	Djelatnici	Studenti	Smjene	Troskovi per. pregleda	Troskove zamjene mat.	Troskovi periodicni popravaka	Troskovi reaktivnog odrzavanja	Troskovi uporabe	Ukupni troskovi odrzavanja
Starost gradjevine	1,00	-0,03	0,28	-0,64	0,38	0,47	0,59	-0,02	0,51	0,43	-0,15	0,39	0,67	0,22	0,04	0,47	-0,05	-0,09	0,21	0,82	0,03	0,33
Broj godine uporabe	-0,03	1,00	0,84	0,28	0,34	0,47	-0,09	0,53	-0,41	0,26	0,19	-0,46	0,06	-0,01	0,82	0,18	0,74	-0,38	-0,42	-0,05	-0,05	-0,45
Ref. period	0,28	0,84	1,00	0,22	0,31	0,48	0,12	0,65	-0,15	0,63	0,44	-0,39	0,34	0,05	0,55	0,39	0,52	-0,12	-0,24	0,16	-0,16	-0,25
Etaze	-0,64	0,28	0,22	1,00	-0,53	-0,32	-0,46	0,36	-0,16	-0,30	0,43	-0,18	-0,32	0,24	0,07	-0,44	0,41	-0,02	-0,56	-0,38	0,27	-0,53
Pov. predavaonica	0,38	0,34	0,31	-0,53	1,00	0,79	0,25	0,51	0,02	0,44	0,27	-0,11	0,61	-0,02	0,13	0,43	-0,19	0,10	0,37	0,12	-0,20	0,34
Pov. kabineta	0,47	0,47	0,48	-0,32	0,79	1,00	0,64	0,38	0,40	0,43	0,14	0,10	0,82	0,39	0,44	0,31	0,21	0,06	0,41	0,15	0,22	0,47
Pov. komunikacija	0,59	-0,09	0,12	-0,46	0,25	0,64	1,00	-0,26	0,76	0,42	-0,21	0,36	0,75	0,46	0,19	0,21	0,01	0,22	0,71	0,22	0,35	0,82
Pov. sanitarija	-0,02	0,53	0,65	0,36	0,51	0,38	-0,26	1,00	-0,15	0,38	0,86	-0,32	0,36	0,08	-0,02	0,21	0,02	0,15	-0,21	-0,03	-0,18	-0,23
Pov. ureda	0,51	-0,41	-0,15	-0,16	0,02	0,40	0,76	-0,15	1,00	0,02	0,00	0,64	0,74	0,77	-0,21	-0,13	-0,15	0,22	0,47	0,37	0,65	0,68
Pov. knjiznica	0,43	0,26	0,63	-0,30	0,44	0,43	0,42	0,38	0,02	1,00	0,37	-0,22	0,52	-0,28	0,02	0,76	-0,14	0,49	0,46	0,01	-0,55	0,37
Pov. laboratorija	-0,15	0,19	0,44	0,43	0,27	0,14	-0,21	0,86	0,00	0,37	1,00	-0,42	0,31	0,19	-0,34	-0,03	-0,29	0,29	-0,03	-0,09	-0,09	-0,03
Ostale povrsine	0,39	-0,46	-0,39	-0,18	-0,11	0,10	0,36	-0,32	0,64	-0,22	-0,42	1,00	0,35	0,26	-0,23	0,19	0,00	0,30	0,20	0,21	0,28	0,32
Ukupna povrsina	0,67	0,06	0,34	-0,32	0,61	0,82	0,75	0,36	0,74	0,52	0,31	0,35	1,00	0,52	-0,02	0,33	-0,12	0,32	0,54	0,34	0,25	0,66
Djelatnici	0,22	-0,01	0,05	0,24	-0,02	0,39	0,46	0,08	0,77	-0,28	0,19	0,26	0,52	1,00	0,10	-0,57	0,17	-0,25	0,02	0,38	0,93	0,26
Studenti	0,04	0,82	0,55	0,07	0,13	0,44	0,19	-0,02	-0,21	0,02	-0,34	-0,23	-0,02	0,10	1,00	0,03	0,88	-0,54	-0,28	0,01	0,21	-0,27
Smjene	0,47	0,18	0,39	-0,44	0,43	0,31	0,21	0,21	-0,13	0,76	-0,03	0,19	0,33	-0,57	0,03	1,00	-0,03	0,50	0,29	0,00	-0,73	0,17
Troskovi per. pregleda	-0,05	0,74	0,52	0,41	-0,19	0,21	0,01	0,02	-0,15	-0,14	-0,29	0,00	-0,12	0,17	0,88	-0,03	1,00	-0,47	-0,53	-0,01	0,28	-0,49
Troskove zamjene mat.	-0,09	-0,38	-0,12	-0,02	0,10	0,06	0,22	0,15	0,22	0,49	0,29	0,30	0,32	-0,25	-0,54	0,50	-0,47	1,00	0,65	-0,52	-0,40	0,55
Troskovi periodicni popravaka	0,21	-0,42	-0,24	-0,56	0,37	0,41	0,71	-0,21	0,47	0,46	-0,03	0,20	0,54	0,02	-0,28	0,29	-0,53	0,65	1,00	-0,24	-0,07	0,96
Troskovi reaktivnog odrzavanja	0,82	-0,05	0,16	-0,38	0,12	0,15	0,22	-0,03	0,37	0,01	-0,09	0,21	0,34	0,38	0,01	0,00	-0,01	-0,52	-0,24	1,00	0,26	-0,06
Troskovi uporabe	0,03	-0,05	-0,16	0,27	-0,20	0,22	0,35	-0,18	0,65	-0,55	-0,09	0,28	0,25	0,93	0,21	-0,73	0,28	-0,40	-0,07	0,26	1,00	0,15
Ukupni troskovi odrzavanja	0,33	-0,45	-0,25	-0,53	0,34	0,47	0,82	-0,23	0,68	0,37	-0,03	0,32	0,66	0,26	-0,27	0,17	-0,49	0,55	0,96	-0,06	0,15	1,00

Grafički prikaz korelacije neovisnih i ovisnih varijabli nalazi se u prilogu 3.

Povezanost obilježja *X* i *Y* zovemo statističkom povezanošću. Izučavanjem statističke povezanosti bavi se teorija korelacije i regresije [93]. Pod pojmom korelacija podrazumijeva se međuzavisnost ili povezanost slučajnih varijabli. Po smjeru korelacija može biti:

- pozitivna, rast jedne varijable prati rast druge promatrane varijable
- negativna, rast jedne varijable prati pad druge varijable i obrnuto [94].

Problem koji se javlja u regresijskoj analizi prikupljenih podataka iz kontinuiranih procesa (procesi koji se odvijaju prije, ali i nakon prikupljanja podataka), a ne podatcima dobivenim eksperimentom, je pojava korelacije neovisnih varijabli. Ta pojava onemogućuje utvrđivanje utjecaja i značaja neovisnih varijabli na ovisnu varijablu [108]. Kada postoji kolinearnost, rezultati regresijske analize mogu biti nepouzdani, a ta pojava ima jako veliki utjecaj na

standardnu pogrešku regresijskih koeficijenata. Procjena regresijskog koeficijenta postaje nestabilna. Posljedice kolinearnosti:

- neprecizne procjene regresijskih koeficijenata
- male promjene u visini korelacije mogu rezultirati velikim razlikama u regresijskim koeficijentima
- dodavanje ili izbacivanje varijabli može rezultirati velikim razlikama u regresijskim koeficijentima
- povećanje standardne pogreške koeficijenata koja smanjuje njihovu značajnost [105, 109]
- u najgorem slučaju regresijski koeficijenti dodijeljeni kolinearnim varijablama bit će veliki s naznakom nasumičnosti
- neovisne varijable s poznatim, jakim utjecajem na ovisnu varijablu neće biti statistički značajne [109].

Predlaže se nekoliko mjera kojima je moguće utvrditi postojanje *multikolinearnosti* varijabli:

1. provjera predznaka regresijskih koeficijenata ovisno o prethodnim spoznajama slične problematike
2. provjera važnosti pojedinih neovisnih varijabli koja se također temelji na prethodnim spoznajama
3. provjera utjecaja brisanja pojedinih redova ili stupaca neovisne varijable (ako dođe do velikih promjena modela, moguće je postojanje kolinearnosti)
4. provjera korelacije između svih parova neovisnih varijabli preko matrice korelacije
5. utvrđivanje vrijednosti VIF-a (*Variance inflaction factor*) [108].

Prve tri mjere ne moraju nužno značiti postojanje multikolinearnosti te stoga nisu pouzdane, četvrta mjera ne bi trebala nužno biti i odlučujuća, ali daje naznake ponašanja varijabli. Peta mjera može poslužiti za utvrđivanje problema, međutim postavlja se problem vrijednosti same veličine, odnosno koliko velika vrijednost VIF definira kolinearnost [108].

Kao mjera kolinearnosti najčešće se koristi tolerancija (*tolerance*) koja se ponekad izražava preko njezine inverzne vrijednosti koja se naziva VIF-a, odnosno faktora inflacije tolerancije [109-110]. Tolerancija manja od 0.1 upućuje na ozbiljan problem, ispod 0.2 na mogući problem, tolerancija blizu nule pokazuje visoku kolinearnost. VIF (*Variance inflaction factor*) veći od 10 [110] (neki statističari uzimaju stroži kriterij – veći od 4) ukazuju na visoku razinu kolinearnosti [105]. Smatra se da kolinearnost neovisnih varijabli između -0.70 i 0.70 ne stvara probleme pri provedbi regresijske analize [99].

Problem kolinearnosti neovisnih varijabli koji se naziva i multikolinearnost moguće je riješiti nekom od sljedećih metoda - regresija glavnih komponenti (*principal component regression, PCR*), *ridge* regresije i metode najmanjih parcijalnih kvadrata. Od navedenih, metoda najmanjih parcijalnih kvadrata zahtijeva najmanje proračuna, odnosno najjednostavnija je [111]. Rezultati testa kolinearnosti su dani u prilogu 4. Neovisne varijable kolinearne su i nije moguća primjena klasičnih regresijskih metoda.

Izbor varijabli modela ovisi o ciljevima analize, pri čemu utvrđivanje važnosti varijabli i uzročno posljedičnih veza ovisi o izvoru podataka i prirodi tih podataka. Ako je cilj istraživanja izrada realističnog modela koji će objasniti neku pojavu, važno je utvrditi koje varijable značajno utječu na ovisnu varijablu te njihovu kauzalnost. U ovom slučaju korelacijska struktura varijabli postaje relativno nevažna pri izboru varijabli, u najboljem slučaju može poslužiti kao sredstvo utvrđivanja skupina varijabli kao jamstvo utvrđivanja uzročno posljedičnih veza u budućim istraživanjima [110].

Pri primjeni regresijskih modela javljaju se obično dva problema pri izboru varijabli:

1. izbor samo relevantnih varijabli među velikim brojem neovisnih varijabli
2. takav izbor varijabli često uzrokuje pojavu korelacije među varijablama, ali može dovesti do toga da je veći broj odabranih varijabli od broja uzoraka.

Stoga klasične regresijske metode [112] i po ovom kriteriju nisu prikladne za analizu neovisnih i ovisnih varijabli u ovom radu.

Deskriptivna analiza uzorka, odnosno neovisnih i ovisnih varijabli s najosnovnijim statističkim podatcima dana je u tablici 8. Detaljniji podatci nalaze se u prilogu 5. Tablica 8 prikazuje srednje, najveće i najmanje vrijednosti svih neovisnih i ovisnih varijabli, kao i standardnu devijaciju svake od njih.

Tablica 8 Deskriptivna statistika uzorka

Varijabla	Mean	Minimum	Maximum	Std.Dev.
Starost gradjevine	123	10,0	293	97,5
Broj godine uporabe	14	4,0	33	9,4
Referentno razdoblje	9	4,0	12	2,8
Etaze	4	3,0	5	0,9
Pov. predavaonica	847	284,4	1100	281,2
Pov. kabineta	735	223,2	1170	291,9
Pov. komunikacija	966	140,0	2193	681,5
Pov. sanitarija	222	72,3	680	197,3
Pov. ureda	337	139,8	755	192,0
Pov. knjiznica	86	0,0	144	45,5
Pov. laboratorija	472	0,0	1560	494,9
Ostale povrsine	585	100,0	1323	444,8
Ukupna povrsina	4315	2375,0	7345	1481,5
Djelatnici	90	38,0	178	54,0
Studenti	788	189,0	2540	740,2
Smjene	2	1,0	2	0,4
Troskovi per. pregleda	15202	4217,1	32574	8699,5
Troskove zamjene mat.	95981	1916,7	172619	76574,0
Troskovi periodicni popravaka	437733	7397,2	1617220	603133,3
Troskovi reaktivnog odrzavanja	99656	13732,4	344833	110682,1
Troskovi uporabe	466984	349526,8	720453	139485,0
Ukupni troskovi odrzavanja	1115555	586013,4	2180683	634626,4

Iz znanstvene hipoteze izvodi se statistička hipoteza koja se iskazuje na način da može biti vrjednovana statističko-analitičkim postupcima i predstavlja matematički izraz na kojem se

temelji kalkulacija statističkog testa. Testiranje hipoteze je statistički postupak kojim se određuje jesu li i koliko pouzdani raspoloživi podatci te podupiru li navedenu pretpostavku ovisno o razini odabrane statističke značajnosti [95, 113]. Nul-hipoteza, H_0, je pretpostavka o izostanku efekta i uglavnom se postavlja sa svrhom odbacivanja [106, 113-114]. U ovome radu je nul-hipoteza kako se navedenim prediktornim varijablama ne mogu procijeniti troškovi održavanja i uporabe.

U slučaju malog uzorka (manje od deset uzoraka) i kada nema podataka o distribuciji uzoraka ili se čak zna da ne slijede normalnu razdiobu, preporučuje se primjena neparametrijskih testova (testovi neovisni o distribuciji podataka) kao što su D'Agostino-Pearsonov test, Kolmogorov-Smirnovljev test, Anderson-Darlingov test, Cramér-von-Misesov test, Shapiro-Wilkinsonov test, i Shapiro–Francia test normalnosti. Cilj statističke analize je utvrditi povezanost između jedne ili više neovisnih varijabli i jedne i više ovisnih varijabli [113, 115-116].

Izbor neovisnih varijabli osnovni je problem pri svakoj regresijskoj analizi, pri čemu se nastoji zadovoljiti da neovisne varijable opisuju ovisnu što je bolje moguće i da je model jednostavan, odnosno da ne sadrži neovisne varijable koje nisu potrebne za opisivanje određene pojave [98, 117]. S obzirom na navedene dosadašnje spoznaje i na činjenicu kako je uzorak mali, a broj neovisnih varijabli duplo veći od uzorka, prije odabira regresijskog modela potrebno je odabrati neovisne varijable kojima će se opisati ovisna varijabla.

Pri odabiru varijabli potrebno je voditi računa o tome da u model budu uključene samo važne varijable koje istodobno daju i najmanju pogrešku modela [98, 117] i najveću vrijednost koeficijenta determinacije [118].

Neke od metoda odabira varijabli u modelu višestruke regresije su sljedeće:

- *Forward* metoda, na početku nema ni jedne varijable u modelu, a prva varijabla koja ulazi u model je ona s najvećim koeficijentom korelacije s ovisnom varijablom [118-120]
- *Backward* metoda, na početku se u model uključuju sve varijable, a izlazak počinje od onih varijabli koje imaju najmanji koeficijent parcijalne korelacije s ovisnom varijablom i od njih se testiraju kriteriji za izlazak iz modela [118-120]
- *Stepwise* metoda, predstavlja kombinaciju *Forward* i *Backward* metode i u praksi se najčešće koristi [96, 108]; prva varijabla se bira kao kod *Forward* metode, a kao druga se bira ona s najvećim koeficijentom parcijalne korelacije s ovisnom varijablom; *Stepwise* metoda se nastavlja kao kod *Backward* metode ispitujući udovoljava li uključena varijabla kriterijima za izlazak [96-97, 119], a na kraju se utvrđuje razina slučajne pogreške odabranog modela [119]; ova metoda smatra se najboljom za izbor varijabli [108]
- Enter metoda, sve varijable ulaze odjednom u model (forsirani ulaz) [119]
- Test metoda, kod koje je zadan podskup regresijskih varijabli, a testira se niz mogućnosti pomoću kriterija koeficijenta determinacije (r^2) [119].

Kako je nepoznato koje su varijable nepotrebne, izbor varijabli modela mora se zasnivati na samim podatcima, te je potrebno izvesti izbor ovisno o statističkim podatcima, na primjer p-vrijednostima [118]. U ovome radu koristila se procedura postupne eliminacije varijabli (*stepwise metoda*) te su viševarijabilnom (multiplom) regresijskom analizom određene varijable koje značajno utječu na troškove uporabe i troškove održavanja i uporabe građevina, pri čemu se koristio program pod nazivom SAS8.1.

Forward i *Backward* metoda ne uzimaju u obzir, za razliku od *Stepwise* metode, utjecaj dodavanja ili izbacivanja pojedinih varijabli na ostale neovisne varijable [110, 120-121]. Ova metoda posebno je korisna kada je broj mogućih neovisnih varijabli modela velik, pri čemu se kao kriterij ulaza i izlaza varijabli iz modela može uzeti određena razina statističke značajnosti, p-vrijednost (npr. 0,05) [98] ili se ulaz i izlaz varijabli iz modela zasniva na vrijednostima F-testa [108]. Prva varijabla koja ulazi u model je ona koja je u najvećoj korelaciji s ovisnom varijablom, a to je ujedno i ona s najvećom vrijednosti F-testa, pri čemu je potrebno napomenuti kako neki programi umjesto F-testa koriste t-test [108].

Statistička značajnost definirana je na razini manjoj od 5% i predstavlja vjerojatnost da će se drugim mjerenjima dobiti razlika između novih mjerenja i uzorka koja je neznatna, manja od 5% [100, 116]. Statistička značajnost rezultata je vjerojatnost da je zapažena veza između varijabli ili razlika između srednjih vrijednosti uzorka samo puka slučajnost i kako u stvarnosti ne postoji takva veza i predstavlja indeks pouzdanosti rezultata [122]. Slučajnim uzorkovanjem iz identične populacije ustanovila bi se razlika koja bi bila ista ili manja u 95% slučajeva, dok bi veća razlika od opažene bila utvrđena samo u 5% slučajeva.

Rezultati statističke analize (p-vrijednosti, neparametrijski testovi, S*tepwise* analiza) dani su u prilogu 6.

Kriterij statističke značajnosti je $p<0,05$ i smatra se graničnom prihvatljivom vrijednošću [114, 122]. U nastavku su prikazani kriteriji statističke značajnosti za obje skupine troškova koje su bile predmet istraživanja, a kako statistička značajnost ne mora nužno značiti i praktičnost i primjenjivost [113-114], u obzir su uzete i varijable gdje je statistička značajnost bila manja od 0,08 kako bi se utvrdio njihov utjecaj na ovisnu varijablu. Neki od autora preporučuju čak i usvajanje statističke značajnosti od 0,25, jer smatraju kako statistička značajnost od 0,05 ne mora nužno značiti da će varijable biti primjenjive i za predviđanje budućih vrijednosti nekog događaja na testnom uzorku [121].

„p“-vrijednosti manje od 0,01 uobičajeno se smatraju statistički značajnim, dok se vrijednosti manje od 0,005 i 0,001 nazivaju „visoko“ značajnim, pri čemu treba imati na umu kako se radi o dogovorenim vrijednostima, odnosno konvencijama [122].

Vrijednosti u tablicama 9 i 10 su p-vrijednosti i govore o statističkom značaju utjecaja neovisnih varijabli na ovisnu varijablu [123]. Kako su navedene p vrijednosti u tablicama 9 i 10 statistički značajne, možemo odbaciti nul hipotezu kako se navedenim prediktornim varijablama ne mogu procijeniti troškovi održavanja i uporabe. Pritom treba istaknuti kako se varijabla 14, prosječni broj djelatnika u referentnom razdoblju, može smatrati „visoko“ značajnom s obzirom na „p“-vrijednost koja je manja od 0,001.

Tablica 9 Statistički značajne neovisne varijable za model troškova uporabe

VARIJABLA	OPIS	p
var14	**DJELATNICI**	**0,0006**
var16	**SMJENE**	**0,0381**

Tablica 10 Statistički značajne neovisne varijable za model troškova održavanja i uporabe

VARIJABLA	OPIS	p
var7	**POV. KOMUNIKACIJA**	**0,0130**
var9	POV. UREDA	0,0627
var13	UKUPNA POVRŠINA	0,0725

U tablicama 9 i 10 prikazane su statistički značajne varijable za izradu modela procjene troškova uporabe i modela procjene troškova uporabe i održavanja. U tablici 9 vidi se kako je statistički najznačajnija varijabla 14 (prosječni broj djelatnika) gdje p iznosi 0,06% za izradu modela procjene troškova uporabe. U tablici 10 od tri prikazane varijable statistički najznačajnija je varijabla 7 (površina komunikacija), gdje „p“ iznosi 1,30% .

Pri izboru između više modela s različitim varijablama potrebno je za svaki od njih provesti validaciju na testnom uzorku, grafički prikazati ovisnost broja varijabli modela i statističkih pokazatelja [118], što je prikazano u narednim poglavljima. Nakon provedene *Stepwise* analize (Prilog 6) na daljnje razmatranje uzeti su modeli prikazani u tablicama 11 i 12. Ovi modeli odabrani su na osnovi vrijednosti koeficijenta korelacije (R) i koeficijenta determinacije (R^2) (*R-Square Selection Method*). S obzirom na mali uzorak, na razmatranje su uzeti samo modeli s najviše 3 varijable.

Kao kriterij izbora modela moguće je koristiti nekoliko veličina, a neke od njih su koeficijent determinacija (R^2), korijen srednje vrijednosti kvadratne pogreške predviđanja i „podešeni“ koeficijent korelacije (R^2_{adj}), pri čemu je podešeni koeficijent korelacije ekvivalent korijenu srednje vrijednosti kvadratne pogreške predviđanja (*Root Mean Squared Error of Prediction)* [97, 108]. Kada regresijska analiza ima mnogo prediktora, moguće je da R^2 postane umjetno visok, jer slučajna variranja u nekim prediktorima "objašnjavaju" male dijelove varijance prediktora. U ekstremnoj situaciji u kojoj bi broj prediktora bio jednak broju ispitanika, R^2 bi uvijek bio 1. Ovo u praksi znači da se povećanjem broja prediktora, varijabli, povećava i koeficijent determinacije (R^2) što nije realno. Za tu svrhu preporučuje se uporaba „podešenog“ koeficijenta korelacije (R^2_{adj}) s kojim se procjenjuje pogreška predviđanja na novom setu podataka [105, 110, 121, 124].

Kao kriterij izbora modela može se koristiti više kriterija na način da se popišu modeli koji udovoljavaju pojedinim kriterijima, a potom se vrši analiza odabranih modela [97]. Niti jedan od modela neće imati vrijednost koeficijenta determinacije kao model koji uključuje sve neovisne varijable, a to je vrijednost jednaka jedan, ali se traže modeli koji sadržavaju određeni manji broj neovisnih varijabli, a za koje su vrijednosti koeficijenta determinacije dovoljno blizu vrijednosti koeficijenta determinacije modela koji sadrži sve neovisne varijable [97].

U tablicama 11 i 12 prikazani su rezultati regresijske analize za svaki od navedenih modela procjene troškova, a prikazane su i pripadajuće vrijednosti koeficijenata determinacija (R^2) i „prilagođenih“ koeficijenata korelacije (R^2_{adj}). Na osnovi prikazanih rezultata u tablicama izvršit će se konačni izbor modela procjene troškova.

Detaljan prikaz dobivenih rezultata dan je u prilogu 6. Izabrani su modeli procjene troškova uporabe prikazani u tablici 11 i modeli procjene troškova održavanja i uporabe prikazani u tablici 12.

Tablica 11 Prijedlog modela troškova uporabe za daljnju razradu

R-Square	Adjusted R-Square	Variables in Model	Opis varijable
0,8766	0,8560	var14	DJELATNICI
0,5391	0,4623	var16	SMJENE

R-Square	Adjusted R-Square	Variables in Model	Opis varijabli	
0,9566	0,9393	var10 var14	POV. KNJIŽNICA	DJELATNICI
0,9533	0,9346	var14 var11	DJELATNICI	POV. LABORATORIJA
0,9449	0,9229	var8 var14	POV. SANITARIJA	DJELATNICI
0,9373	0,9122	var14 var13	DJELATNICI	UKUPNA POVRŠINA
0,9249	0,8949	var16 var14	SMJENE	DJELATNICI
0,9182	0,8855	var3 var14	REF. RAZDOBLJE	DJELATNICI
0,9035	0,8649	var5 var14	POV. PREDAVAONICA	DJELATNICI
0,8997	0,8596	var1 var14	STAROST GRAĐEVINE	DJELATNICI
0,8936	0,8510	var6 var14	POV. KABINETA	DJELATNICI
0,8878	0,8429	var15 var14	STUDENTI	DJELATNICI

R-Square	Adjusted R-Square	Variables in Model	Opis varijabli		
0,9967	0,9942	var1 var11 var14	STAROST GRAĐEVINE	POV. LABORATORIJA	DJELATNICI
0,9897	0,9820	var11 var14 var16	POV. LABORATORIJA	DJELATNICI	SMJENE
0,9867	0,9768	var11 var13 var14	POV. LABORATORIJA	UKUPNA POVRŠINA	DJELATNICI
0,9852	0,9741	var3 var14 var15	REF. RAZDOBLJE	DJELATNICI	STUDENTI
0,9843	0,9725	var10 var11 var14	POV. KNJIŽNICA	POV. LABORATORIJA	DJELATNICI
0,9825	0,9695	var7 var10 var14	POV. KOMUNIKACIJA	POV. KNJIŽNICA	DJELATNICI
0,9806	0,9661	var8 var10 var14	POV. SANITARIJA	POV. KNJIŽNICA	DJELATNICI
0,9767	0,9593	var8 var9 var14	POV. SANITARIJA	POV. UREDA	DJELATNICI
0,9765	0,9588	var7 var11 var14	POV. KOMUNIKACIJA	POV. LABORATORIJA	DJELATNICI
0,9754	0,9570	var9 var11 var14	POV. UREDA	POV. LABORATORIJA	DJELATNICI
0,9736	0,9538	var4 var11 var14	BROJ ETAŽA	POV. LABORATORIJA	DJELATNICI
0,9733	0,9533	var9 var15 var16	POV. UREDA	STUDENTI	SMJENE
0,9729	0,9525	var10 var14 var15	POV. KNJIŽNICA	DJELATNICI	STUDENTI

Tablica 12 Prijedlog modela troškova održavanja i uporabe za daljnju razradu

R-Square	Adjusted R-Square	Variables in Model	Opis varijable
0,6697	0,6147	var7	POV. KOMUNIKACIJA
0,4648	0,3756	var9	POV. UREDA
0,4410	0,3478	var13	UKUPNA POVRŠINA

R-Square	Adjusted R-Square	Variables in Model	Opis varijabli	
0,8444	0,7821	var7 var15	POV. KOMUNIKACIJA	STUDENTI
0,8119	0,7366	var2 var7	BR.GOD.UPORABE	POV. KOMUNIKACIJA
0,8088	0,7323	var2 var6	BR.GOD.UPORABE	POV. KABINETA
0,7885	0,7038	var3 var7	REF. RAZDOBLJE	POV. KOMUNIKACIJA
0,7046	0,5865	var1 var7	STAROST GRAĐEVINE	POV. KOMUNIKACIJA
0,7006	0,5808	var4 var7	BROJ ETAŽA	POV. KOMUNIKACIJA

R-Square	Adjusted R-Square	Variables in Model	Opis varijabli		
0,9088	0,8405	var3 var7 var11	REF. RAZDOBLJE	POV. KOMUNIKACIJA	POV. LABORATORIJA
0,9028	0,8299	var3 var7 var10	REF. RAZDOBLJE	POV. KOMUNIKACIJA	POV. KNJIŽNICA
0,9027	0,8297	var2 var5 var7	BR.GOD.UPORABE	POV. PREDAVAONICA	POV. KOMUNIKACIJA
0,8968	0,8194	var3 var7 var8	REF. RAZDOBLJE	POV. KOMUNIKACIJA	POV. SANITARIJA
0,8951	0,8164	var1 var7 var15	STAROST GRAĐEVINE	POV. KOMUNIKACIJA	STUDENTI

3.3.3 Metode validacije modela

Validacija modela radi se zbog dva osnovna razloga - poslovnog, sa svrhom utvrđivanja najboljeg modela i statističkog, sa svrhom utvrđivanja razine pogreške [124]. Svrha validacije modela je sljedeća:

- osigurati uporabivost modela za nove setove sličnih podataka [125-126]
- izbjegavanje pojave *over-fitting* (pojava kada je model reprezentativan za skup podataka od kojih je načinjen, a ne za cijeli raspon podataka [107]) i pojave *under-fitting* (pojava kada je model jednostavan, ali pogreška pri testiranju na novim setovima podataka je prevelika) [125].

Postoje najmanje četiri tipa uzorkovanja (*resampling*):

1. Direktna metoda slučajnog odabira (*Randomization exact test*) poznata i pod nazivom metoda permutacija (*permutation test*), koristi se za utvrđivanje statističkog značaja (*statistical significance*)
2. Kros validacija (*cross validation*), koristi se kao metoda za vrjednovanje pogreške predviđanja
3. *Jackknife* metoda, koristi se za vrjednovanje vrijednosti varijance nepoznatih parametara statističkog modela (*estimator*) i za redukciju pogreške (*bias*) istog
4. *Bootstrap* metoda, koristi se za vrjednovanje vrijednosti varijance nepoznatih parametara statističkog modela (*estimator*) [127-128].

Osnovni nedostatak svih metoda je to da se njihovi rezultati temelje na istim onim podatcima od kojih je načinjen uzorak koji se analizira. Stoga neki autori predlažu uporabu

„vanjskih“ uzoraka kako bi se načinila prava validacija dobivenih rezultata, što većina autora uspješno izbjegava koristeći navedene, interne, metode validacije [125, 129].

Odabir metode validacije ovisi o tipu podataka, najčešće se preporuča primjena kros validacija izostavljanjem uzoraka jedan po jedan, ako varijable nisu u korelaciji. U tom slučaju preporuča se primjena kros validacija sukcesivnim grupiranjem uzoraka ili kros validacija grupiranjem uzoraka. Bez obzira na izbor metode kros validacije, osnovno pravilo pri validaciji je odabir onog modela s najmanjom vrijednosti sume kvadrata pogreške predviđanja modela (PRESS) [130].

U metodi kros validacije (*cross validation*) jedan po jedan, set podataka isključuje se iz modela i radi se kalibracija (prilagođavanje) modela. Isključeni setovi podataka koriste se za validaciju modela. Postupak se ponavlja dok se svi setovi ne isključe po jednom, a nakon toga radi se model i kalibracija sa svim setovima podataka [124-125, 131-133]. Svi *podmodeli* sudjeluju u izradi statističkih podataka, odnosno izračunu ukupne kvadratne pogreške [132]. Ovaj način validacije najviše se koristi kad je malen broj setova podataka, za veće setove podataka ova metoda nije realistična. Nedostatak metode je što ne daje nikakve informacije o mogućnostima modela za predviđanje rezultata za neki novi set podataka [125]. Uporabom kros validacije izbjegava se mogućnost pojave *overfitting-a* [131], pojave koja se događa kada kvaliteta predviđanja opada s porastom broja neovisnih varijabli [133].

Postoji nekoliko tipova kros validacije:

- kros validacija izostavljanjem uzoraka jedan po jedan (*one at a time; full cross validation*), ova vrsta kros validacije u literaturi se često naziva i *Jackknife* metoda [117, 133-134]
- kros validacija sukcesivnim grupiranjem uzoraka (*blocked cross validation*), uzorci se grupiraju u blokove, npr. uzorci od 1 do 8 tvore prvi blok, uzorci od 9 do 18 drugi blok i tako dalje
- kros validacija grupiranjem uzoraka (*split sample cross validation*), uzorci blokova ne stoje u nizu, npr. prvi blok tvore uzorci broj 1,5 i 8, drugi blok uzorci 9,13 i 18 i tako dalje
- kros validacija nasumičnim odabirom (*random sample cross validation*), gdje su uzorci za kros validaciju nasumično odabrani [130].

Vrijednost sume kvadrata pogreške predviđanja modela (PRESS) može poslužiti i za određivanje potrebnog broja neovisnih varijabli na način da se varijable prestanu dodavati u trenutku kada vrijednost sume kvadrata pogreške predviđanja modela krene rasti [133].

Neke od statističkih metoda za vrjednovanje (kvantifikacija kvalitete) različitih modela dobivenih kalibracijom (prilagođavanjem) su sljedeći [83, 111, 125, 135]:

- korijen srednje vrijednosti kvadratne pogreške predviđanja (*Root Mean Squared Error of Prediction, RMSEP*), kao razlika sume kvadrata razlike između predviđenih i stvarnih vrijednosti varijable *y*:

$$\mathrm{RMSEP} = \sqrt{\frac{\sum_{i=1}^{n}(\hat{y}_i - \tilde{y}_i)^2}{n}} \tag{30}$$

- analogno prethodnom, može se izraziti i postotak pogreške predviđanja kao:

$$\%RMSEP = \frac{RMSEP \cdot 100\%}{\frac{\bar{y}_{\max} - \bar{y}_{\min}}{2}} \tag{31}$$

- pogreška je prosječna vrijednost razlike predviđene i stvarne vrijednosti varijable *y* svih setova za validaciju:

$$\mathrm{Bias} = \frac{\sum_{i=1}^{n}(\hat{y}_i - \tilde{y}_i)}{n} \tag{32}$$

Korijen srednje vrijednosti kvadratne pogreške predviđanja (*Root Mean Squared Error of Prediction, RMSEP*) je mjera koja pokazuje koliko dobro model opisuje podatke, dok je korijen srednje vrijednosti kvadratne pogreške kros validacije (*root mean square error of cross validation, RMESCV*) mjera koja pokazuje sposobnost predviđanja modela na novim setovima podataka [111]. Korijen srednje vrijednosti kvadratne pogreške kros validacije računa se kao:

$$\mathrm{RMSECV} = \sqrt{\frac{\mathrm{PRESS}}{n}} \tag{33}$$

gdje je PRESS suma kvadrata pogreške predviđanja modela dobivenih kros validacijom [103, 111]. Stoga, ako je cilj modela predviđanje rezultata, tada je model s najmanjom vrijednosti korijena srednje vrijednosti kvadratne pogreške kros validacije (*RMESCV*) mjerodavan [103, 111, 133, 136-137]. Vrijednost PRESS računa se kao [108, 110, 133, 136, 138]:

$$\mathrm{PRESS} = \sum_{i=1}^{n}\frac{(\hat{y}_i - \tilde{y}_i)^2}{n} \tag{34}$$

Točnost modela (*Model Accuracy, A_C*)može se računati kao postotak razlike troškova predviđenih modelom i stvarnih troškova kao [41]:

$$A_C = \left[\frac{PC - AC}{AC}\right] \cdot 100\% \tag{35}$$

gdje su:

- A_c točnost izračunatih troškova
- *PC* troškovi predviđeni modelom
- *AC* stvarni troškovi.

Što je ova vrijednost bliža nuli, model točnije opisuje neko svojstvo, u ovom slučaju troškove.

Srednja vrijednost točnosti modela (*Mean Model Accuracy,* $\overline{A_C}$) za seriju ispitivanja računa se kao aritmetička sredina točnosti prema izrazu [41]:

$$\overline{A_C} = \frac{\sum_{i=1}^{n} A_C}{n} \tag{36}$$

gdje su:

- A_c točnost izračunatih troškova na danom setu podataka i
- *n* broj setova podataka.

Ako je srednja vrijednost točnosti modela blizu nule ili jednaka nuli, to govori da model, u prosjeku, ne preuveličava, ali i ne umanjuje stvarnu vrijednost troškova!

Ukupna točnost modela definirana je disperzijom pojedinačnih točnosti serija građevina neke kategorije. Ova disperzija predstavlja se standardnom devijacijom. Ukupna točnost modela (*Total Model Accuracy*, A_m) tada se definira kao [41]:

$$A_m = \overline{A_C} - \text{std of } A_C \tag{37}$$

Za sve građevine i svaki od predloženih modela izračunate su srednje vrijednosti točnosti ($\overline{A_C}$) i ukupna točnost (A_m) svakog od modela za dani set građevina. Za troškove uporabe rezultati su prikazani na slici 29, a za troškove održavanja i uporabe na slici 30.

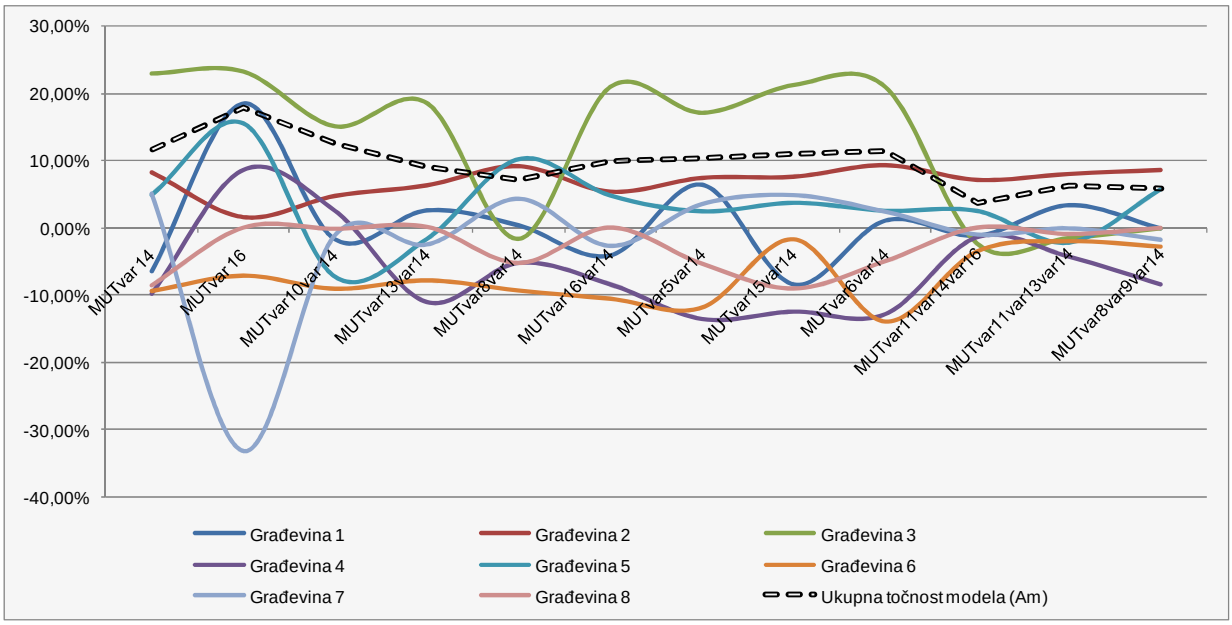

MUT predstavlja kraticu za model uporabnih troškova

Slika 29 Srednje vrijednosti točnosti ($\overline{A_C}$) i ukupna točnost (A_m) svakog od modela procjene troškova uporabe za dani set građevina

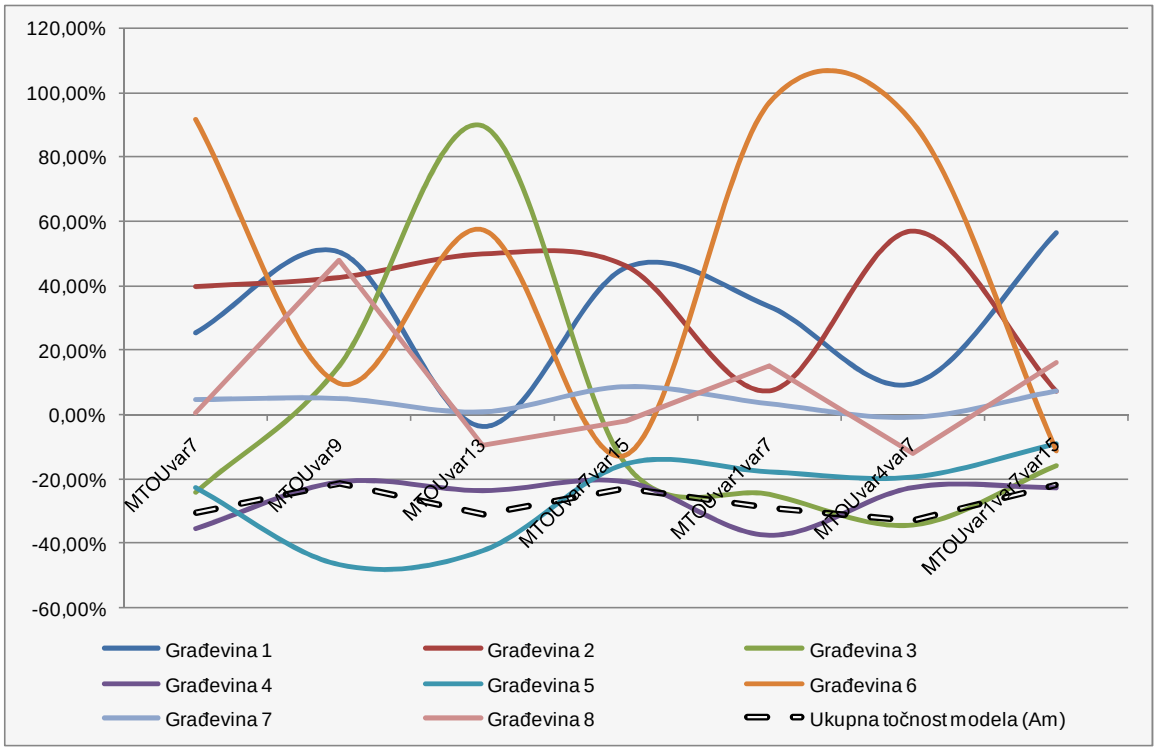

MTOU predstavlja kraticu za model troškova održavanja i uporabe

Slika 30 Srednje vrijednosti točnosti ($\overline{A_C}$) i ukupna točnost (A_m) svakog od modela procjene troškova održavanja i uporabe za dani set građevina

Pri vrjednovanju navedenih modela, u nastavku se koriste vrijednosti koeficijenata determinacija (R^2), korijena srednje vrijednosti kvadratne pogreške kros validacije (*root mean square error of cross validation, RMESCV*) i vrijednosti sume kvadrata pogreške predviđanja modela dobivenih kros validacijom (PRESS). Ove vrijednosti bit će mjerodavne za odabir modela, dok će vrijednosti preciznosti svakog od modela biti uzete u obzir kako bi se utvrdila povezanost s mjerodavnim vrijednostima odabira.

4 RAZVOJ MODELA PROCJENE TROŠKOVA UPORABE GRAĐEVINA

Za predložene modele troškova uporabe i na osnovi rezultata regresijske analize izvršena je analiza vrijednosti koeficijenata determinacija (R^2), korijena srednje vrijednosti kvadratne pogreške kros validacije (*root mean square error of cross validation, RMESCV*) i vrijednosti sume kvadrata pogreške predviđanja modela dobivenih kros validacijom (PRESS).

U tablici 13 prikazani su odabrani modeli troškova uporabe s pripadajućim vrijednostima koeficijenata determinacija, vrijednostima korijena srednje vrijednosti kvadratne pogreške i vrijednostima sume kvadrata pogreške predviđanja modela.

Tablica 13 Vrijednosti sume kvadrata pogreške predviđanja modela, korijena srednje vrijednosti kvadratne pogreške i koeficijenata determinacije

MODELI UPORABNIH TROŠKOVA*	PRESS	RMSECV	R^2
MUTvar 14	33.042.797.067,00	64268	0,8766
MUTvar16	85.433.736.141,00	103340	0,5391
MUTvar10var14	10.004.121.243,00	35363	0,9566
MUTvar13var14	17.974.711.793,00	47401	0,9373
MUTvar8var14	22.399.437.549,00	52914	0,9449
MUTvar16var14	35.881.910.195,00	66972	0,9249
MUTvar5var14	53.688.920.977,00	81921	0,9035
MUTvar15var14	336.973.600.000,00	205236	0,8878
MUTvar6var14	40.262.003.456,00	70942	0,8936
MUTvar11var14var16	10.724.255.970,00	36613	0,9897
MUTvar11var13var14	10.147.237.430,00	35615	0,9867
MUTvar8var9var14	11.676.661.640,00	38204	0,9767

** MUT predstavlja kraticu za model uporabnih troškova*

Vrijednosti prikazane u tablici 13 poredane su prema veličini vrijednosti koeficijenta determinacije i vrijednostima sume kvadrata pogreške predviđanja modela od najmanje prema najvećoj i prikazane u tablici 14.

Tablica 14 Vrijednosti koeficijenata determinacije poredane od najmanjih prema najvećim vrijednostima

MODELI UPORABNIH TROŠKOVA	PRESS	RMSECV	R^2
MUTvar16	85433736141	103340	0,5391
MUTvar 14	33042797067	64268	0,8766
MUTvar15var14	336973600000	205236	0,8878
MUTvar6var14	40262003456	70942	0,8936
MUTvar5var14	53688920977	81921	0,9035
MUTvar16var14	35881910195	66972	0,9249
MUTvar13var14	17974711793	47401	0,9373
MUTvar8var14	22399437549	52914	0,9449
MUTvar10var14	10004121243	35363	0,9566
MUTvar8var9var14	11676661640	38204	0,9767
MUTvar11var13var14	10147237430	35615	0,9867
MUTvar11var14var16	10724255970	36613	0,9897

Vrijednosti prikazane u tablici 14 mogu se prikazati grafički kako bi se utvrdila vrijednost najmanje vrijednosti sume kvadrata pogreške predviđanja modela i odgovarajućih koeficijenata determinacije, što pomaže pri odabiru područja optimalnih vrijednosti sume kvadrata pogreške predviđanja za definiranje modela [130]. Usporedba tih vrijednosti prikazana je na slici 31.

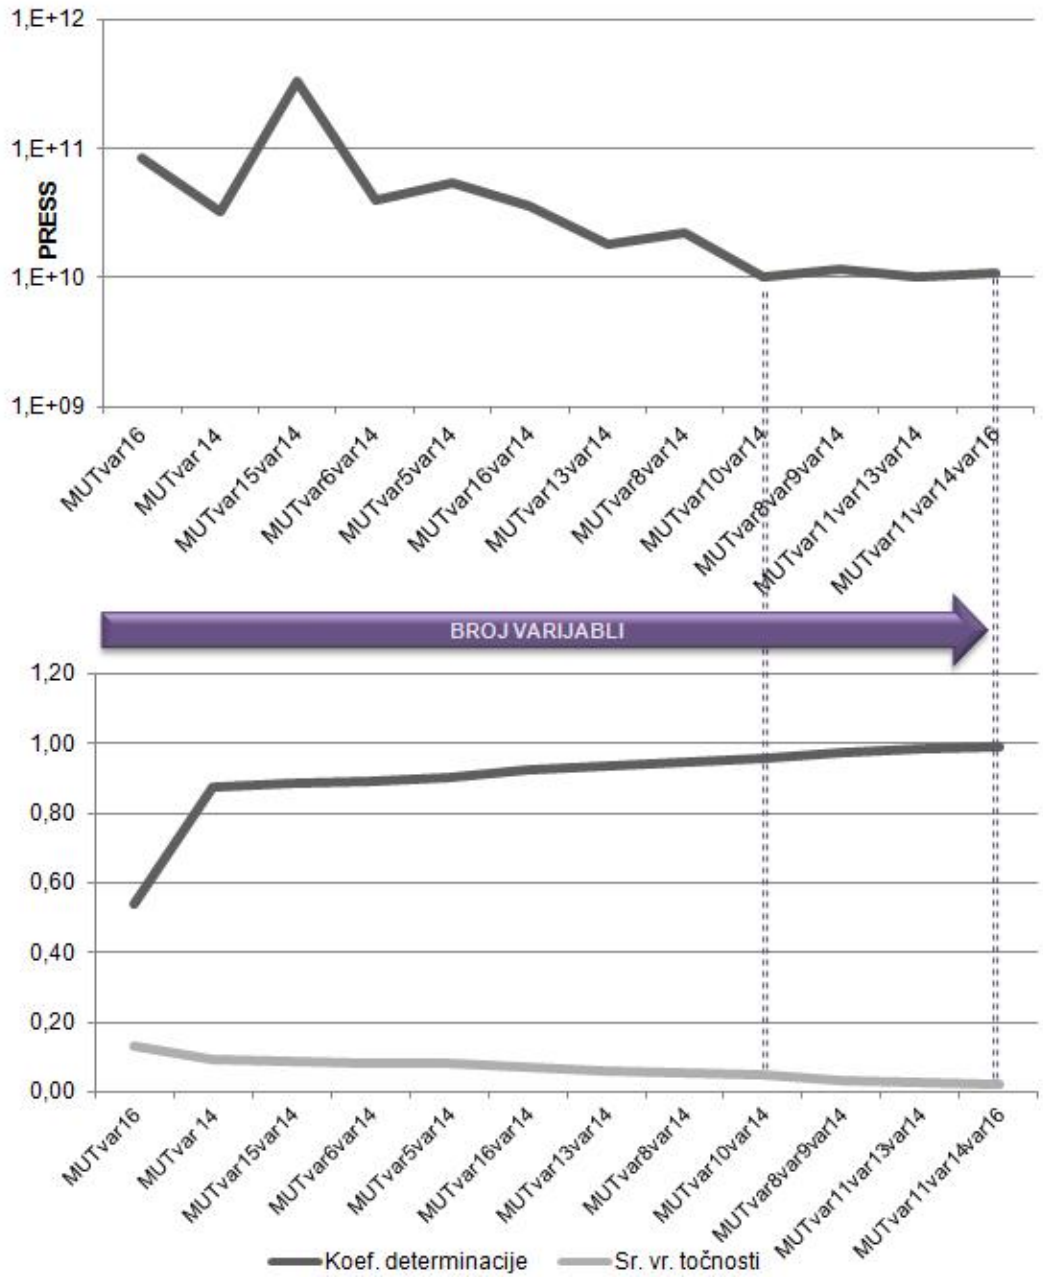

Slika 31 Vrijednosti koeficijenta determinacije i pripadajuće vrijednosti sume kvadrata pogreške predviđanja modela procjene troškova uporabe

Budući da je cilj modela predviđanje rezultata, troškova, tada su modeli s najmanjim vrijednostima korijena srednje vrijednosti kvadratne pogreške kros validacije (PRESS) najprikladniji! U ovom slučaju to su sljedeći modeli troškova uporabe:

- MUTvar10var14
- MUTvar8var9var14
- MUT var11var13var14
- MUT var11var14var16.

U nastavku su prikazani odabrani modeli procjene troškova uporabe građevina. Odabrani modeli procjene troškova uporabe za daljnju razradu, s obzirom na najmanje srednje

vrijednosti kvadratne pogreške kros validacije (PRESS) i pripadajuće varijable, prikazani su u tablici 15.

Tablica 15 Modeli procjene troškova uporabe s pripadajućim varijablama

R^2	R^2_{ADJ}	Varijeble modela	Opis varijabli			PRESS	RMSECV
0,9566	0,9393	var10 var14	POV. KNJIŽNICA	DJELATNICI		10004121243	35363
0,9767	0,9593	var8 var9 var14	POV. SANITARIJA	POV. UREDA	DJELATNICI	11676661640	38204
0,9867	0,9768	var11 var13 var14	POV. LABORATORIJA	UKUPNA POVRŠINA	DJELATNICI	10147237430	35615
0,9897	0,9820	var11 var14 var16	POV. LABORATORIJA	DJELATNICI	SMJENE	10724255970	36613

4.1 MODELI PROCJENE TROŠKOVA UPORABE GRAĐEVINA

U nastavku su prikazani modeli procjene troškova uporabe građevina dobiveni na osnovi analize u poglavljima 3.4.2 i 3.4.3 te rezultata *stepwise* regresijske analize koji su dani u prilogu 6. Predloženim modelima moguće je procijeniti prosječne godišnje nominalne troškove uporabe građevina.

4.1.1 Model I procjene troškova uporabe građevina

Prvi model procjene troškova uporabe je model s dvije varijable, površinom knjižnice i prosječnim brojem djelatnika tijekom razdoblja za koje se procjenjuju troškovi. Regresijskom analizom za navedene varijable dobiveni su regresijski koeficijenti i konstanta prikazani u tablici 16.

Tablica 16 Konstanta i regresijski koeficijenti modela procjene troškova uporabe – model 1

Intercept	**KONSTANTA**	346725,00
var 10	**POV. KNJIŽNICA**	-905,29
var 14	**BROJ DJELATNIKA**	2190,88

Prema navedenim podatcima iz tablice 16 moguće je raspisati prvi model:

$$PGNTU = 346725{,}00 - 905{,}29 \cdot P_{KN} + 2190{,}88 \cdot D_{PR} \tag{38}$$

gdje su:

- *PGNTU,* prosječni godišnji nominalni troškovi uporabe
- P_{KN}, površina knjižnice
- D_{PR}, prosječni broj djelatnika tijekom promatranog vremenskog razdoblja.

4.1.2 Model II procjene troškova uporabe građevina

Drugi model procjene troškova uporabe je model s tri varijable, površinom sanitarnih prostora, površinom ureda i prosječnim brojem djelatnika tijekom razdoblja za koje se procjenjuju troškovi. Regresijskom analizom za navedene varijable dobiveni su regresijski koeficijenti i konstanta prikazani u tablici 17.

Tablica 17 Konstanta i regresijski koeficijenti modela procjene troškova uporabe – model 2

Intercept	**KONSTANTA**	313041,00
var 8	**POV. SANITARIJA**	-230,48
var 9	**POV. UREDA**	-208,51
var 14	**BROJ DJELATNIKA**	3047,94

Prema navedenim podatcima iz tablice 17 moguće je raspisati drugi model:

$$PGNTU = 313041{,}00 - 230{,}48 \cdot P_S - 208{,}51 \cdot P_U + 3047{,}94 \cdot D_{PR} \quad (39)$$

gdje su:

- *PGNTU,* prosječni godišnji nominalni troškovi uporabe
- P_S, površina sanitarnih prostora
- P_U, površina uredskih prostorija
- D_{PR}, prosječni broj djelatnika tijekom promatranog vremenskog razdoblja.

4.1.3 Model III procjene troškova uporabe građevina

Treći model procjene troškova uporabe je model s tri varijable, površinom laboratorijskih prostora, ukupnom površinom građevine i prosječnim brojem djelatnika tijekom razdoblja za koje se procjenjuju troškovi. Regresijskom analizom za navedene varijable dobiveni su regresijski koeficijenti i konstanta prikazani u tablici 18.

Tablica 18 Konstanta i regresijski koeficijenti modela procjene troškova uporabe – model 3

Intercept	**KONSTANTA**	332103,00
var 11	**POV. LABORATORIJA**	-66,01
var 13	**UKUPNA POVRŠINA**	-20,48
var 14	**BROJ DJELATNIKA**	2815,06

Prema navedenim podatcima iz tablice 18 moguće je raspisati treći model:

$$PGNTU = 332103{,}00 - 66{,}01 \cdot P_L - 20{,}48 \cdot P_{UKP} + 2815{,}06 \cdot D_{PR} \quad (40)$$

gdje su:

- *PGNTU,* prosječni godišnji nominalni troškovi uporabe
- P_L, površina laboratorijskih prostora
- P_{UKP}, ukupna površina građevine
- D_{PR}, prosječni broj djelatnika tijekom promatranog vremenskog razdoblja.

4.1.4 Model IV procjene troškova uporabe građevina

Četvrti model procjene troškova uporabe je model s tri varijable, površinom laboratorijskih prostora, prosječnim brojem djelatnika i brojem smjena u kojima se obavlja djelatnost građevine tijekom promatranog vremenskog razdoblja za koje se procjenjuju

troškovi. Regresijskom analizom za navedene varijable dobiveni su regresijski koeficijenti i konstanta prikazani u tablici 19.

Tablica 19 Konstanta i regresijski koeficijenti modela procjene troškova uporabe – model 4

Intercept	**KONSTANTA**	481206,00
var 11	**POV. LABORATORIJA**	-73,60
var 14	**BROJ DJELATNIKA**	2182,63
var 16	**SMJENE**	-94266,00

Prema navedenim podatcima iz tablice 19 moguće je raspisati četvrti model:

$$PGNTU = 481206{,}00 - 73{,}60 \cdot P_L + 2182{,}63 \cdot D_{PR} - 94266{,}00 \cdot S \qquad (41)$$

gdje su:

- *PGNTU,* prosječni godišnji nominalni troškovi uporabe
- P_L, površina laboratorijskih prostora
- D_{PR}, prosječni broj djelatnika tijekom promatranog vremenskog razdoblja
- *S,* broj smjena u kojima se obavlja djelatnost građevine tijekom promatranog vremenskog razdoblja.

4.3 VALIDACIJA MODELA PROCJENE TROŠKOVA UPORABE GRAĐEVINA NA TESTNOM UZORKU

Radi utvrđivanja primjenjivosti modela za predviđanje troškova uporabe, dobiveni modeli primijenjeni su na građevine koje nisu sudjelovale u definiranju regresijskih koeficijenata, odnosno ostavljeni su za testiranje modela. Za validaciju modela procjene troškova uporabe postoje dva testna uzorka, prvi je za građevinu Sveučilišta u Rijeci (F20), a drugi je građevina Sveučilišta u Osijeku (F17) za koju su dostavljeni samo podatci o uporabnim troškovima.

Kako je već i navedeno pri predviđanju ovisne varijable, u ovom slučaju troškova uporabe potrebno je voditi računa o tome da vrijednosti neovisnih varijabli koje se koriste za predviđanje nisu izvan granica neovisnih varijabli koje su se koristile za utvrđivanje regresijskih koeficijenata, jer u suprotnom je moguće dobiti potpuno netočne rezultate [98, 102]. Prvi korak koji se provodi prije uporabe modela je provjera vrijednosti neovisnih varijabli testnog uzorka u odnosu na vrijednosti neovisnih varijabli koje su se koristile za utvrđivanje regresijskih koeficijenata.

Neovisne varijable koje su potrebne u predložena četiri modela su sljedeće varijable:

- površina sanitarnih prostora
- površina ureda
- površina knjižnica
- površina laboratorija

- ukupna površina
- prosječni broj djelatnika
- broj smjena.

Na slici 32 prikazane su maksimalne i minimalne vrijednosti navedenih varijabli, kao i vrijednosti varijabli građevina koje su poslužile kao testni uzorak, građevina označenih kao F17 i F20.

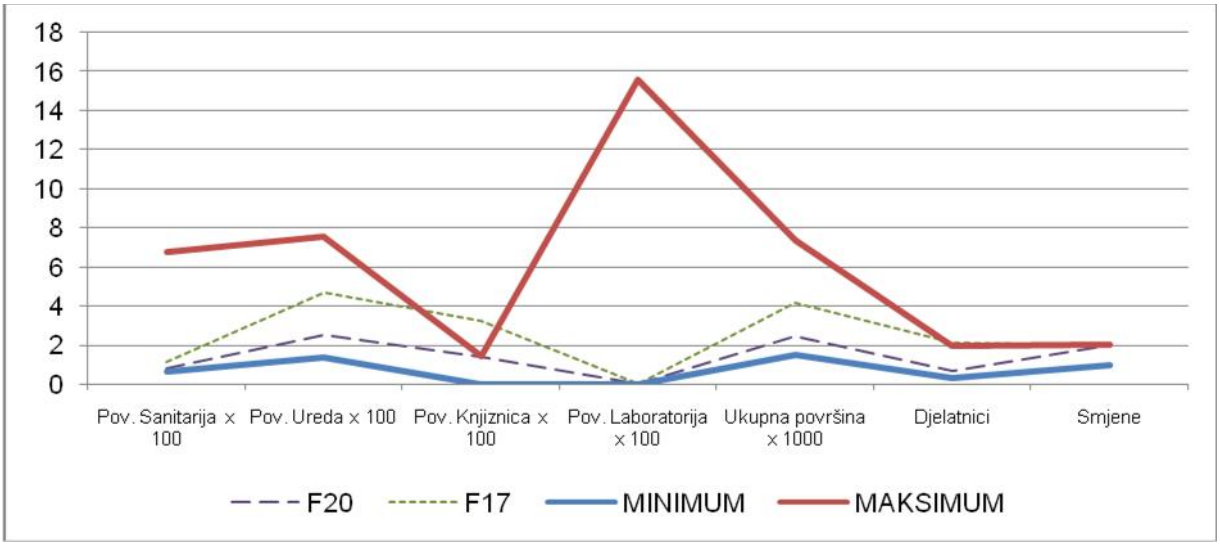

Slika 32. Maksimalne i minimalne vrijednosti neovisnih varijabli rabljenih za utvrđivanje vrijednosti regresijskih koeficijenata i vrijednosti istih varijabli testnog uzorka

Kako je vidljivo na slici 32, građevina F17 ima vrijednosti dvije varijable izvan dopuštenih granica, to su varijable površine knjižnice, gdje je površina testnog uzorka veća za 55,39% u odnosu na maksimalnu preporučenu vrijednost i varijabla prosječnog broja djelatnika koja je veća za 6,28% u odnosu na preporučenu maksimalnu vrijednost.

Vrijednosti neovisnih varijabli građevine F20 u granicama su preporučenih vrijednosti. Pri modeliranju usvojena je pretpostavka kako su površine funkcionalnih prostora svake od građevina konstantne, odnosno ne mijenjaju se tijekom vremena.

Svi usvojeni modeli procjene troškova uporabe kao jednu od neovisnih varijabli imaju prosječni broj djelatnika, koji kod građevine F17 odstupa od preporučenih vrijednosti za 6,28%. S obzirom na malo odstupanje navedene varijable, izvršit će se validacija svih modela na građevini F17 pri čemu se očekuje da model 1 neće biti primjenjiv jer obje neovisne varijable tog modela odstupaju od preporučenih vrijednosti.

4.3.1 Validacija modela I procjene troškova uporabe građevina

Kako je i navedeno, očekuje se da prvi model (1) s neovisnim varijablama površine knjižnica i prosječnog broja djelatnika nije primjenjiv na građevinu F17. Ako se primijeni, dobit će se rezultati prikazani u tablici 20. Razlika između stvarnih i predviđenih vrijednosti

troškova uporabe izračunata je prema izrazu za točnost modela (35) i predstavlja odstupanje procijenjenih od stvarnih vrijednosti troškova uporabe izraženih u postotcima.

Tablica 20 Rezultati validacije modela 1 uporabnih troškova na građevinama F17 i F20

Građevina	Stvarna vrijednost	Procijenjena vrijednost	Točnost modela (A_C)
F20	401.306,98 kn	357.104,42 kn	-11,01%
F17	749.301,82 kn	508.733,19 kn	-32,11%

Odstupanje procijenjenih troškova uporabe od stvarnih troškova uporabe građevine F20 iznosi -11,01%. Budući da se radi o građevini izvan Sveučilišta u Osijeku ovo odstupanje smatra se prihvatljivim, a model primjenjivim za procjenu troškova uporabe.

Očekivano odstupanje procijenjenih troškova uporabe od stvarnih troškova uporabe građevine F17 iznosi -32,11%. Dodatni razlozi odstupanja analizirat će se u poglavlju 5 gdje će biti napravljena analiza osjetljivosti radi utvrđivanja veličine utjecaja promjene pojedinih varijabli na procjenu troškova uporabe.

4.3.2 Validacija modela II procjene troškova uporabe građevina

Model 2 uporabnih troškova za procjenu uporabnih troškova koristi tri varijable, površinu sanitarnih prostora, površinu ureda i prosječni broj djelatnika. Rezultati validacije na građevinama F17 i F20 prikazani su u tablici 21. Odstupanje procijenjenih troškova uporabe od stvarnih vrijednosti troškova uporabe građevina iznosi oko 9%, odnosno model daje za oko 9% veće vrijednosti troškova uporabe od stvarnih vrijednosti.

Tablica 21 Rezultati validacije modela 2 uporabnih troškova na građevinama F17 i F20

Građevina	Stvarna vrijednost	Procijenjena vrijednost	Točnost modela (A_C)
F20	401.306,98 kn	434.287,02 kn	8,22%
F17	749.301,82 kn	820.985,48 kn	9,57%

4.3.3 Validacija modela III procjene troškova uporabe građevina

Model 3 uporabnih troškova za procjenu uporabnih troškova koristi tri varijable, površinu laboratorija, ukupnu površinu građevine i prosječni broj djelatnika. Rezultati validacije na građevinama F17 i F20 prikazani su u tablici 22. Odstupanja procijenjenih troškova uporabe od stvarnih vrijednosti troškova uporabe građevina iznose između 11% i 15%, odnosno model daje veće vrijednosti troškova uporabe od stvarnih vrijednosti u prosjeku za 13%.

Tablica 22 Rezultati validacije modela 3 uporabnih troškova na građevinama F17 i F20

Građevina	Stvarna vrijednost	Procijenjena vrijednost	Točnost modela (A_C)
F20	401.306,98 kn	459.477,12 kn	14,50%
F17	749.301,82 kn	829.555,81 kn	10,71%

4.3.4 Validacija modela IV procjene troškova uporabe građevina

Model 4 uporabnih troškova za procjenu uporabnih troškova koristi tri varijable, površinu laboratorija, prosječni broj djelatnika i broj smjena u kojima se odvija djelatnost ustanove. Rezultati validacije na građevinama F17 i F20 prikazani su u tablici 23. Odstupanja procijenjenih troškova uporabe od stvarnih vrijednosti troškova uporabe građevina iznose između 1% i 7%, odnosno model daje manju vrijednost troškova uporabe od stvarnih vrijednosti troškova za građevinu Sveučilišta u Osijeka u iznosu od oko 1%. Za građevinu izvan Sveučilišta u Osijeku model daje procijenjenu vrijednost troškova uporabe koja je veća za oko 7% u odnosu na stvarnu vrijednost.

Tablica 23 Rezultati validacije modela 4 uporabnih troškova na građevinama F17 i F20

Građevina	Stvarna vrijednost	Procijenjena vrijednost	Točnost modela (A_C)
F20	401.306,98 kn	430.179,94 kn	7,19%
F17	749.301,82 kn	744.479,23 kn	-0,64%

4.3.5 Izbor modela procjene troškova uporabe građevina

Prikazani rezultati odstupanja procijenjenih troškova uporabe od stvarnih vrijednosti troškova uporabe sva četiri modela troškova uporabe grafički su prikazani na slici 33. Na slici je vidljivo kako pri primjeni modela 2 procijenjeni troškovi uporabe približno jednako odstupaju od svojih stvarnih vrijednosti za obje građevine koje su se koristile kao testni uzorak. Model 1 daje razliku odstupanja između dvije građevine testnog uzorka u iznosu od 20%, što je već prethodno objašnjeno odstupanjem vrijednosti varijable građevine F17 (površina knjižnice).

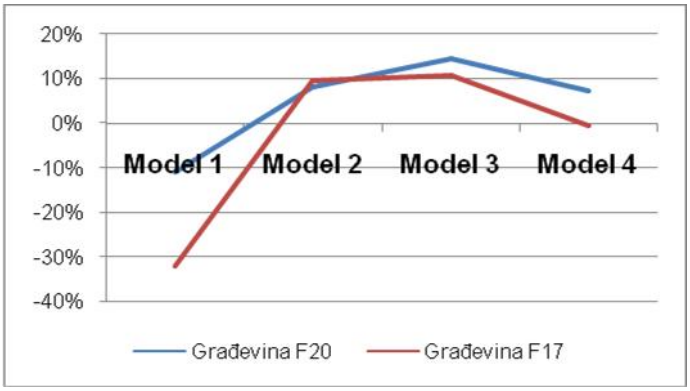

Slika 33 Odstupanja procijenjenih troškova uporabe od stvarnih vrijednosti troškova uporabe svih modela troškova uporabe

Model 1 iz navedenih je razloga neprimjenjiv za građevinu F17. Ostali modeli primjenjivi su na obje građevine, unatoč činjenici da varijabla prosječnog broja djelatnika građevine F17 neznatno odstupa od maksimalne preporučene vrijednosti, što dovodi do zaključka kako je model manje osjetljiv na promjene broja djelatnika nego na promjene površina.

Odstupanja procijenjenih troškova uporabe od stvarnih vrijednosti troškova uporabe sva četiri modela kreću se unutar područja od -11,01% do 14,50%. Rezultati ovih odstupanja odnose se samo na testni uzorak.

Na temelju provedenih analiza, kao mjerodavni model procjene troškova i uporabe usvaja se model broj 2. Nekoliko je razloga za ovu odluku:

- male vrijednosti standardne devijacije točnosti modela 2 i ukupne točnosti modela 2 što je prikazano na slici 34, gdje se vidi kako za modele 2, 3 i 4 ove vrijednosti poprimaju vrijednosti najbliže nuli, odnosno kreću se u intervalu od ±5,0%; kako je već navedeno, poželjno je da su ove vrijednosti što bliže nuli
- prihvatljive vrijednosti koeficijenta determinacije modela 2, slika 31
- mala vrijednost korijena srednje vrijednosti kvadratne pogreške kros validacije (PRESS) modela, slika 31
- varijable modela 2 značajne su sa stajališta struke (površine sanitarnih prostora, ureda i prosječni broj djelatnika) pri određivanju troškova uporabe
- varijable modela 2 veće su od nule za sve građevine koje su sudjelovale u istraživanju, odnosno sve građevine imaju ove funkcionalne površine.

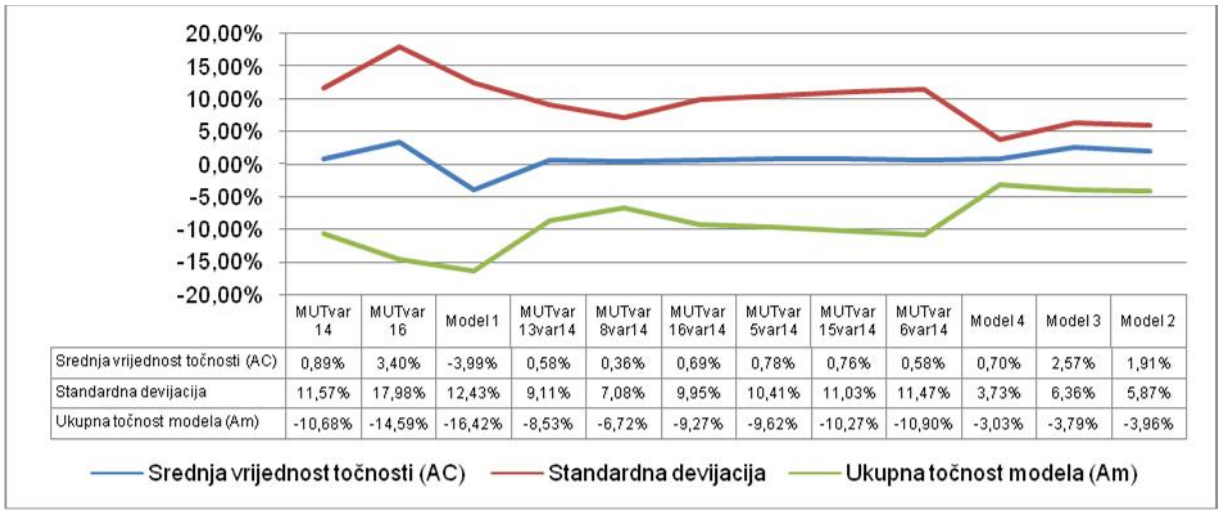

	MUTvar 14	MUTvar 16	Model 1	MUTvar 13var14	MUTvar 8var14	MUTvar 16var14	MUTvar 5var14	MUTvar 15var14	MUTvar 6var14	Model 4	Model 3	Model 2
Srednja vrijednost točnosti (AC)	0,89%	3,40%	-3,99%	0,58%	0,36%	0,69%	0,78%	0,76%	0,58%	0,70%	2,57%	1,91%
Standardna devijacija	11,57%	17,98%	12,43%	9,11%	7,08%	9,95%	10,41%	11,03%	11,47%	3,73%	6,36%	5,87%
Ukupna točnost modela (Am)	-10,68%	-14,59%	-16,42%	-8,53%	-6,72%	-9,27%	-9,62%	-10,27%	-10,90%	-3,03%	-3,79%	-3,96%

Slika 34 Srednje vrijednosti točnosti modela, ukupne točnosti modela i standardne devijacije modela procjene troškova uporabe za građevine koje su sudjelovale u istraživanju i građevina za validaciju

4.4 ANALIZA OSJETLJIVOSTI MODELA PROCJENE TROŠKOVA UPORABE GRAĐEVINA

U metodi troškova životnog ciklusa dva su osnovna pristupa problemu nesigurnosti, analiza osjetljivosti i probabilistička metoda, kao što je npr. *Monte Carlo* analiza. Osnovna razlika između ova dva pristupa je što analiza osjetljivosti ne zahtijeva podatke o distribuciji vjerojatnosti varijabli. Međutim, analiza osjetljivosti je poseban slučaj probabilističke metode u kojoj je jednaka vjerojatnost dodijeljena svakoj varijabli unutar raspona u kojemu se očekuje da će varirati [22, 31].

Analiza osjetljivosti je računski postupak koji se koristi za predviđanje utjecaja promjena ulaznih podataka na izlazne podatke modela [139-140]. Drugim riječima, to je postupak koji analizira kako promjene određenih ulaznih podataka (prihodi, troškovi, vrijednost investicija i sl.) koje proizlaze iz neprimjerenog predviđanja ili iz nekog drugog razloga, utječu na vrjednovanje investicijskih projekata. Primjenom ove metode moguće je pronaći maksimalne ili minimalne vrijednosti podataka unutar kojih je investicijski projekt i dalje ekonomski opravdan i prihvatljiv za izvedbu [141].

Analiza osjetljivosti je tehnika modeliranja koja se koristi kako bi se utvrdio utjecaj promjene vrijednosti jedne nezavisne varijable na ovisnu varijablu. Metoda se sastoji od tri osnovna koraka:

- dodjeljivanje nekoliko različitih razumnih vrijednosti ulaznoj varijabli
- izračun pripadajućih vrijednosti ovisne varijable
- analiza dobivenih vrijednosti [25, 37].

Kod analize osjetljivosti troškova životnog ciklusa najčešće se variraju one komponente za koje se smatra da imaju najveći utjecaj na pojavu nesigurnosti kod troškova životnog ciklusa, kao na primjer:

- diskontna stopa
- razdoblje analize
- nepouzdan životni vijek ili održavanje, ciklusi popravaka i zamjena [3].

Pri analizi osjetljivosti treba izabrati kritične varijable i parametre modela. Kritične varijable su one čije (pozitivne ili negativne) varijacije imaju najjači utjecaj na pokazatelje učinkovitosti promatranog projekta [142].

Analiza osjetljivosti pokazatelj je koliko su troškovi životnog ciklusa osjetljivi na promjene ključnih varijabli. Ako se pokaže da promjene varijable imaju veliki utjecaj na krajnji rezultat, tada je potrebna podrobnija analiza modela [3].

Glavna prednost analize osjetljivosti je brza provedba, rezultati se lako mogu predočiti tekstualno, tablično ili grafički. Glavni nedostatak ove metode je nedavanje podataka o vjerojatnosti drugačijih ishoda te zbog toga konačni izbor varijantnih rješenja i dalje ovisi o osobnoj procjeni [143]. Nadalje, nedostatci su neuzimanje u obzir korelacije između neovisnih varijabli te činjenica kako promjene neovisnih varijabli unutar nekog raspona ne moraju odgovarati promjenama koje su moguće u stvarnosti. Unatoč tomu, ova metoda pruža podatke bez uporabe dodatnih resursa.

Glavna dva nedostatka ove metode su:

1. jednodimenzionalnost, metodom je moguće varirati jednu po jednu varijablu
2. ne kvantificira rizike, već identificira varijable koje su osjetljive na rizike [25].

4.4.1 Analiza osjetljivosti odabranog modela procjene troškova uporabe građevina

Usvojeni model procjene troškova uporabe podvrgnut je analizi osjetljivosti, pri čemu su vrijednosti varijable prosječnog broja djelatnika varirane od -20% do 20% u koracima od 5%. Ovo olakšava i ubrzava proračun, ali potreban je određeni oprez kako varijable ne bi poprimile vrijednosti koje u stvarnosti ne mogu nikada poprimiti, kao npr. broj smjena veći od dvije ili manji od jedne. Ista stvar događa se kada su neovisne varijable međusobno povezane, odnosno u korelaciji pa promjena jedne utječe na promjenu druge, odnosno dolazi do redundancije i pogrešne interpretacije rezultata [142]. Primjer za to bio bi u ovome slučaju smanjenje broja smjena zbog smanjenja broja studenata, uz pretpostavku da se površine ne mijenjaju tijekom referentnog razdoblja za koji se radi procjena troškova uporabe građevine.

Varijabla se varira prema navedenim i opisanim koracima i prati se utjecaj varijacije na promjenu procjene troškova uporabe građevina.

Na slici 35 su prikazani rezultati analize osjetljivosti modela 2 procjene troškova uporabe građevina. Rezultati su prikazani za sve građevine, odnosno za građevine koje su se koristile u regresijskoj analizi i za građevine koje su se koristile za validaciju modela procjene troškova uporabe. Utjecaj promjene varijable broja djelatnika na procjenu troškova uporabe građevine kreće se u rasponu od ±17% za promjene varijable prosječnog broja djelatnika u granicama od ±20%.

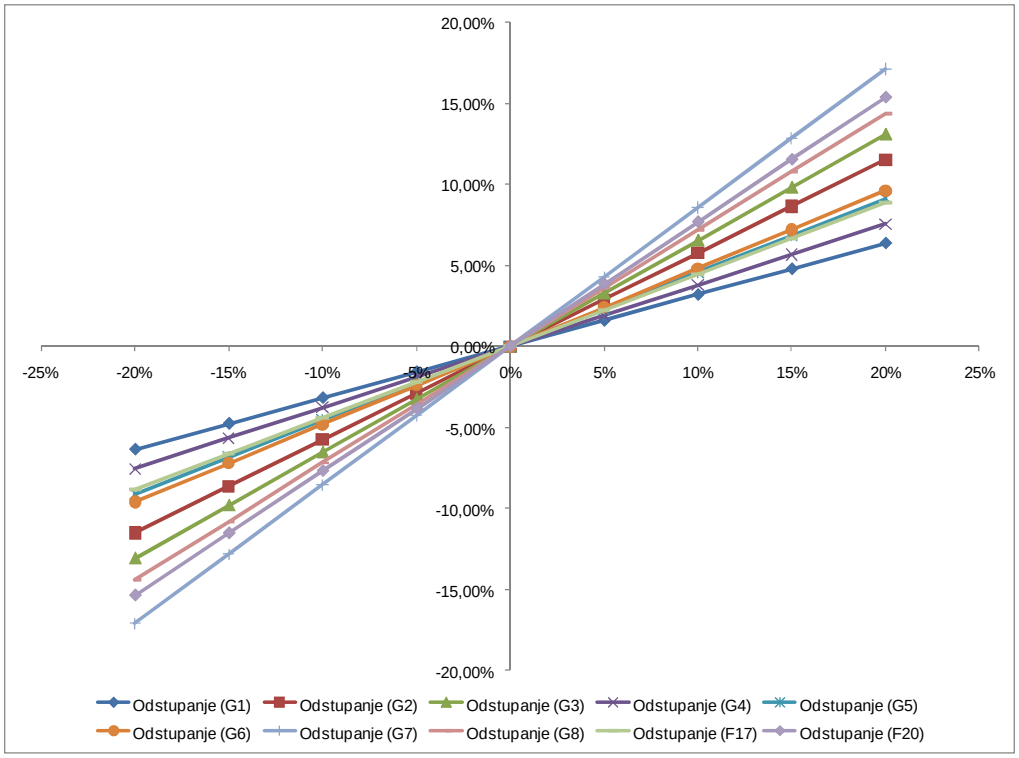

Slika 35 Rezultati analize osjetljivosti – model 2

Analizom osjetljivosti je utvrđeno kako promjena prosječnog broja djelatnika, izraženo u postotcima, uzrokuje gotovo jednaku promjenu procijenjenih uporabnih troškova kod nekih

građevina. Ovo dovodi do zaključka kako je prilikom primjene modela, odnosno predviđanja troškova uporabe, potrebno što preciznije predvidjeti prosječni broj djelatnika za razdoblje predviđanja troškova. Ako dođe do promjene broja djelatnika, podatci se mogu iznova unijeti u model, odnosno ažurirati ga. Kako model daje podatke o prosječnim godišnjim neto troškovima uporabe, podatci o promjeni broja djelatnika mogu se (i moraju) ažurirati na godišnjoj bazi zbog njihova utjecaja na procjenu troškova.

4.5 MODEL PROCJENE DISKONTIRANIH TROŠKOVA UPORABE GRAĐEVINA

Metode vrjednovanja projekata dijele se na statičke i dinamičke, osnovna razlika među njima je što dinamičke metode nastoje uvažiti vremensku vrijednost novca [144]. Od dinamičkih metoda posebno se ističe metoda neto sadašnje vrijednosti.

U tablici 24 prikazane su prednosti i nedostatci različitih metoda financijskog vrjednovanja koje se primjenjuju za analizu troškova životnog ciklusa [143, 145-146].

Tablica 24 Prednosti i nedostatci metoda financijskog vrjednovanja troškova životnog ciklusa [140, 143, 145-146]

METODA	ŠTO RAČUNA?	PREDNOSTI	NEDOSTACI	UPORABA
Metoda povratnog razdoblja	Vrijeme potrebno za povrat početnog ulaganja. Investicija s najkraćim periodom povrata je najisplativija.	Brz i jednostavan proračun. Laka interpretacija rezultata.	Ne uzima u obzir inflaciju i novčane tokove.	Gruba procjena profitabilnosti investicije.
Metoda diskontiranog povrata	U principu ista metoda kao metoda povratnog razdoblja samo što u obzir uzima i vremensku vrijednost novca.	Uzima u obzir i vremensku vrijednost novca.	Zanemaruje sve novčane tokove izvan povratnog perioda.	Probir alternativa, ali ne i odlučivanje.
Metoda neto sadašnje vrijednosti	Diskontnom stopom diskontira sve buduće troškove i dobiti na sadašnju vrijednost. Projekt s većom NSV je najisplativiji projekt.	Uzima u obzir vremensku vrijednost novca.	Teža interpretacija rezultata. Neuporabljiva za alternative različitog životnog vijeka.	Uglavnom se koristi za proračun(analizu) troškova životnog ciklusa.
Metoda ekvivalentnih godišnjih troškova	Izražava godišnju ekvivalentu vrijednost neto sadašnje vrijednosti. Uzima u obzir sadašnju vrijednost anuiteta.	Omogućava usporedbu alternativa različitih životnih vjekova.	Daje samo prosječnu vrijednost. Nema podataka o stvarnom trošku za svaku godinu.	Usporedba različitih alternativa različitog životnog vijeka.
Metoda interne stope povrata	Diskontna stopa pri kojoj je sadašnja vrijednost očekivanih novčanih tokova jednaka sadašnjoj vrijednosti izdataka.NSV je jednaka nuli. Alternativa s najvećom internom stopom povrata je najbolja.	Rezultat predočen postotkom što daje očitu interpretaciju.	Uporabljiva jedino ako projekt donosi dobit.	Samo za investicije koje donese dobit (prihode) što uvijek nije slučaj u građevinarstvu.
Metoda neto uštede	Računa se kao razlika sadašnje vrijednosti dobiti koja će nastati investicojom i vrijednosti investicije. Alternativa s najvećom neto uštedom je najbolja.	Lako razumljiva metoda procjene investicija.	Uporabljiva jedino ako projekt donosi dobit.	Služi usporedbi alternativa, ali samo ukoliko ostvaruju dobit.

Na temelju karakteristika metoda za izračun troškova životnog ciklusa [25], napravljena je tablica s prikazom osnovnih prednosti i nedostataka metoda kao i njihovih osnovnih karakteristika. U tablici 25 prikazane su najčešće rabljene metode za izračun troškova životnog ciklusa. Naglasak je stavljen na nedostatke svake od metoda.

Tablica 25. Metode izračuna troškova životnog ciklusa i njihovi nedostatci [25]

Metoda	Karakteristike	Prednosti	Nedostaci
Metoda neto sadašnje vrijednosti	Daje neto sadašnju vrijednost svih prihoda i izdataka projekta koji će se javiti tijekom životnog vijeka građevine. Troškovi se prikazuju kao pozitivna vrijednost, a izdaci kao negativna vrijednost.	Najčešći pristup pri izračunu troškova životnog ciklusa.	1. Brojčana vrijednost rezultata koja klijentu ne znači previše. 2. U slučaju alternativa s različitim životnim vjekom potrebno je s preostalom vrijednosti alternative s kraćim životnim vijekom pokriti preostali period.
Ekvivalentni godišnji troškovi	Svi troškovi životnog ciklusa predstavljaju se godišnjim ekvivalentim troškovima. Metoda je zasnovana na metodi neto sadašnje vrijednosti.	Omogućava usporedbu alternativa različitog životnog vijeka	1. Rezultat je prosječna vrijednost koja ne daje podatke o stvarnim troškovima svake godine životnog ciklusa.
Diskontirani povratni period	Vrijeme potrebno za povrat investicije pri čemu se uvažava vremenska vrijednost novca.	Uzima u obzir vremensku vrijednost novca.	1. Zanemarivanje novčanih tokova izvan povratnog perioda. 2. Potrebna je evaluacija prihvatljivog povratnog perioda za što ne postoji nikakva metoda.
Interna stopa povrata	Postotak zarade ovisno o količini uloženog kapitala tijekom svake godine životnog ciklusa nakon povrata uloženog kapitala.	Rezultat je jasno predstavljen postotkom i ne zahtjeva uporabu diskontne stope kao prethodne metode.	1. Ovo je metoda pokušaja i pogrešaka. 2. Osnovna pretpostavka metode je da će projekt stvarati dobit što nije uvijek slučaj u građevinarstvu.
Neto uštede	Proračun vrijednosti sadašnje vrijednosti prihoda stvorenog investicijom u odnosu na investiranu vrijednost.	Lako razumljiva tradicionalna metoda procjene vrijednosti investicije.	1. Osnovni nedostatak metode je pretpostavka da će projekt stvarati dobit što nije uvijek slučaj u građevinarstvu.
Omjer prihoda i izdataka	Omjer sadašnje vrijednosti dobiti investicije i troškova investicije.	Tradicionalna metoda procjene vrijednosti investicije.	1. Osnovni nedostatak metode je pretpostavka da će projekt stvarati dobit što nije uvijek slučaj u građevinarstvu.

Metoda neto sadašnje vrijednosti po mnogim autorima jedna je od najboljih mogućih metoda za vrjednovanje ukupnih životnih troškova različitih rješenja građevina [39].

Vremenske preferencije ekonomskih subjekata imaju važnu karakteristiku, a to je da su im kvantificirane koristi u sadašnje vrijeme veće vrijednosti od onih u budućnosti. Ta činjenica posebno je važna u građevinskim projektima, jer su projekti u pravilu dugotrajni i vremenska vrijednost novca ima važnu ulogu te je izuzetno važno prebroditi vremenski nesklad između novčanih tijekova iz različitih razdoblja [144].

Veza između sadašnje i buduće vrijednosti novca izražava se uz pomoć kamatnog množitelja [22, 143-144, 147-148]

$$FV = PV \cdot (1+r)^n \tag{42}$$

gdje je:

- *FV* konačna vrijednost glavnice
- *PV* početna vrijednost glavnice
- *r* kamatna stopa
- *n* broj kamatnih razdoblja

$$PV = \frac{FV}{(1+r)^n} \tag{43}$$

Neto sadašnja vrijednost definira se kao razlika uloženog kapitala i ukupne diskontirane razlike priljeva i odljeva sredstava kroz cijelo vrijeme trajanja projekta [149].

Neto sadašnja vrijednost je sadašnja vrijednost novčanih tokova koje projekt generira tijekom investicijskog horizonta, umanjena za sadašnju vrijednost investicijskih ulaganja [146].

Metoda neto sadašnje vrijednosti omogućava svođenje niza novčanih priljeva koji se javljaju u različito vrijeme u budućnosti na jednu vrijednost u vremenu, a opisani postupak naziva se diskontiranje [150].

Neto sadašnja vrijednost budućih troškova brzo se smanjuje tijekom vremena ovisno o visini diskontne stope, što je ilustrirano na slici 36. Prikazano je smanjenje neto sadašnje vrijednosti novčanih priljeva u iznosu od 1000 novčanih jedinica godišnje tijekom vremenskog razdoblja od 30 godina.

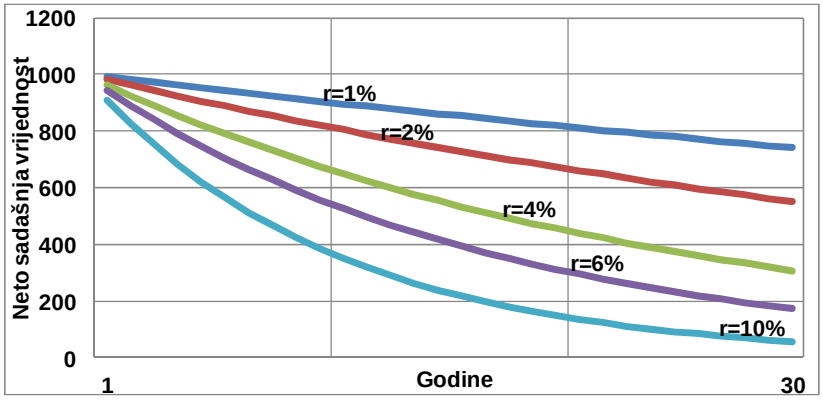

Slika 36. Promjena neto sadašnje vrijednosti u vremenu, ovisno o visini diskontne stope.

4.5.1 Diskontna stopa

Vrlo važna varijabla pri proračunu diskontiranih troškova životnog ciklusa građevina svakako je diskontna stopa koja odražava vremensku vrijednost novca i utjecaj inflacije. Izborom većih diskontnih stopa ide se na ruku kratkoročnim projektima s niskim kapitalnim troškovima, dok u suprotnom niže diskonte stope daju prednost mogućnosti uštede troškova u budućnosti [4].

Diskontna stopa može odražavati djelovanje inflacije kao i sposobnost zarade novca uloženog na određeni vremenski rok [52].

Vrijednosti diskontne stope mogu biti i sljedeće vrijednosti:

- kamata koju tvrtka plaća za posuđeni novac
- kamata koja bi se ostvarila posuđivanjem novca koji je uložen u neku investiciju
- najniža kamatna stopa zajmova u financijski stabilnoj proizvodnji
- nominalna kamatna stopa državnih obveznica [35, 43].

Diskontna stopa kao stopa diskontiranja predstavlja mjeru vremenske vrijednosti novca, odnosno svodi buduće novčane iznose ili primitke na sadašnju vrijednost. Pri diskontiranju na sadašnju vrijednost, diskontna stopa izuzetno je važna. Viša diskontna stopa ide u korist projektima s nižim kapitalnim troškovima, projektima kraćeg životnog vijeka i projektima s visokim troškovima održavanja. Ovo pravilo vrijedi i obrnuto. Nadalje, izborom duljeg uporabnog vijeka i većih diskontnih stopa moguće je dobiti rezultate koji bi mogli dovesti do pogrešnih zaključaka ako se ne analiziraju detaljno svi značajni faktori koji utječu na ukupne životne troškove građevina [43, 151].

Kada govorimo o diskontiranju, potrebno je razlikovati sljedeće vrste troškova [3, 37]:

- nominalni troškovi
- stvarni troškovi
- diskontirani troškovi.

Nominalni troškovi predstavljaju onu vrijednost troška koju će biti potrebno podmiriti kada za to dođe vrijeme (npr. troškovi koji sadržavaju inflaciju i promjenu cijene zbog npr. promjene tehnologije). Stvarni troškovi zanemaruju inflaciju, ali uzimaju u obzir promjene cijene zbog promjena na tržištu. Diskontirani troškovi su stvarni troškovi diskontirani diskontnom stopom što je ustvari jednako nominalnim troškovima koji su diskontirani nominalnom kamatnom (ili diskontnom) stopom [52, 152].

Veza između nominalnih, stvarnih i diskontiranih troškova dana je sljedećim formulama [24]:

$$C_R = C_N \cdot (1+f)^{-n} \tag{44}$$

$$C_D = C_N \cdot (1+i)^{-n} \tag{45}$$

gdje je:

- C_N nominalni trošak
- C_R stvarni trošak
- C_D diskontirani trošak
- i nominalna diskontna stopa
- n broj godina
- f stopa inflacije.

Ovisno o tome koriste li se nominalni ili stvarni troškovi, primjenjuju se različite diskontne stope. Koriste li se nominalni troškovi, diskontna stopa treba uzeti u obzir i inflaciju, a koriste li se stvarni troškovi, diskontna stopa može izostaviti stopu inflacije. Različite diskontne stope rabe različite organizacije i pojedinci [3, 37].

The National Institute of Standards and Technology (NIST) također razlikuje ove dvije vrste diskontne stope, stvarnu i nominalnu. Razlika među njima je ta da stvarna diskontna stopa ne sadrži stopu inflacije, a nominalna diskontna stopa uzima u obzir i stopu inflacije. Međutim, ova činjenica ne znači da stvarna diskontna stopa zanemaruje inflaciju, ona jednostavno pojednostavljuje sam postupak proračuna izostavljajući inflaciju iz jednadžbe neto sadašnje vrijednosti. Uporaba bilo koje od navedenih diskontnih stopa u kombinaciji s odgovarajućom vrstom troškova daje jednake rezultate [22, 147].

Osim ove podjele postoji još jedna, podjela na financijsku i društvenu diskontnu stopu. Financijska diskontna stopa najčešće se određuje prema kamatama koje bi tvrtka plaćala za posuđeni novac ili kao kamata koja bi se ostvarila ulaganjem novca u banku ili u državne obveznice. Društvene diskontne stope odražavaju društvene vrijednosti pri usporedbi i vrjednovanju velikih javnih zahvata kao što je izgradnja infrastrukture. Više stope društvenih diskontnih stopa odražavaju tendenciju prebacivanja troškova na buduće generacije [153].

Povijesno gledano, diskontna stopa odražava opću stopu produktivnosti proizvođača, sektora ili grane privrede. Opća stopa produktivnosti dugoročno iznosi između 0% i 2%. Zbog ove činjenice preporučuje se uzimati upravo te vrijednosti kao stvarne diskontne stope te vrjednovati i usporediti rezultate dobivene uzimanjem tih stopa [3].

Stvarna diskontna stopa može se izračunati iz nominalne diskontne stope prema sljedećoj formuli [3, 143, 154]:

$$d = \frac{1+D}{1+I} - 1 \tag{46}$$

gdje je:

- *d* stvarna diskontna stopa
- *D* nominalna diskontna stopa
- *I* inflacija.

Analogno, iz prethodne formule moguće je izračunati i nominalnu diskontnu stopu prema sljedećoj formuli:

$$D = (1+I) \cdot (1+d) - 1 \tag{47}$$

U slučaju kada ocjena varijantnog rješenja ovisi materijalno o utjecaju diskontiranja tijekom duljeg vremenskog razdoblja, općeprihvaćeno pravilo je korištenja nižih diskontnih stopa. Glavni razlozi ovom smanjenju diskontne stope kod dugoročnih projekata vezani su za sve veću nesigurnost oko budućnosti koja se povećava s produljenjem vremenskog razdoblja. Zbog navedenih činjenica predlaže se smanjenje diskontne stope ovisno o duljini vremenskog razdoblja, kako je prikazano u tablici 26 [155].

Tablica 26. Diskontne stope i vremensko razdoblje [155]

Vremensko razdoblje	**0-30**	**31-75**	**76-125**	**126-200**	**201-300**	**301+**
Diskontna stopa	3.50%	3.0%	2.50%	2.0%	1.50%	1.0%

Slično predlaže i *Weitzman*, njegova klizna skala za diskontne stope rezultat je istraživanja preko dvije tisuće znanstvenika s područja ekonomije i prikazana je u tablici 27 [156]. U ovoj skali povećanjem duljine vremenskog razdoblja opada iznos diskontne stope.

Tablica 27. Weitzmanova klizna skala diskontnih stopa [156]

Vremensko razdoblje	**Raspon godina**		**Diskontna stopa**
	Od	**Do**	
Neposredna budućnost	1	5	4%
Bliska budućnost	6	25	3%
Dalja budućnost	26	75	2%

Na slici 37 prikazano je kretanje neto sadašnje vrijednosti troškova održavanja građevine, ovisno o promatranom vremenskom razdoblju i primijenjenoj diskontnoj stopi pri izračunu neto sadašnje vrijednosti troškova. Na slici je vidljivo kako se povećanjem diskontne stope smanjuje razlika u neto sadašnjoj vrijednosti troškova održavanja građevine za vremensko razdoblje od 30 i 50 godina. Pri diskontnoj stopi od 9,50% gotovo nema razlike između neto sadašnje vrijednosti troškova održavanja za promatrana vremenska razdoblja.

Promatra li se utjecaj promjene diskontne stope i trajanje promatranog vremenskog razdoblja, vidi se kako ista promjena stope ima puno veći utjecaj na promjenu troškova duljeg vremenskog razdoblja, ali i kako s povećanjem diskontne stope taj utjecaj opada [151].

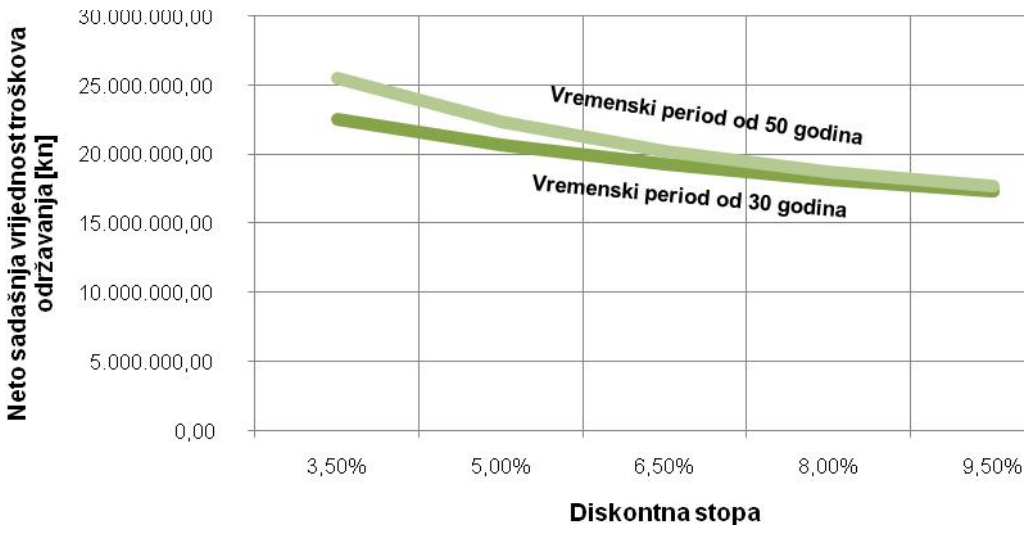

Slika 37 Neto sadašnja vrijednost troškova održavanja građevine [151]

Vlada Republike Hrvatske objavila je 30. rujna 2008. godine novi Pravilnik o utvrđivanju referentne i diskontne stope [157]. Komisija o reviziji načina određivanja referentnih i diskontnih stopa predlaže metodologiju utvrđivanja diskontne i referentne stope koja je i usvojena sa sljedećim karakteristikama:

- metodologija je jednostavna za primjenu (naročito za države članice koje se bave mjerama obuhvaćenima pravilima de *minimis* i uredbama o skupnom izuzeću)
- osigurava jednak tretman državama članicama uz minimalna odstupanja od trenutačne prakse i olakšava primjenu referentnih stopa za nove države članice
- koristi pojednostavljene kriterije uzimajući u obzir kreditnu sposobnost poduzetnika umjesto samo njegovu veličinu, što se čini prejednostavnim kriterijem. Štoviše, ova metoda omogućuje da se izbjegne dodavanje nesigurnosti i složenosti metodama izračuna u promjenjivom bankovnom i financijskom okruženju zbog provedbe okvira *Basel II*, što bi moglo imati značajan učinak na alokaciju kapitala, kao i na ponašanje banaka.

Temeljem te odluke diskontne i referentne stope računaju se na novi način, u tablici 28 prikazano je njihovo kretanje od 01. siječnja 2008. godine do 1. travnja 2011. godine [158-159]. Podatci navedeni u tablici su podatci Agencije za zaštitu tržišnog natjecanja, pri čemu se diskontna stopa kao i referentna stopa koriste isključivo sa svrhom izračuna elementa državne potpore u zajmovima pod povoljnijim uvjetima odobrenim poduzetnicima od strane davatelja državnih potpora. Naime, sve buduće novčane tokove kod takvih zajmova potrebno je diskontirati kako bi utvrdili iznos državne potpore u trenutku njezinog odobrenja.

Konkretno, diskontna stopa koristi se kod izračuna nezakonite državne potpore uvećane za kamate kada se nalaže povrat takve nezakonite potpore. Dosada se kod povrata nezakonitih potpora koristila zakonska zatezna kamata, ali je izmjenama Zakona o državnim potporama (NN 49/2011) to promijenjeno.

Agencija za zaštitu tržišnog natjecanja pri izračunima, bilo da je riječ o odobrenju nove potpore ili iznosu potpore za povrat, koristi jednostavan račun i ne korigira diskontnu stopu za stopu inflacije ili ostale pokazatelje, pa bi prema tome ova diskontna stopa više odražavala nominalnu diskontnu stopu.

Tablica 28. Osnovna referentna i diskontna stopa u Republici Hrvatskoj [158]

Razdoblje		Osnovna referentna stopa	Diskontna stopa
Od	Do		
1.7.2011.	…	3,47%	4,47%
1.4.2011.	…	4,10%	5,10%
1.1.2011.	31.03.2011.	4,10%	5,10%
1.6.2010.	31.12.2010.	3,79%	4,79%
1.4.2010.	31.5.2010.	5,46%	6,46%
1.1.2010.	31.3.2010.	7,33%	8,33%
15.10.2009.	31.12.2009.	7,63%	8,63%
1.7.2009.	30.9.2009.	7,63%	8,63%
1.4.2009.	30.6.2009.	7,63%	8,63%
1.3.2009.	31.3.2009.	7,63%	8,63%
1.1.2009.	28.2.2009.	6,54%	7,54%
1.10.2008.	31.12.2008.	5,55%	6,55%
1.7.2008.	30.9.2008.	6,01%	7,01%
1.4.2008.	30.6.2008.	6,01%	7,01%
1.1.2008.	31.3.2008.	6,01%	7,01%

U tablici 29 prikazano je kretanje prosječne godišnje stope inflacije (stopa inflacije mjerena je indeksom potrošačkih cijena) u Republici Hrvatskoj tijekom vremenskog razdoblja od 1998. godine do 2009. godine [160-162].

Tablica 29. Prosječna godišnja stope inflacije u Republici Hrvatskoj od 1998. do 2011. godine [160-162]

Godina	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011
Prosječna godišnja stopa inflacije	5,70%	4,00%	4,60%	3,80%	1,70%	1,80%	2,10%	3,30%	3,20%	2,90%	6,10%	2,40%	1,10%	1,80%

Na temelju podataka o kretanjima diskontne stope [158, 163] i kretanjima stope inflacije iz tablice 29, na slici 38 prikazano je grafički kretanje stope inflacije i diskontne stope za vremensko razdoblje od 1999. godine do 2011. godine.

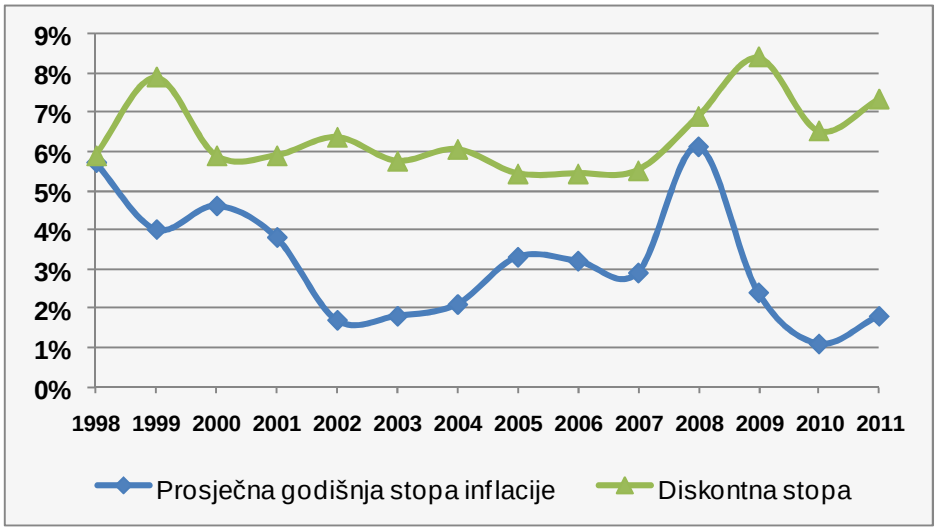

Slika 38. Grafički prikaz kretanja stope inflacije i diskontne stope

4.5.2 Ekvivalentna godišnja vrijednost

Budući da su podatci o troškovima građevina Sveučilišta u Osijeku prikupljeni za nejednaka vremenska razdoblja te da modeli procjene troškova predviđaju troškove za proizvoljno vremensko razdoblje, javlja se problem ako se ti troškovi diskontiraju i uspoređuju. Ovo je moguće riješiti primjenom metode ekvivalentne godišnje vrijednosti.

Ekvivalentna godišnja vrijednost izražava vrijednost svih troškova tijekom vremenskog razdoblja analize kao konstantne ekvivalentne godišnje vrijednosti za svaku godinu tijekom razdoblja analize. Svi troškovi koji se jave tijekom tog razdoblja mogu se prikazati preko ekvivalentnih godišnjih troškova. U izrazu 48 s *A* je označena ekvivalentna godišnja vrijednost, s *P* troškovi u prvoj godini, diskontna stopa označena je s *i*, a broj godina s *N* [67, 153, 164].

$$A = P \cdot \left(\frac{i \cdot (1+i)^N}{(1+i)^N - 1} \right) \tag{48}$$

Kao rezultat analize troškova životnog ciklusa obično se javlja jedinstvena vrijednost dobivena metodom neto sadašnje vrijednosti ili metodom ekvivalentnih godišnjih troškova svih predviđenih troškova građevine tijekom životnog vijeka [165].

Usporedbu građevina različitog životnog vijeka omogućava metoda ekvivalentnih godišnjih troškova, što je u biti prosječna diskontirana neto sadašnja vrijednost svih troškova životnog ciklusa za dani životni vijek [166-167].

Metodom ekvivalentne godišnje vrijednosti računa se konstantni godišnji anuitet koji se ostvaruje tijekom promatranog razdoblja na osnovi diskontirane razlike prihoda i troškova projekta. Kao rezultat primjene, dobiju se novčani tijekovi unutar promatranog vremenskog razdoblja svedeni na vrijednost na kraju promatranog razdoblja [168].

Metodom ekvivalentnih godišnjih troškova svi troškovi koji se javljaju tijekom životnog vijeka pretvaraju se u konstantne ekvivalentne godišnje troškove. Ova metoda je jedna od najprikladnijih metoda usporedbe, posebice za projekte različitog životnog vijeka [37, 169].

Budući da troškovi različitih mogućnosti mogu biti različiti od godine do godine metoda neto sadašnje vrijednosti i nije najprikladnija za usporedbu, stoga se preporuča procjena prosječnih godišnjih troškova životnog ciklusa. Ovom metodom u obzir se uzimaju inicijalni troškovi kao i vremenska vrijednost novca, i naziva se metoda ekvivalentnih godišnjih troškova. Kako bi se izračunali ekvivalentni godišnji troškovi potrebno je izračunati neto sadašnju vrijednost svih troškova tijekom životnog ciklusa (PV). Ako je s „d“ označena diskontna stopa, a s „n“ broj godina, tada se prosječni godišnji troškovi računaju kao [170]:

$$AEC = \frac{PV \cdot d}{1-(1+d)^{-n}} \tag{49}$$

Primjenom jednake vremenske transformacije troškova na sve prihode i dobiti tijekom životnog ciklusa moguće je izračunati smislene ekvivalentne procjene svih novčanih tijekova i kao rezultat dobiti reprezentativne godišnje ekvivalente kretanja troškova koji su u skladu s preporukama o primjeni metode neto sadašnje vrijednosti [67].

4.5.3 Model procjene diskontiranih troškova uporabe građevina

Procijenjeni troškovi uporabe građevina računaju se prema izrazu:

$$PGNTU = 31304{,}00 - 230{,}48 \cdot P_S - 208{,}51 \cdot P_U + 3047{,}94 \cdot D_{PR} \tag{50}$$

gdje su:

- *PGNTU,* prosječni godišnji nominalni troškovi uporabe
- P_S, površina sanitarnih prostora
- P_U, površina uredskih prostorija
- D_{PR}, prosječni broj djelatnika tijekom promatranog vremenskog razdoblja.

Dobiveni troškovi predstavljaju prosječnu godišnju vrijednost troškova uporabe građevina tijekom vremenskog razdoblja od *N* godina, odnosno nominalne troškove. Ovaj izraz može se raspisati kao kombinacija izraza 43 i 50, što omogućuje izračun procijenjene neto sadašnje vrijednosti troškova uporabe građevina za N godina prema izrazu:

$$PGNTU_{NPV} = PGNTU \sum_{n=1}^{N} \frac{1}{(1+r)^n} \tag{51}$$

gdje su:

- *PGNTU,* prosječni godišnji nominalni troškovi uporabe
- *r,* nominalna diskontna stopa
- *n,* godina u kojoj se javljaju troškovi

- *N,* broj vremenskih razdoblja (godina) za koje se računaju diskontirani troškovi uporabe građevina.

U tablici 30 prikazane su srednje vrijednosti točnosti modela izračunate prema izrazu 36. Prikazane su i stvarne i procijenjene vrijednosti troškova uporabe na osnovi kojih su srednje vrijednosti točnosti modela i računate. Prikazane vrijednosti troškova odnose se na prosječne vrijednosti troškova uporabe građevina tijekom referentnog razdoblja.

Građevina 4 (F14) i građevina 9 (F17) imaju slične srednje vrijednosti točnosti modela (A_C) ali suprotnog predznaka, odnosno na građevini 4 (F14) vrijednost troškova uporabe dobivena modelom manja je od stvarne vrijednosti troškova uporabe, dok za građevinu 9 (F17) vrijedi suprotno, vrijednost troškova uporabe dobivena modelom veća je od stvarne vrijednosti troškova uporabe. Podatci za obje građevine dani su za slična referentna razdoblja (4 i 5 godina).

Za obje građevine u nastavku će se prikazati rezultati primjene modela procjene diskontiranih troškova uporabe građevina prema izrazu 51.

Tablica 30 Srednje vrijednosti točnosti modela uporabe građevina

Šifra građevine	Građevina	Ref. razdoblje	Stvarna vrijednost troškova uporabe*	Vrijednost troškova uporabe dobivena modelom*	Srednja vrijednost točnosti modela (A_C)
F4	Građevina 1	8	363.703 kn	363.477 kn	-0,06%
F9	Građevina 2	10	424.020 kn	460.389 kn	8,58%
F10	Građevina 3	12	349.527 kn	349.464 kn	-0,02%
F14	Građevina 4	4	396.157 kn	362.941 kn	-8,38%
F18	Građevina 5	8	372.894 kn	394.232 kn	5,72%
F8	Građevina 6	12	463.924 kn	450.931 kn	-2,80%
F16	Građevina 7	10	645.192 kn	634.307 kn	-1,69%
F6	Građevina 8	6	720.453 kn	720.130 kn	-0,04%
F17	Građevina 9	5	749.302 kn	820.985 kn	9,57%
F20	Građevina 10	10	401.307 kn	434.287 kn	8,22%

** Prikazane vrijednosti troškova uporabe građevina odnose se na prosječnu vrijednost troškova tijekom referentnog razdoblja*

Grafički prikaz vrijednosti kumulativnih troškova uporabe (stvarnih vrijednosti i vrijednosti dobivenih modelom) za građevinu 4 dan je na slici 39 za razdoblje od 2005. do 2008., a za građevinu 9 na slici 40 za razdoblje od 2004. do 2008. godine. Za prikazane stvarne kumulativne vrijednosti troškova uporabe građevina izračunate su njihove neto sadašnje vrijednosti prema izrazu 43 i prikazane kao kumulativne vrijednosti za obje građevine i pripadajuća referentna razdoblja.

Na slikama 39 i 40 grafički je prikazana usporedba stvarnih kumulativnih i kumulativnih vrijednosti troškova uporabe dobivenih modelom građevina 4 i 9. Diskontna stopa kojim su troškovi diskontirani iznosila je 5,10% (važeća diskontna stopa u trenutku proračuna, ožujak 2011).

Na slici 39 je vidljivo kako je vrijednost kumulativnih troškova uporabe dobivena modelom manja od vrijednosti stvarnih kumulativnih troškova uporabe građevine 4 i to za 8,38%, dok razlika istih troškova izraženih preko neto sadašnjih vrijednosti iznosi 5,42%.

Na slici 40 prikazano je kako je vrijednost kumulativnih troškova uporabe dobivena modelom veća od stvarne vrijednosti kumulativnih troškova uporabe građevine 9 i to za 9,57%, dok razlika istih troškova izraženih preko neto sadašnje vrijednosti iznosi 9,21%.

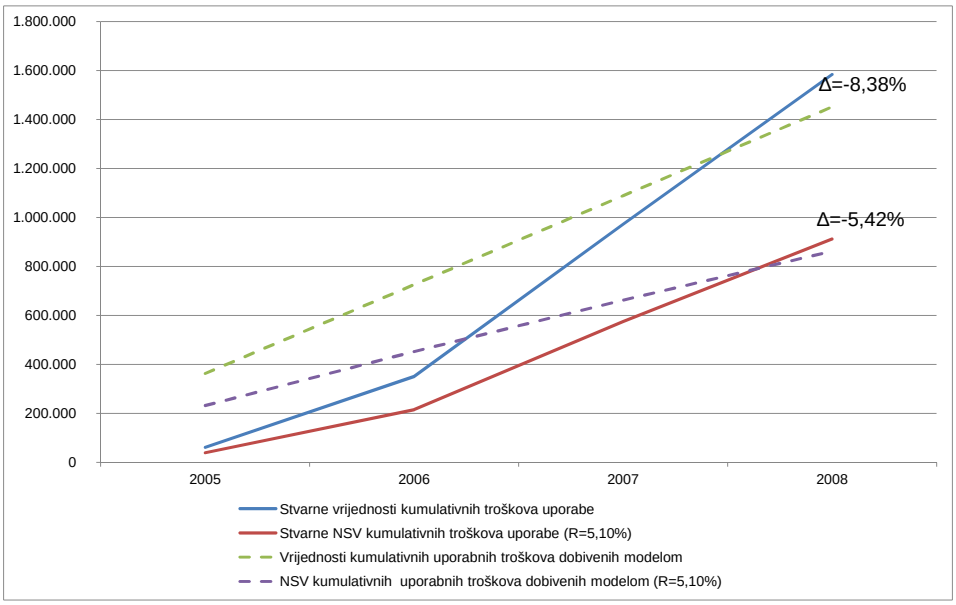

Slika 39 Grafički prikaz usporedbe kumulativnih troškova uporabe dobivenih modelom i stvarnih kumulativnih vrijednosti troškova uporabe građevine 4 (F14)

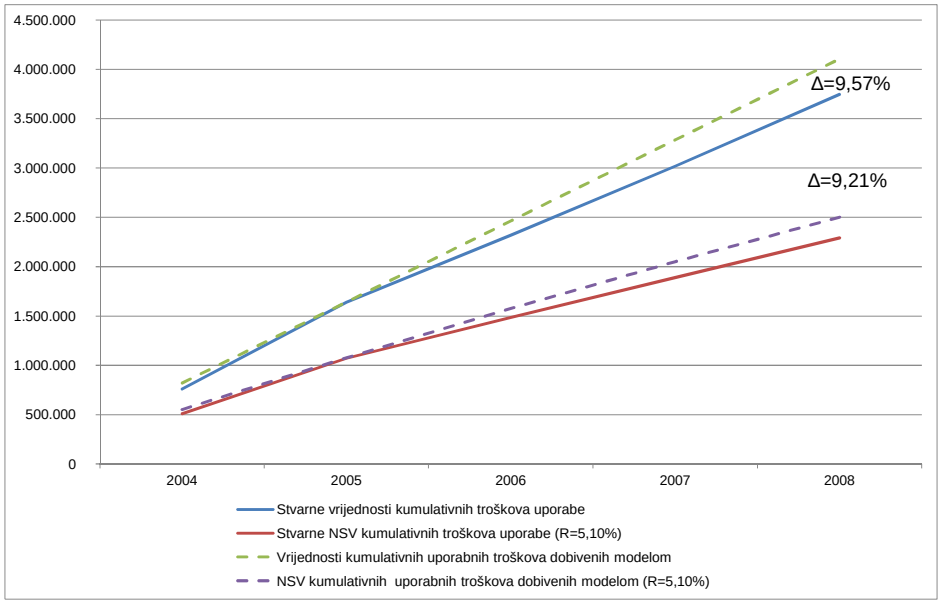

Slika 40 Grafički prikaz usporedbe kumulativnih troškova uporabe dobivenih modelom i stvarnih kumulativnih vrijednosti troškova uporabe građevine 9 (F17)

Kako bi se utvrdio utjecaj diskontne stope na model procjene diskontiranih troškova uporabe građevina, u nastavku će se varirati diskontna stopa od 5,10% u 2 koraka i to povećanjem i smanjenjem navedene stope u iznosu od 25%. Utjecaj promjene diskontne stope provjerit će se za sljedeće stope: 3,83%, 5,10% i 6,38%.

Rezultati utjecaja promjene diskontne stope na razliku kumulativnih troškova uporabe dobivenih modelom i stvarnih kumulativnih vrijednosti troškova uporabe prikazani su grafički na slikama 41 i 42 za građevine 4 i 9.

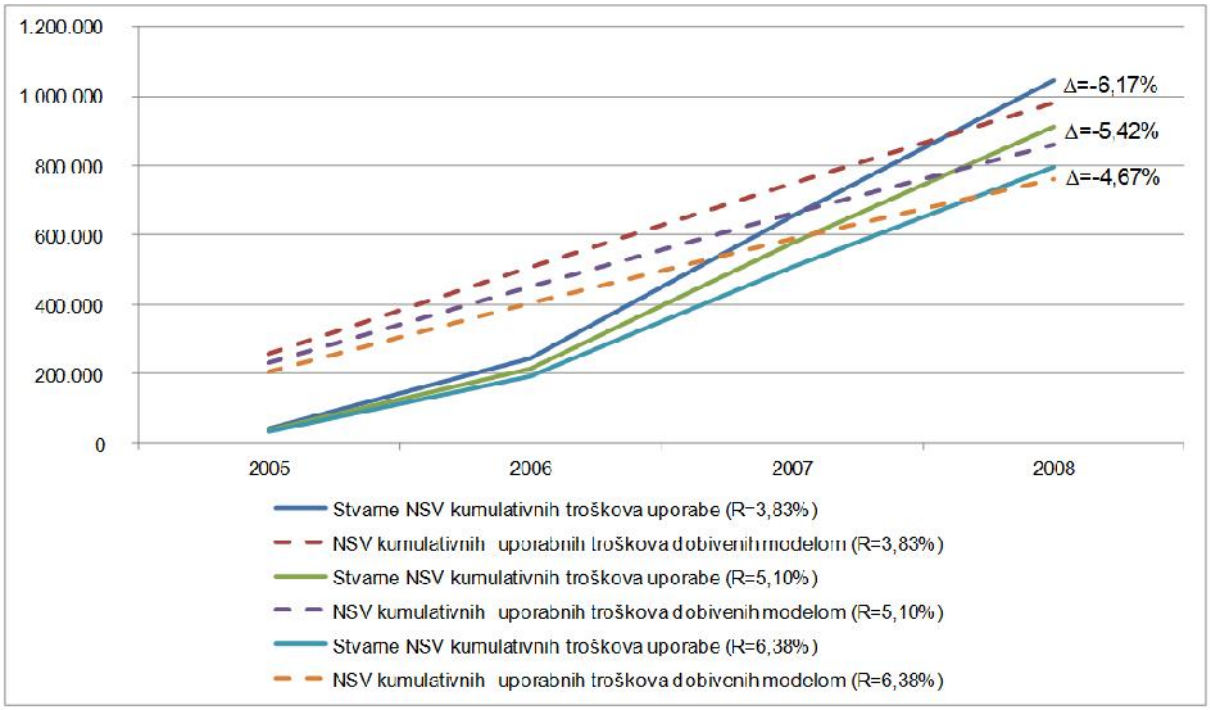

Slika 41 Promjena vrijednosti troškova uporabe ovisno diskontnoj stopi za građevinu 4

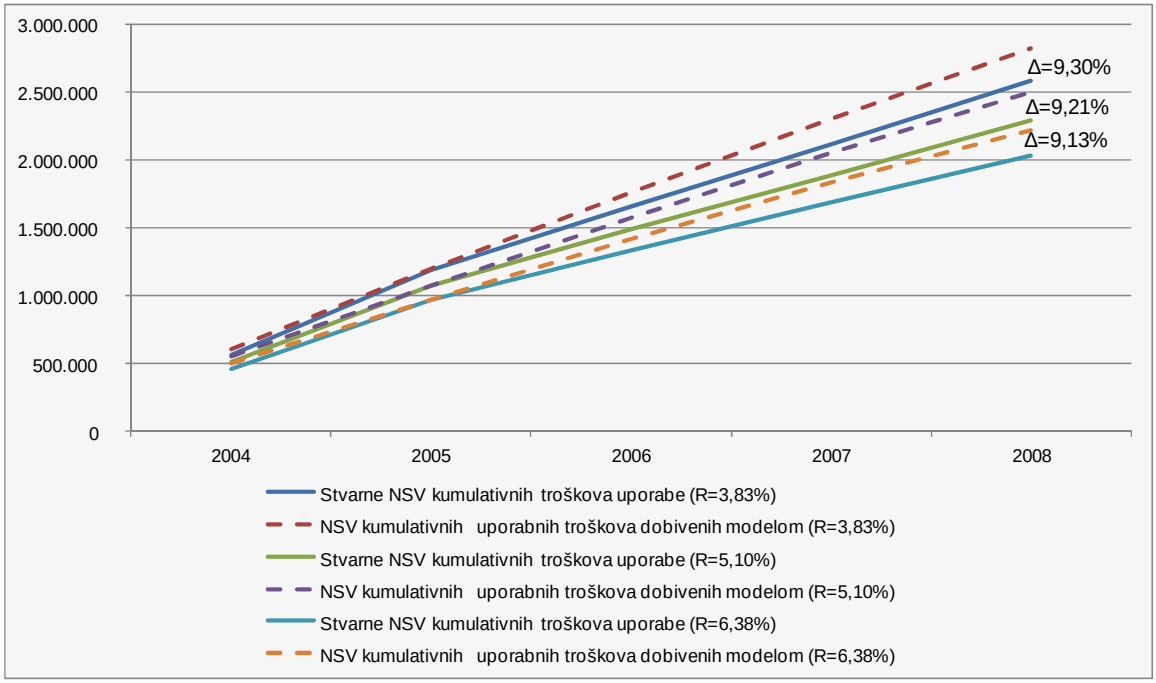

Slika 42 Promjena vrijednosti troškova uporabe ovisno diskontnoj stopi za građevinu 9

Iz prikazanoga je moguće zaključiti sljedeće: neovisno o tome jesu li vrijednosti troškova uporabe dobivene modelom veće ili manje od stvarnih vrijednosti troškova uporabe, diskontiranjem istih većim diskontnim stopama smanjuje se razlika između navedenih troškova, odnosno pogreška predviđanja. Porastom diskontne stope koja se rabi kako bi se utvrdila diskontirana vrijednost troškova uporabe dobivenih modelom, smanjuje se razlika u pogrešci predviđanja troškova uporabe.

4.6 PREDNOSTI I OGRANIČENJA MODELA PROCJENE TROŠKOVA UPORABE GRAĐEVINA

4.6.1 Prednosti modela procjene troškova uporabe građevina

Prva i najveća prednost primjene predloženog modela procjene troškova uporabe građevina je jednostavnost primjene, jer je za procjenu troškova potreban mali broj varijabli. Varijable potrebne za procjenu troškova su površina sanitarnih prostora, površina uredskih prostorija i prosječni godišnji broj djelatnika tijekom vremenskog razdoblja za koje se procjenjuju troškovi.

Ovo su podatci do kojih je moguće doći već u ranoj fazi projektiranja i razrade projekta pa samim time već u toj fazi model omogućuje procjenu troškova i razmatranje različitih projektnih rješenja građevina. Varijacijama vrijednosti varijabli moguće je vrjednovanje različitih projektnih rješenja sa stajališta uporabnih troškova građevina.

Nadalje, varijable navedenih funkcionalnih prostora, kao i varijabla broja djelatnika, su varijable koje mora sadržavati svako od projektnih rješenja bilo koje građevine koja je

namijenjena visokom školstvu. Ovo je važno zbog toga što je model zbog te činjenice primjenjiv na sve građevine tog tipa, što omogućuje izravnu usporedbu troškova.

Srednja vrijednost točnosti modela, računata prema izrazu 36 za građevine koje su sudjelovale u istraživanju i građevine za validaciju, iznosi 1,91%. Validacija modela na građevinama izvan Sveučilišta u Osijeku pokazala je kako je model jednako primjenjiv i na građevine izvan Sveučilišta u Osijeku gdje su zabilježena najveća odstupanja u iznosu do 9,57%. Ukupna točnost modela izračunata prema izrazu 37 iznosi -3,96%.

Kao rezultat procjene troškova uporabe, model daje vrijednosti prosječnih godišnjih nominalnih troškova uporabe koji su jednaki za svaku godinu tijekom promatranog vremenskog razdoblja.

Modificiranim modelom procjene troškova uporabe moguće je također odrediti i procijenjene neto sadašnje vrijednosti troškova uporabe građevina, odnosno diskontirane troškove uporabe. Ovo omogućuje primjenu prikladne diskontne stope u određenom trenutku kako bi se uvažila vremenska vrijednost troškova uporabe.

4.6.2 Ograničenja modela procjene troškova uporabe građevina

Prvo i osnovno ograničenje modela procjene troškova uporabe građevina je njegova primjenjivost isključivo na fakultetske građevine Sveučilišta u Osijeku. Kako su prikupljeni i obrađeni podatci o troškovima i karakteristikama fakultetskih građevina Sveučilišta u Osijeku, preporučuje se primjena samo na te građevine. Validacija modela izvršena je na građevini izvan Sveučilišta u Osijeku, ali budući da je riječ samo o jednoj građevini, rezultati nisu reprezentativni iako odstupanje nije bilo veliko (8,22%). Kako bi se utvrdila primjenjivost na građevine izvan Osijeka potrebno je povećati uzorak za validaciju, što je u ovom radu bilo onemogućeno zbog nedostupnosti podataka.

Drugo ograničenje o kojem je potrebno voditi računa definira da vrijednosti neovisnih varijabli koje se koriste za predviđanje nisu izvan granica neovisnih varijabli koje su se koristile za utvrđivanje regresijskih koeficijenata, budući da je u suprotnom moguće dobiti potpuno netočne rezultate [98, 102]. Prvi korak koji je potrebno provesti prije uporabe modela je provjera vrijednosti neovisnih varijabli građevine u odnosu na vrijednosti neovisnih varijabli koje su se koristile za utvrđivanje regresijskih koeficijenata.

Preporučene vrijednosti površina sanitarnih prostorija kreću se u rasponu od 72 m^2 do 680 m^2, a površina uredskih prostorija u rasponu od 140 m^2 do 755 m^2. Preporučene vrijednosti prosječnog godišnjeg broja djelatnika tijekom promatranog vremenskog razdoblja kreću se u rasponu od 38 do 178 djelatnika.

Uporaba modela, ako vrijednosti varijabli građevina nisu unutar ovih raspona, nije preporučljiva.

Treće ograničenje modela je broj godina za koje se procjenjuju troškovi uporabe građevina, a to je najviše za 12 godina, budući da je to najduže vremensko razdoblje za koji su prikupljeni podatci o troškovima uporabe građevina. Stoga se i procijenjeni troškovi uporabe mogu usporediti sa stvarnima samo za to vremensko razdoblje. Kako bi se utvrdilo vremensko razdoblje za koje se mogu procijeniti troškovi uporabe, potrebno je nastaviti s prikupljanjem i obradom podataka i usporedbom s procijenjenim troškovima.

Četvrto ograničenje modela procjene troškova uporabe odnosi se na osjetljivost modela na promjenu broja djelatnika, što je utvrđeno analizom osjetljivosti koja je pokazala kako za jednak postotak promjene broja djelatnika dolazi do gotovo jednake promjene procijenjenih troškova uporabe. Ova činjenica sugerira kako je potrebno oprezno pristupiti procjeni prosječnog broja djelatnika za vremensko razdoblje za koje se želi napraviti procjena troškova uporabe.

Peto ograničenje modela je potreba provedbe analize osjetljivosti procijenjenih neto sadašnjih vrijednosti troškova uporabe dobivenih uporabom izraza 51 kako bi se utvrdio utjecaj inflacije, promjena diskontne stope i deprecijacije na procjenu neto sadašnjih vrijednosti troškova uporabe.

5 RAZVOJ MODELA PROCJENE TROŠKOVA ODRŽAVANJA I UPORABE GRAĐEVINA

Za predložene modele troškova održavanja i uporabe i na osnovi rezultata regresijske analize izvršena je analiza vrijednosti koeficijenata determinacija (R^2), korijena srednje vrijednosti kvadratne pogreške kros validacije (*root mean square error of cross validation, RMESCV*) i vrijednosti sume kvadrata pogreške predviđanja modela dobivenih kros validacijom (PRESS), analogno modelu procjene troškova uporabe.

U tablici 31 su prikazani odabrani modeli troškova održavanja i uporabe s pripadajućim vrijednostima koeficijenata determinacija, vrijednostima korijena srednje vrijednosti kvadratne pogreške i vrijednostima sume kvadrata pogreške predviđanja modela.

Tablica 31 Vrijednosti sume kvadrata pogreške predviđanja modela, korijena srednje vrijednosti kvadratne pogreške i koeficijenata determinacije

MODELI TROŠKOVA ODRŽAVANJA I UPORABE*	PRESS	RMSECV	R^2
MTOUvar7	1,4875E+12	431205	0,6697
MTOUvar9	2,2243E+12	527293	0,4647
MTOUvar13	2,1269E+12	515613	0,441
MTOUvar7var15	3,0013E+12	612506	0,8444
MTOUvar1var7	1,5342E+12	437926	0,7046
MTOUvar4var7	1,8033E+12	474779	0,7006
MTOUvar1var7var15	2,5024E+12	559290	0,8951

** MTOU predstavlja kraticu za model troškova održavanja i uporabe*

Vrijednosti prikazane u tablici 31 poredane su prema veličini vrijednosti koeficijenta determinacije i vrijednostima sume kvadrata pogreške predviđanja modela od najmanje prema najvećoj i prikazane u tablici 32.

Tablica 32 Vrijednosti koeficijenata determinacije poredane od najmanjih prema najvećim vrijednostima

MODELI TROŠKOVA ODRŽAVANJA I UPORABE	PRESS	RMSECV	R^2
MTOUvar13	2126853000000	515613	0,441
MTOUvar9	2224300000000	527293	0,4647
MTOUvar7	1487504000000	431205	0,6697
MTOUvar4var7	1803324000000	474779	0,7006
MTOUvar1var7	1534232000000	437926	0,7046
MTOUvar7var15	3001304000000	612506	0,8444
MTOUvar1var7var15	2502444000000	559290	0,8951

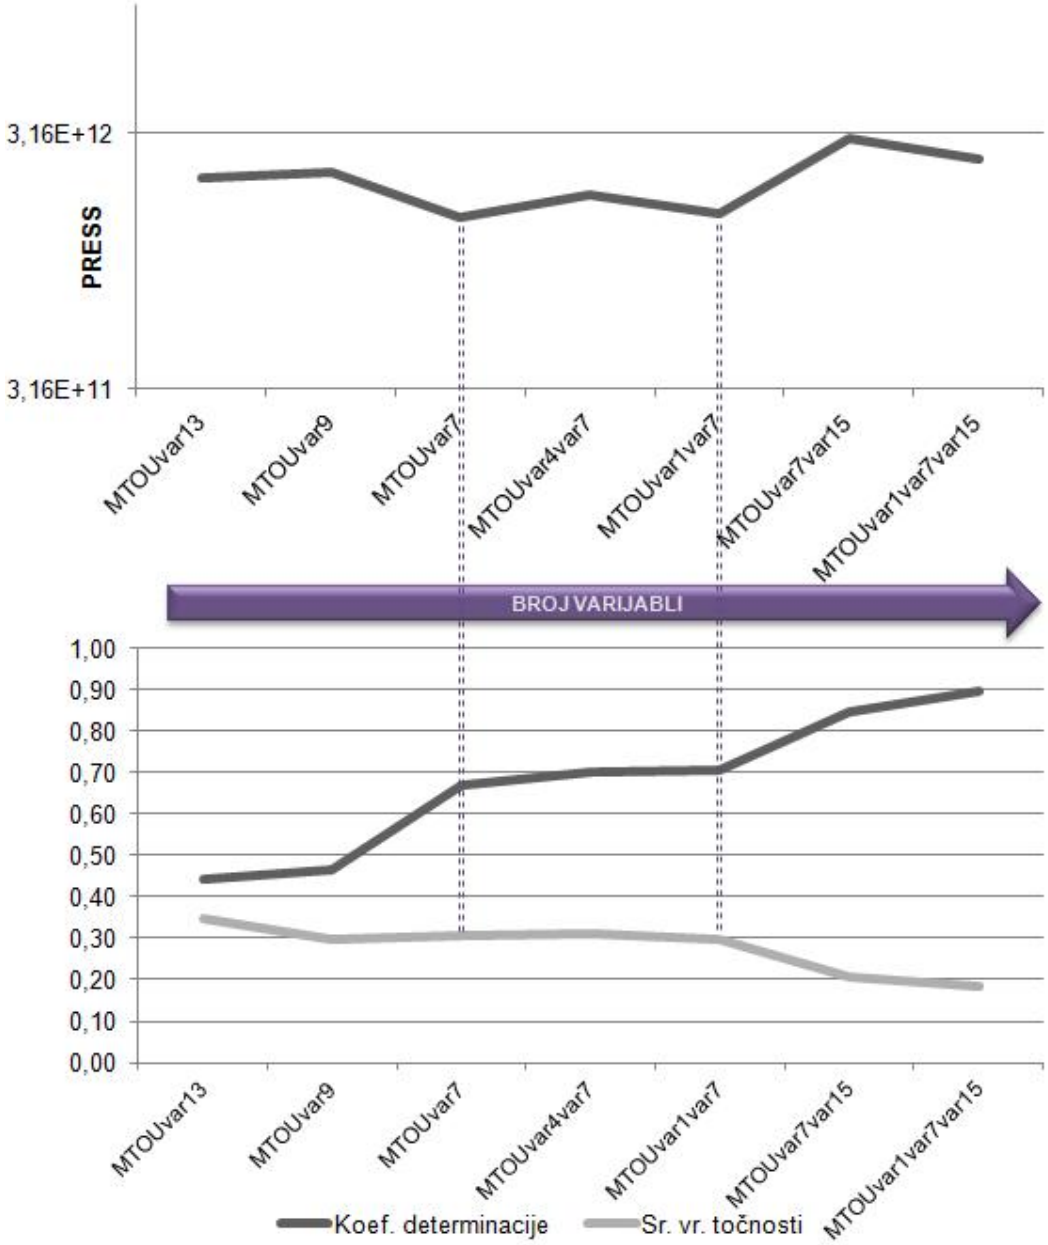

Slika 43 Vrijednosti koeficijenta determinacije i pripadajuće vrijednosti sume kvadrata pogreške predviđanja modela procjene troškova održavanja i uporabe

Vrijednosti prikazane u tablici 19 mogu se prikazati grafički da bi se utvrdila vrijednost najmanje vrijednosti sume kvadrata pogreške predviđanja modela i odgovarajućih koeficijenata determinacije, što pomaže pri odabiru područja optimalnih vrijednosti sume kvadrata pogreške predviđanja za definiranje modela. Usporedba tih vrijednosti prikazana je na slici 43. Budući da je cilj modela predviđanje rezultata, tada su modeli s najmanjim vrijednostima korijena srednje vrijednosti kvadratne pogreške kros validacije (PRESS) najmjerodavniji. U ovom slučaju to su sljedeći modeli troškova održavanja i uporabe:

- MTOvar7
- MTOvar4var7
- MTOvar1var7.

5.1 MODELI PROCJENE TROŠKOVA ODRŽAVANJA I UPORABE GRAĐEVINA

Prikazani su modeli procjene troškova održavanja i uporabe građevina dobiveni na osnovi analize u poglavljima 3.4.2 i 3.4.3 te rezultata *stepwise* regresijske analize koji su dani u prilogu 6. Predloženim modelima moguće je procijeniti prosječne godišnje nominalne troškove održavanja i uporabe građevina.

Odabrani modeli procjene troškova održavanja i uporabe za daljnju razradu, s obzirom na najmanje srednje vrijednosti kvadratne pogreške kros validacije (PRESS) i pripadajuće varijable, prikazani su u tablici 33.

Tablica 33 Modeli procjene troškova održavanja i uporabe s pripadajućim varijablama

R^2	R^2_{ADJ}	Varijeble modela	Opis varijable		PRESS	RMSECV
0,6697	0,6147	var7	POV. KOMUNIKACIJA		1487504000000	431205
0,7006	0,5808	var4 var7	BROJ ETAŽA	POV. KOMUNIKACIJA	1803324000000	474779
0,7046	0,5865	var1 var7	STAROST GRAĐEVINE	POV. KOMUNIKACIJA	1534232000000	437926

5.1.1 Model I procjene troškova održavanja i uporabe građevina

Prvi model procjene troškova održavanja i uporabe je model s jednom varijablom, površinom komunikacija. Regresijskom analizom za navedenu varijablu dobiveni su regresijski koeficijent i konstanta prikazani u tablici 34.

Tablica 34 Konstanta i regresijski koeficijenti modela procjene troškova održavanja i uporabe – model 1

Intercept	**KONSTANTA**	379184,00
var 7	**POV. KOMUNIKACIJA**	762,09

Prema navedenim podatcima iz tablice 34 moguće je raspisati prvi model:

$$PGNTOiU = 379184 + 762{,}09 \cdot P_{KOM} \tag{52}$$

gdje su:

- *PGNTOiU,* prosječni godišnji nominalni troškovi održavanja i uporabe
- P_{KOM}, površina komunikacija.

5.1.2 Model II procjene troškova održavanja i uporabe građevina

Drugi model procjene troškova održavanja i uporabe je model s dvije varijable, površinom komunikacija i brojem etaža građevine. Regresijskom analizom za navedene varijable dobiveni su regresijski koeficijenti i konstanta prikazani u tablici 35.

Tablica 35 Konstanta i regresijski koeficijenti modela procjene troškova održavanja i uporabe – model 2

Intercept	**KONSTANTA**	1005069,00
var 4	**BROJ ETAŽA**	-135840,00
var 7	**POV. KOMUNIKACIJA**	676,68

Prema navedenim podatcima iz tablice 35 moguće je raspisati drugi model:

$$PGNTOiU = 1005069 - 135840 \cdot E + 676{,}68 \cdot P_{KOM} \tag{53}$$

gdje su:

- *PGNTOiU,* prosječni godišnji nominalni troškovi održavanja i uporabe
- *E,* broj etaža građevine
- P_{KOM}, površina komunikacija.

5.1.3 Model III procjene troškova održavanja i uporabe građevina

Treći model procjene troškova održavanja i uporabe također je model s dvije varijable, površinom komunikacija i starosti građevine na kraju vremenskog razdoblja za koji se radi procjena troškova održavanja i uporabe. Regresijskom analizom za navedene varijable dobiveni su regresijski koeficijenti i konstanta prikazani u tablici 36.

Tablica 36 Konstanta i regresijski koeficijenti modela procjene troškova održavanja i uporabe – model 3

Intercept	**KONSTANTA**	441527,00
var 1	**STAROST GRAĐEVINE**	-1508,05
var 7	**POV. KOMUNIKACIJA**	889,54

Prema navedenim podatcima iz tablice 36 moguće je raspisati drugi model:

$$PGNTOiU = 441527 - 1508{,}05 \cdot S + 889{,}54 \cdot P_{KOM} \tag{54}$$

gdje su:

- *PGNTOiU,* prosječni godišnji nominalni troškovi održavanja i uporabe
- *S,* starost građevine u trenutku procjene troškova
- P_{KOM}, površina komunikacija.

5.3 VALIDACIJA MODELA PROCJENE TROŠKOVA ODRŽAVANJA I UPORABE GRAĐEVINA NA TESTNOM UZORKU

Radi utvrđivanja primjenjivosti modela za predviđanje troškova održavanja i uporabe, dobiveni modeli primijenjeni su na građevinu koja nije sudjelovala u definiranju regresijskih koeficijenata. Za validaciju modela procjene troškova uporabe postoji jedan testni uzorak, fakultetska građevina Sveučilišta u Rijeci (F20).

Analogno validaciji modela procjene troškova uporabe i ovdje je potrebno voditi računa o tome da vrijednosti neovisnih varijabli koje se koriste za predviđanje nisu izvan granica neovisnih varijabli koje su se koristile za utvrđivanje regresijskih koeficijenata. Prvi korak koji se provodi prije uporabe modela je provjera vrijednosti neovisnih varijabli testnog uzorka u odnosu na vrijednosti neovisnih varijabli koje su se koristile za utvrđivanje regresijskih koeficijenata.

Neovisne varijable koje su potrebne u predložena tri modela su sljedeće:

- površina komunikacija
- broj etaža građevine
- starost građevine na kraju vremenskog razdoblja za koji se radi procjena troškova održavanja i uporabe.

Na slici 44 prikazane su maksimalne i minimalne vrijednosti navedenih varijabli, kao i vrijednosti varijabli građevine koja je poslužila kao testni uzorak, građevina označena kao F20. Vidljivo je kako su vrijednosti varijable testne građevine u dopuštenim preporučenim granicama vrijednosti varijabli.

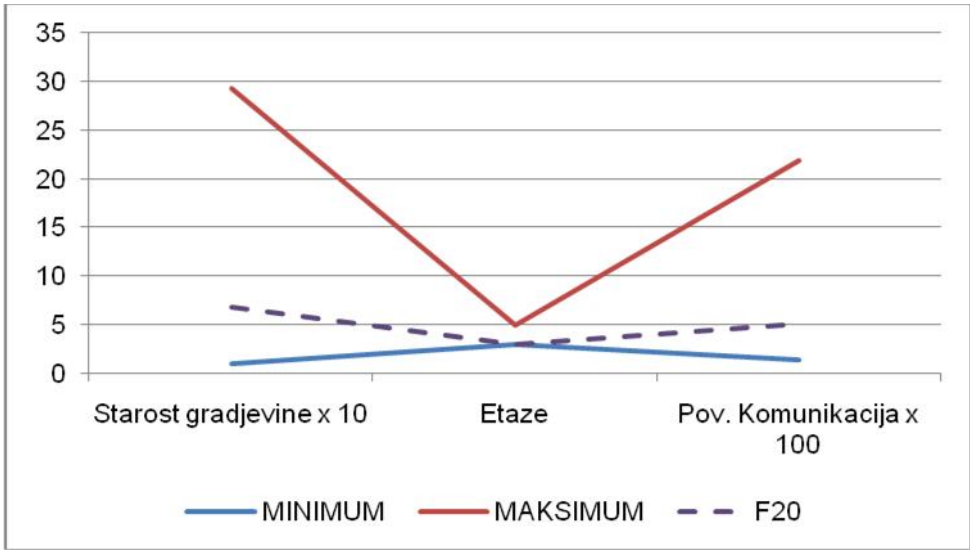

Slika 44 Maksimalne i minimalne vrijednosti neovisnih varijabli rabljenih za utvrđivanje vrijednosti regresijskih koeficijenata i vrijednosti istih varijabli testnog uzorka

Vrijednosti neovisnih varijabli građevine F20 u granicama su preporučenih vrijednosti. Pri modeliranju usvojena je pretpostavka kako su površine funkcionalnih prostora svake od građevine konstantne, odnosno ne mijenjaju se tijekom vremena.

5.3.1 Validacija modela održavanja i uporabe građevina

Razlika između stvarnih i predviđenih vrijednosti troškova održavanja i uporabe izračunata je prema izrazu za točnost modela 35 i predstavlja odstupanje procijenjenih od stvarnih vrijednosti troškova uporabe izraženih u postotcima. U tablici 37 prikazani su rezultati validacije modela procjene troškova održavanja i uporabe na građevini F20. Prikazane su vrijednosti točnosti modela izračunate prema izrazu 35.

Tablica 37 Rezultati validacije modela procjene troškova održavanja i uporabe na testnom uzorku

Model	Stvarna vrijednost	Procijenjena vrijednost	Točnost modela
1	762.933,14 kn	766.326,71 kn	0,44%
2	762.933,14 kn	941304,44	23,38%
3	762.933,14 kn	790866,30	3,66%

5.3.2 Izbor modela procjene troškova održavanja i uporabe

S obzirom na mali testni uzorak, odnosno samo jednu građevinu, niti za jedan od navedenih modela procjene troškova održavanja i uporabe ne može se sa sigurnošću utvrditi primjenjivost na građevine izvan Sveučilišta u Osijeku, unatoč dobivenim malim odstupanjima prikazanima u tablici 35. Kako bi se ovo moglo potvrditi s većom sigurnošću, potrebno je povećati testni uzorak kako bi se utvrdilo javljaju li se iste ili slične vrijednosti odstupanja i na ostalim građevinama izvan Sveučilišta u Osijeku.

Na temelju provedenih analiza, kao mjerodavni model procjene troškova održavanja i uporabe usvaja se model broj 1. Nekoliko je razloga za ovu odluku:

- male vrijednosti standardne devijacije točnosti modela 1 i ukupne točnosti modela 1 što je prikazano na slici 45, gdje se vidi kako su navedene vrijednosti najmanje u odnosu na vrijednosti modela 2 i 3, a poželjno je da su ove vrijednosti što bliže nuli;
- prihvatljive vrijednosti koeficijenta determinacije modela 1, slika 43;
- mala vrijednost korijena srednje vrijednosti kvadratne pogreške kros validacije (PRESS) modela, slika 43;
- varijabla modela 1 značajna je sa stajališta struke (površine komunikacija) pri određivanju troškova održavanja i uporabe;
- varijabla modela 1 veća je od nule za sve građevine koje su sudjelovale u istraživanju, odnosno sve građevine imaju ovu funkcionalnu površinu.

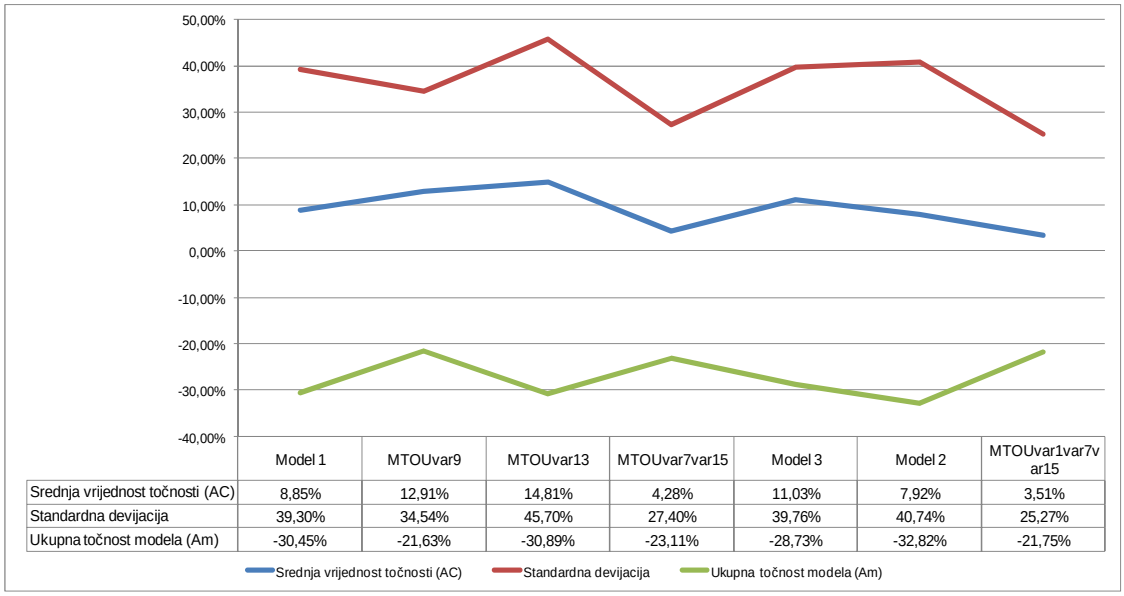

	Model 1	MTOUvar9	MTOUvar13	MTOUvar7var15	Model 3	Model 2	MTOUvar1var7var15
Srednja vrijednost točnosti (AC)	8,85%	12,91%	14,81%	4,28%	11,03%	7,92%	3,51%
Standardna devijacija	39,30%	34,54%	45,70%	27,40%	39,76%	40,74%	25,27%
Ukupna točnost modela (Am)	-30,45%	-21,63%	-30,89%	-23,11%	-28,73%	-32,82%	-21,75%

Slika 45 Srednje vrijednosti točnosti modela, ukupne točnosti modela i standardne devijacije modela procjene troškova održavanja i uporabe za građevine koje su sudjelovale u istraživanju i građevine za validaciju

Grafički prikaz rezultata validacije odabranog modela održavanja i uporabe na građevinama na osnovi čijih podataka su formirani regresijski koeficijenti, prikazani su na slici 46. Točnost modela za svaku od građevina izračunata je prema izrazu 35.

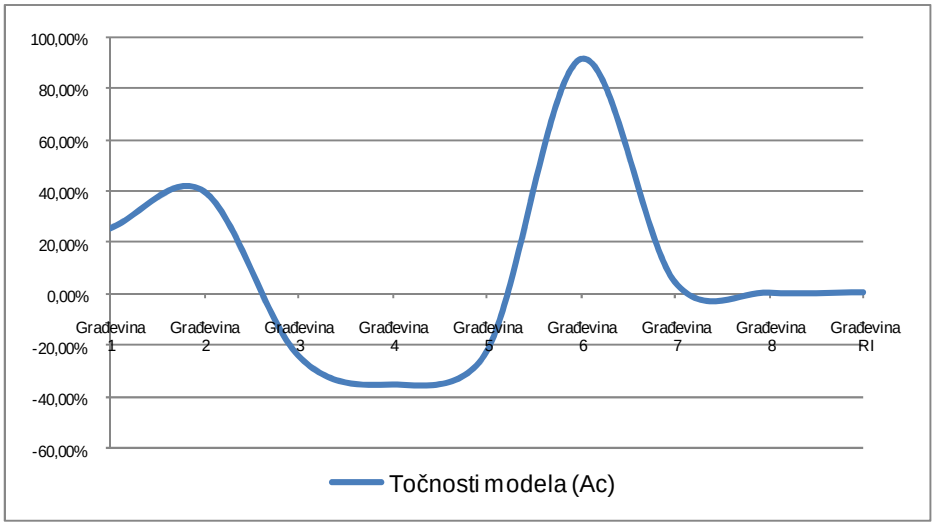

Slika 46 Točnost modela na građevinama uzorka i građevini za validaciju

Na slici 46 vidljivo je kako se najveće odstupanje pri predviđanju troškova održavanja i uporabe javlja kod građevina 2 i 6 te iznosi 39,93%, odnosno 91,73% te je zbog toga potrebno provesti analizu ovih odstupanja koja su značajna u odnosu na odstupanja ostalih građevina.

Isključi li se građevina 6 iz statističke analize, koeficijent korelacije površine komunikacija i ukupnih troškova održavanja i uporabe raste s 0,82 na 0,88, a učini li se isto s građevinom 2, tada koeficijent korelacije iznosi 0,91.

Na slici 47 prikazane su grafički vrijednosti površine komunikacija građevina uzorka, ukupni troškovi održavanja i uporabe (podijeljeni s tisuću) i prosječna vrijednost površina komunikacija uzorka kao pravac. Na slici je vidljivo kako građevine (građevina 2 i 6) čije procijenjene vrijednosti troškova održavanja i uporabe najviše odstupaju od stvarnih vrijednosti troškova imaju površine komunikacija koje su najbliže srednjoj vrijednosti površina komunikacija uzorka. Ova činjenica upućuje na to kako bi trebalo izbjegavati procjenu troškova održavanja i uporabe navedenim modelom kod onih građevina kod kojih je vrijednost površine komunikacija blizu srednje vrijednosti površine komunikacija uzorka rabljenog za definiranje regresijskih koeficijenata, a koja iznosi 966,28 m^2. Međutim, navedeno bi trebalo potvrditi ili opovrgnuti na većem broju analiziranih uzoraka.

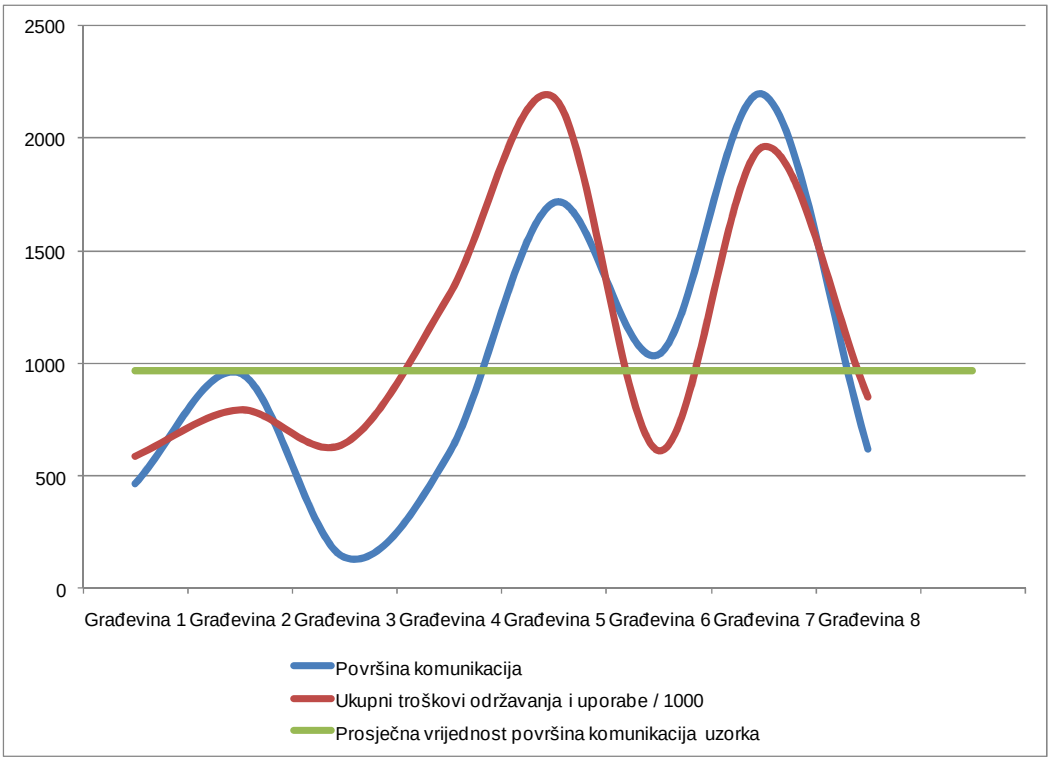

Slika 47 Usporedba procijenjenih troškova održavanja i uporabe građevina i neovisne varijable modela (površine komunikacija)

Detaljnijom analizom površina komunikacija navedenih građevina utvrđeno je kako njihove površinu odstupaju za 0,96% i 7,54% od prosječne vrijednosti površine komunikacija, dok se odstupanja ostalih građevina kreću u intervalu od približno 35% do 126%. Unutar tih granica nema većeg utjecaja na procjenu troškova održavanja i uporabe niti se uočava nekakav trend, a što se i vidi na slici 48.

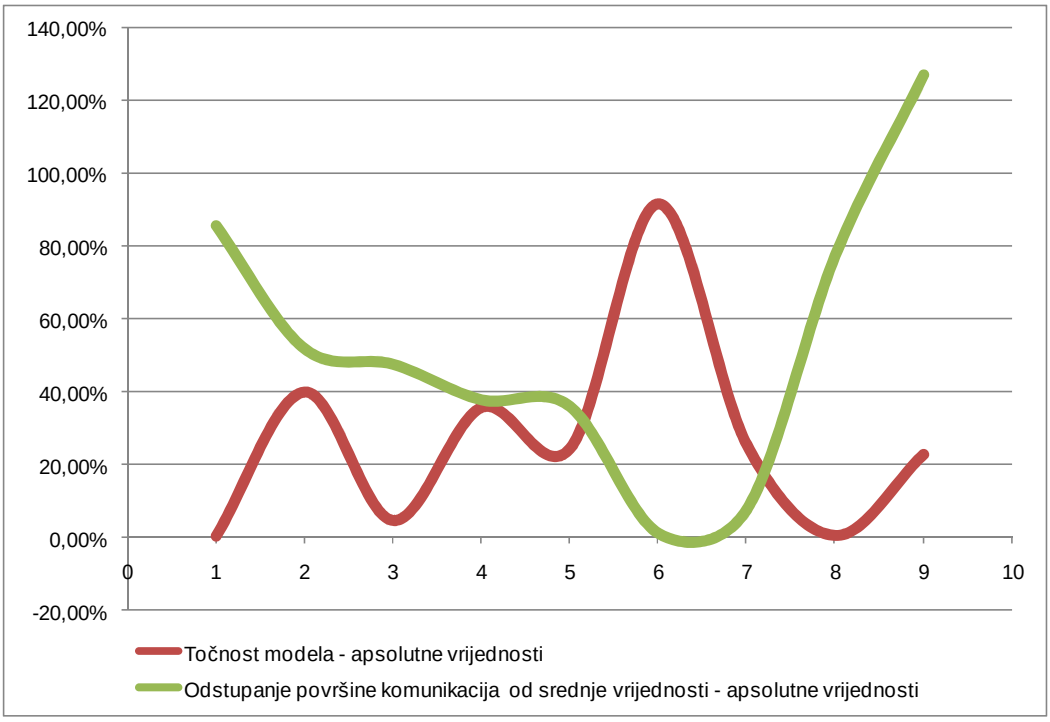

Slika 48 Odstupanja površina komunikacija od srednje vrijednosti površine komunikacija uzorka i točnosti modela na tim građevinama

Iz navedenog se može preporučiti primjena odabranog modela održavanja i uporabe građevina samo na onim građevinama kod kojih vrijednosti površina komunikacija značajnije odstupaju od srednje vrijednosti površine komunikacija uzorka građevina od kojih su definirani regresijski koeficijenti modela, a ta površina iznosi 966,28 m^2. U slučaju kada su vrijednosti površine komunikacije gotovo identične prosječnoj vrijednosti površine komunikacije uzorka, odstupanja procijenjenih vrijednosti troškova održavanja i uporabe značajno odstupaju od stvarnih.

Navedeno objašnjenje trebalo bi potvrditi validacijom modela na većem uzorku, a što u ovom radu nije bilo moguće radi nedostupnosti podataka.

5.4 MODEL PROCJENE DISKONTIRANIH TROŠKOVA ODRŽAVANJA I UPORABE GRAĐEVINA

Procijenjeni troškovi održavanja i uporabe građevina računaju se prema izrazu:

$$PGNTOiU = 379184 + 762{,}09 \cdot P_{KOM} \tag{55}$$

gdje su:

- *PGNTOiU,* prosječni godišnji nominalni troškovi održavanja i uporabe
- P_{KOM}, površina komunikacija.

Dobiveni troškovi predstavljaju prosječnu godišnju vrijednost troškova održavanja i uporabe građevina tijekom vremenskog razdoblja od *N* godina, odnosno nominalne troškove. Ovaj izraz može se raspisati kao kombinacija izraza 43 i 55, što omogućuje izračun procijenjene neto sadašnje vrijednosti troškova održavanja i uporabe građevina za N godina prema izrazu:

$$PGNTOiU_{NPV} = PGNTOiU \sum_{n=1}^{N} \frac{1}{(1+r)^n} \tag{56}$$

gdje su:

- *PGNTOiU,* prosječni godišnji nominalni troškovi održavanja i uporabe
- *r,* nominalna diskontna stopa
- *n,* godina u kojoj se javljaju troškovi
- *N,* broj vremenskih razdoblja, godina, za koje se računaju diskontirani troškovi uporabe građevina.

U tablici 38 prikazane su srednje vrijednosti točnosti modela izračunate prema izrazu 36. Prikazane su i stvarne i procijenjene vrijednosti troškova održavanja i uporabe na osnovi kojih su srednje vrijednosti točnosti modela i računate. Prikazane vrijednosti troškova odnose se na prosječne vrijednosti troškova održavanja i uporabe građevina tijekom referentnog razdoblja.

Građevina 1 (F4) i građevina 3 (F10) imaju slične srednje vrijednosti točnosti modela (A_C), ali suprotnog predznaka, odnosno na građevini 3 (F10) vrijednost troškova održavanja i uporabe dobivena modelom manja je od stvarne vrijednosti troškova održavanja i uporabe, dok za građevinu 1 (F4) vrijedi suprotno, vrijednost troškova održavanja i uporabe dobivena modelom veća je od stvarne vrijednosti troškova održavanja i uporabe. Podatci za obje građevine dani su za referentna razdoblja od 8 i 12 godina.

Za obje građevine u nastavku će se prikazati rezultati primjene modela procjene diskontiranih troškova održavanja i uporabe građevina prema izrazu 56.

Tablica 38 Srednje vrijednosti točnosti modela održavanja i uporabe građevina

Šifra građevine	Građevina	Ref. razdoblje	Stvarna vrijednost troškova održavanja i uporabe*	Vrijednost troškova održavanje i uporabe dobivena modelom*	Srednja vrijednost točnosti modela (A_C)
F4	Građevina 1	8	586.013 kn	735.081 kn	25,44%
F9	Građevina 2	10	792.204 kn	1.108.506 kn	39,93%
F10	Građevina 3	12	642.078 kn	485.877 kn	-24,33%
F14	Građevina 4	4	1.302.523 kn	837.963 kn	-35,67%
F18	Građevina 5	8	2.180.683 kn	1.683.885 kn	-22,78%
F8	Građevina 6	12	610.758 kn	1.170.997 kn	91,73%
F16	Građevina 7	10	1.961.044 kn	2.050.451 kn	4,56%
F6	Građevina 8	6	849.138 kn	851.681 kn	0,30%
F20	Građevina RI	10	762.933 kn	766.327 kn	0,44%

** Prikazane vrijednosti troškova održavanja i uporabe građevina odnose se na prosječnu vrijednost troškova tijekom referentnog razdoblja*

Grafički prikaz vrijednosti kumulativnih troškova održavanja i uporabe (stvarnih vrijednosti i vrijednosti dobivenih modelom) za građevinu 1 je dan na slici 49 za razdoblje od 2001. do 2008., a za građevinu 3 na slici 50 za razdoblje od 1997. do 2008. godine. Za prikazane stvarne kumulativne vrijednosti troškova održavanja i uporabe građevina izračunate su njihove neto sadašnje vrijednosti prema izrazu 43 i prikazane kao kumulativne vrijednosti za obje građevine i pripadajuća referentna razdoblja.

Na slikama 49 i 50 grafički je prikazana usporedba stvarnih kumulativnih i kumulativnih vrijednosti troškova održavanja i uporabe dobivenih modelom građevina 1 i 3. Diskontna stopa kojim su troškovi diskontirani iznosila je 5,10% (važeća diskontna stopa u trenutku proračuna, ožujak 2011.).

Na slici 49 je vidljivo kako je vrijednost kumulativnih troškova održavanja i uporabe dobivena modelom veća od vrijednosti stvarnih kumulativnih troškova održavanja i uporabe građevine 1 i to za 25,44%, dok razlika istih troškova izraženih preko neto sadašnjih vrijednosti iznosi 24%.

Na slici 50 prikazano je kako je vrijednost kumulativnih troškova održavanja i uporabe dobivena modelom manja od stvarne vrijednosti kumulativnih troškova održavanja i uporabe građevine 3 i to za 24,33%, dok razlika istih troškova izraženih preko neto sadašnje vrijednosti iznosi 24,10%.

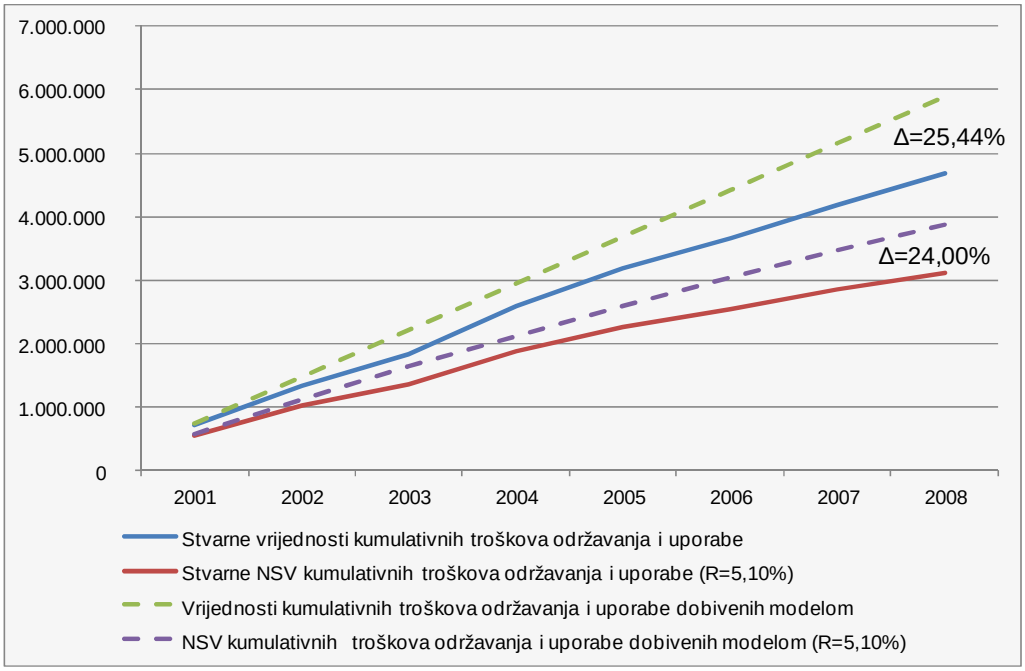

Slika 49 Grafički prikaz usporedbe kumulativnih troškova održavanja i uporabe dobivenih modelom i stvarnih kumulativnih vrijednosti troškova održavanja i uporabe građevine 1 (F4)

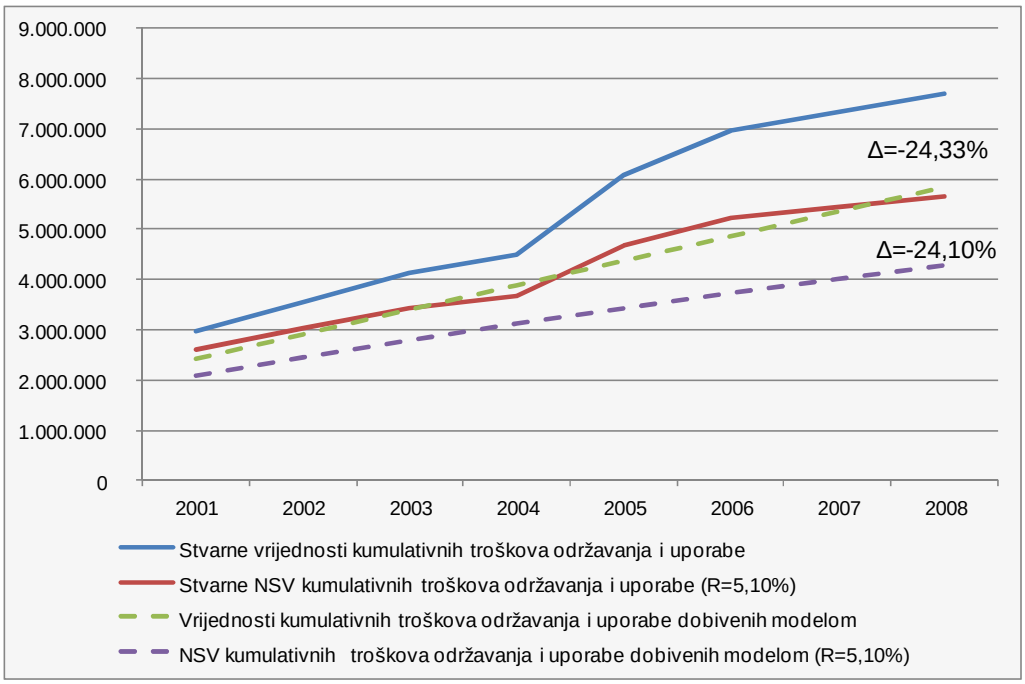

Slika 50 Grafički prikaz usporedbe kumulativnih troškova održavanja i uporabe dobivenih modelom i stvarnih kumulativnih vrijednosti troškova održavanja i uporabe građevine 3 (F10)

Kako bi se utvrdio utjecaj diskontne stope na model procjene diskontiranih troškova održavanja i uporabe građevina, u nastavku će se varirati diskontna stopa od 5,10% u 2 koraka i to povećanjem i smanjenjem navedene stope u iznosu od 25%. Utjecaj promjene diskontne stope provjerit će se za sljedeće stope: 3,83%, 5,10% i 6,38%.

Rezultati utjecaja promjene diskontne stope na razliku kumulativnih troškova održavanja i uporabe dobivenih modelom i stvarnih kumulativnih vrijednosti troškova održavanja i uporabe prikazani su grafički na slikama 51 i 52 za građevine 1 i 3.

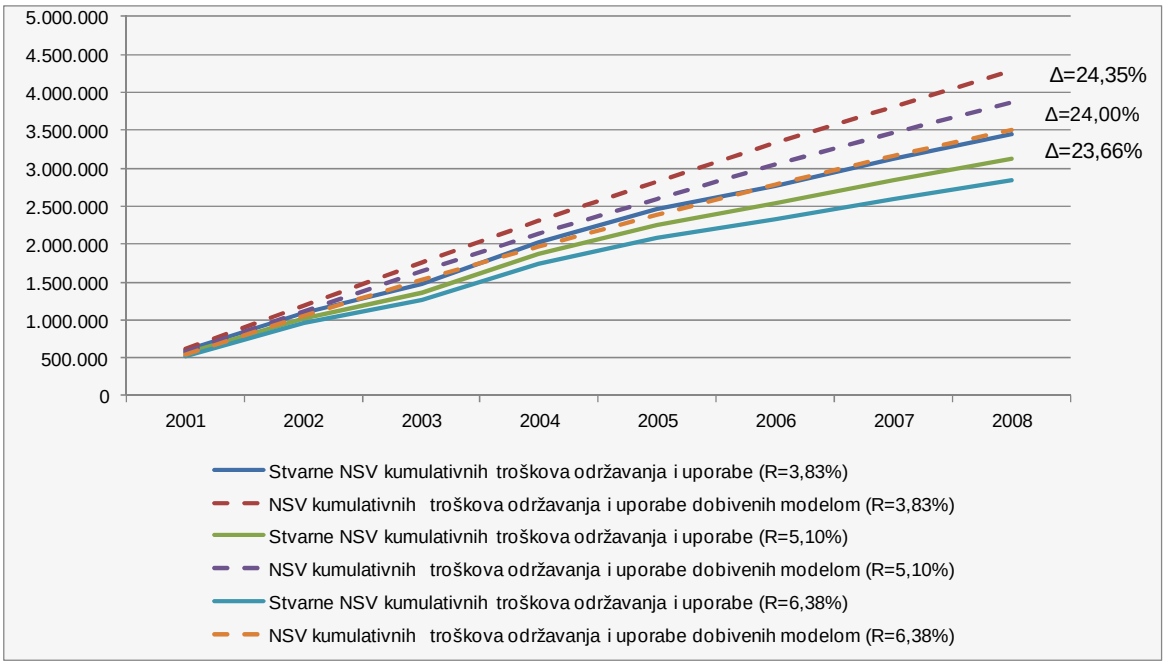

Slika 51 Promjena vrijednosti troškova održavanja i uporabe ovisno diskontnoj stopi za građevinu 1

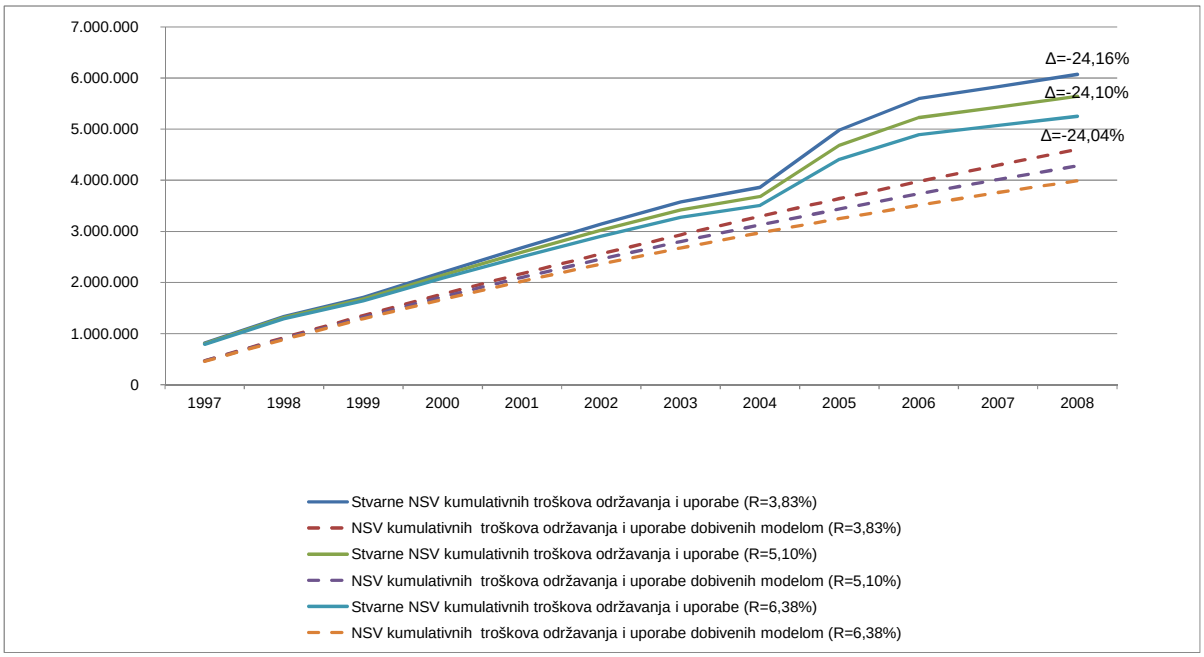

Slika 52 Promjena vrijednosti troškova održavanja i uporabe ovisno diskontnoj stopi za građevinu 3

Iz prikazanoga je moguće zaključiti sljedeće: neovisno o tome jesu li vrijednosti troškova održavanja i uporabe dobivene modelom veće ili manje od stvarnih vrijednosti troškova

održavanja i uporabe, diskontiranjem istih većim diskontnim stopama smanjuje se razlika između navedenih troškova, odnosno pogreška predviđanja. Porastom diskontne stope koja se rabi kako bi se utvrdila diskontirana vrijednost troškova održavanja i uporabe dobivenih modelom, smanjuje se razlika u pogrešci predviđanja troškova održavanja i uporabe.

5.5 PREDNOSTI I OGRANIČENJA MODELA PROCJENE TROŠKOVA ODRŽAVANJA I UPORABE GRAĐEVINA

5.5.1 Prednosti modela procjene troškova održavanja i uporabe građevina

Prva i najveća prednost primjene predloženog modela procjene troškova održavanja i uporabe građevina je jednostavnost primjene, budući da je za procjenu troškova potrebna samo jedna varijabla. Ta varijabla je površina komunikacija u koju su uključene površine svih hodnika, ulaznih pretprostora i holova.

Ovo je podatak do kojeg je moguće doći već u ranoj fazi projektiranja i razrade projekta pa samim time već u toj fazi model omogućuje procjenu troškova i razmatranje različitih projektnih rješenja građevina. Varijacijama vrijednosti varijable moguće je vrjednovanje različitih projektnih rješenja sa stajališta ukupnih troškova održavanja građevina.

Nadalje, varijabla površine komunikacija je varijabla koju mora sadržavati svako od projektnih rješenja bilo koje građevine koja je namijenjena visokom školstvu. Ova činjenica važna je zato što je model zbog te činjenice primjenjiv na sve građevine tog tipa, što omogućuje izravnu usporedbu ovih analiziranih troškova.

Srednja vrijednost točnosti modela računata prema izrazu 36 iznosi 8,85%. Validacija modela na građevini izvan Sveučilišta u Osijeku pokazala je kako je model primjenjiv i na građevine izvan Sveučilišta u Osijeku gdje je zabilježeno odstupanje koje iznosi 0,44%. Ukupna točnost modela izračunata prema izrazu 37 iznosi -30,45%.

Kao rezultat procjene troškova održavanja i uporabe, model daje vrijednosti prosječnih godišnjih nominalnih troškova održavanja i uporabe koji su jednaki za svaku godinu tijekom promatranog vremenskog razdoblja.

Modificiranim modelom procjene troškova održavanja i uporabe moguće je također odrediti i procijenjene neto sadašnje vrijednosti troškova održavanja i uporabe građevina, odnosno diskontirane troškove održavanja i uporabe. To omogućuje primjenu prikladne diskontne stope u određenom trenutku kako bi se uvažila vremenska vrijednost troškova održavanja i uporabe.

5.5.2 Ograničenja modela procjene troškova održavanja i uporabe građevina

Prvo i osnovno ograničenje modela procjene troškova održavanja i uporabe građevina je njegova primjenjivost isključivo na fakultetske građevine Sveučilišta u Osijeku. Kako su prikupljeni i obrađeni podatci o troškovima i karakteristikama fakultetskih građevina Sveučilišta u Osijeku, preporučuje se primjena samo na te građevine. Validacija modela

izvršena je na građevini izvan Sveučilišta u Osijeku, ali kako je riječ samo o jednoj građevini, rezultati nisu reprezentativni iako odstupanje nije bilo veliko (0,44%). Da bi se utvrdila primjenjivost na građevine izvan Osijeka, potrebno je povećati uzorak za validaciju.

Drugo ograničenje o kojemu je potrebno voditi računa je da vrijednost neovisne varijable koja se koristi za predviđanje nije izvan granica neovisne varijable koja se koristila za utvrđivanje regresijskih koeficijenata, inače je moguće dobiti potpuno netočne rezultate [98, 102]. Prvi korak koji je potrebno provesti prije uporabe modela je provjera vrijednosti neovisne varijable građevine u odnosu na vrijednost neovisne varijable koja se koristila za utvrđivanja regresijskih koeficijenata.

Preporučena vrijednost površina komunikacija na analiziranim građevinama kreće se u rasponu od 140 m^2 do 2193 m^2. Uporaba modela, ako vrijednosti varijable površine komunikacija građevine nisu unutar ovog raspona, nije preporučljiva. Također, nije preporučljivo primjenjivati model na onim građevinama čija je površina komunikacija vrlo slična prosječnoj površini komunikacija (razlika manja od 1%). Veća odstupanja procijenjenih troškova dobivenih modelom od stvarnih troškova pojavila su se samo kod dvije građevine čije su vrijednosti površina komunikacija vrlo bliske prosječnoj površini komunikacija. Međutim, kako je i ranije navedeno, ovu pojavu potrebno je potvrditi ili odbaciti provjerom modela na većem broju uzoraka.

Treće ograničenje modela je broj godina za koji se procjenjuju troškovi održavanja i uporabe građevina, a to je najviše za 12 godina, jer je upravo to najduže vremensko razdoblje za koje su prikupljeni podatci o troškovima održavanja i uporabe građevina. Stoga se i procijenjeni troškovi održavanja i uporabe mogu usporediti sa stvarnima samo za to vremensko razdoblje. Kako bi se utvrdilo vremensko razdoblje za koje se mogu procijeniti troškovi održavanja i uporabe, potrebno je nastaviti s prikupljanjem i obradom podataka i usporedbom s procijenjenim troškovima.

Četvrto ograničenje modela je potreba provedbe analize osjetljivosti procijenjenih neto sadašnjih vrijednosti troškova održavanja i uporabe dobivenih uporabom izraza 56 kako bi se utvrdio utjecaj inflacije, promjena diskontne stope i deprecijacije na procjenu neto sadašnjih vrijednosti troškova održavanja i uporabe.

6 SAŽETI PRIKAZ REZULTATA, ZAKLJUČAK I SMJERNICE ZA DALJNJA ISTRAŽIVANJA

6.1 SAŽETI PRIKAZ REZULTATA ISTRAŽIVANJA

6.1.1 Model procjene troškova uporabe građevina

Usvojeni model procjene troškova uporabe je model s tri varijable, površinom sanitarnih prostora, površinom ureda i prosječnim brojem djelatnika tijekom razdoblja za koje se procjenjuju troškovi. Izraz prema kojemu se računaju procijenjeni godišnji nominalni troškovi uporabe glasi:

$$PGNTU = 31304{,}00 - 230{,}48 \cdot P_S - 208{,}51 \cdot P_U + 3047{,}94 \cdot D_{PR} \tag{57}$$

gdje su:

- *PGNTU,* prosječni godišnji nominalni troškovi uporabe
- P_S, površina sanitarnih prostora
- P_U, površina uredskih prostorija
- D_{PR}, prosječni broj djelatnika tijekom promatranog vremenskog razdoblja.

Kao rezultat procjene troškova uporabe, model daje vrijednosti prosječnih godišnjih nominalnih troškova uporabe koji su jednaki za svaku godinu tijekom promatranog vremenskog razdoblja.

Modificiranim modelom procjene troškova uporabe moguće je također odrediti i procijenjene neto sadašnje vrijednosti troškova uporabe građevina, odnosno diskontirane troškove uporabe. Ovo omogućuje primjenu prikladne diskontne stope u određenom trenutku kako bi se uvažila vremenska vrijednost troškova uporabe.

Izraz 57 može se raspisati tako da omogući izračun procijenjene neto sadašnje vrijednosti troškova uporabe građevina za N godina prema izrazu:

$$PGNTU_{NPV} = PGNTU \sum_{n=1}^{N} \frac{1}{(1+r)^n} \tag{58}$$

gdje su:

- *PGNTU,* prosječni godišnji nominalni troškovi uporabe
- *r,* nominalna diskontna stopa
- *n,* godina u kojoj se javljaju troškovi
- *N,* broj vremenskih razdoblja, godina, za koje se računaju diskontirani troškovi uporabe građevina.

Prednosti modela procjene troškova uporabe građevina su sljedeći:

- jednostavnost primjene, jer je za procjenu troškova potreban mali broj varijabli;
- varijable potrebne za procjenu troškova moguće je utvrditi jednostavno i brzo;

- model omogućuje procjenu troškova i razmatranje različitih projektnih rješenja građevina već u ranoj fazi projektiranja i razrade projekta;
- varijacijama vrijednosti pojedinih varijabli modela moguće je vrjednovanje različitih projektnih rješenja sa stajališta uporabnih troškova građevina;
- varijable modela su varijable koje mora sadržavati svako od projektnih rješenja bilo koje građevine koja je namijenjena visokom školstvu; ovo je važno jer je model zbog te činjenice primjenjiv na sve građevine tog tipa, što omogućuje izravnu usporedbu troškova;
- srednja vrijednost točnosti modela računata prema izrazu 36 za građevine koje su sudjelovale u istraživanju i građevina za validaciju iznosi 1,91%. Validacija modela na građevinama izvan Sveučilišta u Osijeku pokazala je kako je model jednako primjenjiv i na građevine izvan Sveučilišta u Osijeku gdje su zabilježena najveća odstupanja u iznosu do 9,57%. Ukupna točnost modela izračunata prema izrazu 37 iznosi -3,96%.
- validacija modela na građevinama izvan Sveučilišta u Osijeku pokazala je kako je model jednako primjenjiv i na građevine izvan Sveučilišta u Osijeku gdje su zabilježena najveća odstupanja u iznosu do 9,57%.

Ograničenja modela procjene troškova uporabe građevina su sljedeća:

- primjenjivost isključivo na fakultetske građevine Sveučilišta u Osijeku;
- validacija modela izvršena je na građevini izvan Sveučilišta u Osijeku, ali kako je riječ samo o jednoj građevini, rezultati nisu reprezentativni, iako odstupanje nije bilo veliko (8,22%);
- drugo ograničenje o kojemu je potrebno voditi računa definira da vrijednosti neovisnih varijabli koje se koriste za predviđanje nisu izvan granica neovisnih varijabli koje su se koristile za utvrđivanje regresijskih koeficijenata;
- ograničen je i broj godina za koje se procjenjuju troškovi uporabe građevina, a to je najviše za 12 godina, budući da je to najduže vremensko razdoblje za koje su prikupljeni podatci o troškovima uporabe građevina;
- osjetljivost modela na promjenu broja djelatnika, što je utvrđeno analizom osjetljivosti koja je pokazala kako za jednaki postotak promjene broja djelatnika dolazi do gotovo jednake promjene procijenjenih troškova uporabe;
- potreba provedbe analize osjetljivosti procijenjenih neto sadašnjih vrijednosti troškova uporabe radi utvrđivanja utjecaja inflacije, promjena diskontne stope i deprecijacije na procjenu vrijednosti troškova.

6.1.2 Model procjene troškova održavanja i uporabe građevina

Usvojeni model procjene troškova održavanja i uporabe je model s jednom varijablom, površinom komunikacija. Izraz prema kojemu se računaju procijenjeni godišnji nominalni troškovi održavanja i uporabe glasi:

$$PGNTOiU = 379184 + 762{,}09 \cdot P_{KOM} \tag{59}$$

gdje su:

- *PGNTOiU,* prosječni godišnji nominalni troškovi održavanja i uporabe
- P_{KOM}, površina komunikacija.

Kao rezultat procjene troškova održavanja i uporabe, model daje vrijednosti prosječnih godišnjih nominalnih troškova održavanja i uporabe koji su jednaki za svaku godinu tijekom promatranog vremenskog razdoblja.

S obzirom na mali testni uzorak, odnosno samo jednu građevinu za niti jedan od modela procjene troškova i uporabe koji su uzeti na razmatranje, ne može se sa sigurnošću utvrditi primjenjivost na građevine izvan Sveučilišta u Osijeku, unatoč dobivenim malim odstupanjima. Kako bi se uspješno potvrdila primjenjivost modela, potrebno je povećati testni uzorak kako bi se utvrdilo javljaju li se iste ili slične vrijednosti odstupanja i na ostalim građevinama izvan Sveučilišta u Osijeku.

Modificiranim modelom procjene troškova održavanja i uporabe moguće je također odrediti i procijenjene neto sadašnje vrijednosti troškova održavanja i uporabe građevina, odnosno diskontirane troškove održavanja i uporabe. To omogućuje primjenu prikladne diskontne stope u određenom trenutku kako bi se uvažila vremenska vrijednost troškova održavanja i uporabe.

Primjenom izraza 59 računa se prosječna godišnja vrijednost troškova održavanja i uporabe građevina tijekom vremenskog razdoblja od *N* godina, odnosno nominalni troškovi. Navedeni izraz može se raspisati tako da se omogući izračun procijenjene neto sadašnje vrijednosti troškova održavanja i uporabe građevina za N godina prema izrazu:

$$\mathrm{PGNTOiU_{NPV}} = \mathrm{PTOiU}\sum_{n=1}^{N}\frac{1}{(1+r)^{n}} \tag{60}$$

gdje su:

- *PGNTOiU,* prosječni godišnji nominalni troškovi održavanja i uporabe
- *r,* nominalna diskontna stopa
- *n,* godina u kojoj se javljaju troškovi
- *N,* broj vremenskih razdoblja, godina, za koje se računaju diskontirani troškovi uporabe građevina.

Prednosti modela procjene troškova održavanja i uporabe građevina su sljedeći:

- jednostavnost primjene, budući da je za procjenu troškova potrebna samo jedna varijabla;
- podatak o površini komunikacija dostupan je već u ranoj fazi projektiranja i razrade projekta pa samim time već u toj fazi model omogućuje procjenu troškova i razmatranje različitih projektnih rješenja građevina;
- varijacijama vrijednosti varijable površine komunikacija moguće je vrjednovanje različitih projektnih rješenja sa stajališta ukupnih troškova održavanja građevina;
- varijabla površine komunikacija je varijabla koju mora sadržavati svako od projektnih rješenja bilo koje građevine koja je namijenjena visokom školstvu, stoga je model primjenjiv na sve građevine tog tipa što omogućuje izravnu usporedbu troškova;

- srednja vrijednost točnosti modela računata prema izrazu 36 za građevine koje su sudjelovale u istraživanju i građevina za validaciju iznosi 8,85%. Validacija modela na građevini izvan Sveučilišta u Osijeku pokazala je kako je model primjenjiv i na građevine izvan Sveučilišta u Osijeku gdje je zabilježeno odstupanje koje iznosi 0,44%. Ukupna točnost modela izračunata prema izrazu 37 iznosi -30,45%.

Ograničenja modela procjene troškova održavanja i uporabe građevina su sljedeća:

- primjenjivost isključivo na fakultetske građevine Sveučilišta u Osijeku;
- validacija modela izvršena je na građevini izvan Sveučilišta u Osijeku, ali kako je riječ samo o jednoj građevini, rezultati nisu reprezentativni, iako odstupanje nije bilo veliko (0,44%);
- vrijednost neovisne varijable koja se koristi za predviđanje troškova ne smije biti izvan granica neovisne varijable koja se koristila za utvrđivanje regresijskih koeficijenata, inače je moguće dobiti potpuno netočne rezultate;
- nije preporučljivo primjenjivati model na onim građevinama čija je površina komunikacija vrlo slična prosječnoj površini komunikacija (razlika manja od 1%), ovu pojavu potrebno je potvrditi ili odbaciti provjerom modela na većem uzorku;
- broj godina za koje se procjenjuju troškovi održavanja i uporabe građevina, a to je najviše za 12 godina, jer je upravo to najduže vremensko razdoblje za koje su prikupljeni podatci o troškovima održavanja i uporabe građevina;
- potreba provedbe analize osjetljivosti procijenjenih neto sadašnjih vrijednosti troškova održavanja i uporabe radi utvrđivanja utjecaja inflacije, promjena diskontne stope i deprecijacije na procjenu vrijednosti troškova.

6.2 ZAKLJUČAK I SMJERNICE ZA DALJNJA ISTRAŽIVANJA

6.2.1 Zaključak

Istraživanje o troškovima održavanja i uporabe u radu je provedeno na fakultetskim građevinama Sveučilišta u Osijeku. U Hrvatskoj dosada nije provedeno istraživanje o navedenim troškovima te dosada nisu ni postojali podatci, odnosno baze podataka o troškovima održavanja i uporabe građevina koje bi omogućile statističku obradu radi modeliranja troškova održavanja i uporabe građevina bilo koje namjene. Podatci su prikupljani pomoću upitnika koji su poslani svim sastavnicama Sveučilišta u Osijeku, a traženi su opći podatci o uporabi i karakteristikama građevine i podatci o troškovima održavanja i uporabe građevina prema unaprijed definiranoj strukturi troškova.

U prethodnom poglavlju dan je sažeti prikaz modela procjene troškova uporabe i modela procjene troškova održavanja i uporabe fakultetskih građevina koji su rezultat provedenog istraživanja. Prikazane su potrebne varijable za procjenu tih troškova kao i prednosti i ograničenja uporabe modela za procjenu troškova održavanja i uporabe građevina.

Istraživanjem je utvrđeno sljedeće:

- Moguće je prikupljanje povijesnih podataka o troškovima održavanja i uporabe fakultetskih građevina i stvaranje baze podataka o troškovima održavanja i uporabe prema unaprijed definiranoj strukturi troškova. Odaziv na istraživanje je bio 87% i od prikupljenih podataka definirana je baza podataka o troškovima održavanja i uporabe za vremensko razdoblje od 1997. do 2008. godine.

- Utvrđen je udio troškova uporabe fakultetskih građevina u ukupnim troškovima održavanja i uporabe koji iznosi 42%. Udio troškova održavanja u ukupnim troškovima održavanja i uporabe iznosi 58%.

- Istražena je mogućnost stvaranja matematičkog modela predviđanja troškova održavanja i uporabe javnih građevina visokogradnje za potrebe znanstveno obrazovnih ustanova Sveučilišta u Osijeku uporabom statističkih metoda. Utvrđena je mogućnost primjene višestruke regresijske analize pri izradi modela procjene troškova održavanja i uporabe kao i primjenjivost *Stepwise* metode za određivanje statistički značajnih varijabli modela.

- Definiranjem modela procjene troškova održavanja i uporabe, odnosno varijabli modela, definirane su i karakteristike građevine i način uporabe koji utječu na troškove održavanja i uporabe, a time i informacije potrebne za projektiranje novih građevina sličnog tipa s obzirom na racionalizaciju troškova održavanja i uporabe. Varijable koje utječu na troškove održavanja su površina sanitarnih prostora, površina ureda i prosječni broj djelatnika tijekom razdoblja za koje se procjenjuju troškovi. Varijabla koja utječe na procjenu troškova održavanja i uporabe je površina komunikacija.

- Definirane su prednosti i ograničenja modela procjene troškova održavanja i uporabe i modela procjene troškova uporabe. Osnovna prednost primjene oba modela je jednostavnost primjene i potreban mali broj podataka koji su lako dostupni i prisutni kod svake građevine za procjenu troškova. Osnovno ograničenje oba modela je primjenjivost isključivo na fakultetske građevine Sveučilišta u Osijeku.

- Primjenom modela moguće je planirati proračun troškova održavanja i uporabe fakultetskih građevina na razini građevina Sveučilišta u Osijeku za određena vremenska razdoblja.

- Unatoč relativno dužem razdoblju od pojave metode troškova životnog ciklusa, metoda i dalje nije sastavni dio suvremenog načina projektiranja. Neki od razloga su nedostatak pouzdanih podataka i nedostatak motivacije za uporabu zbog složenosti postojećih metoda. Rezultati provedenog istraživanja mogli bi pomoći pri savladavanju ovih zapreka.

6.2.2 Smjernice za daljnja istraživanja

Ključno područje za daljnja istraživanja je povezivanje teoretskog pristupa proračuna troškova održavanja i uporabe građevina s praktičnim potrebama korisnika građevina, vodeći pritom računa o jednostavnosti proračuna i načinu tumačenja i prikaza rezultata. Daljnja istraživanja trebalo bi usmjeriti na:

- razvoj zajedničkog sustava prikupljanja i obrade podataka o troškovima održavanja i uporabe javnih građevina na razini Republike Hrvatske, a u skladu s europskim propisima i normom ISO 15686 – dio V, budući da bez toga neće biti moguća usporedba troškova održavanja i uporabe građevina kao i drugačijih mogućih projektnih rješenja na razini Hrvatske, ali i Europske Unije;

- otklanjanje otpora javnih institucija pri otkrivanju podataka o troškovima održavanja i uporabe javnih građevina. Podatci o troškovima se uglavnom smatraju komercijalno osjetljivim te je stoga prikupljanje podataka izuzetno otežano. Prikupljanjem i ažuriranjem baza podataka smanjila bi se razina nepouzdanosti i nesigurnosti predviđanja budućih troškova održavanja i uporabe građevina.

- utvrđivanje stupnja nesigurnosti vezanog uz pretpostavke i prikupljene podatke uporabom statističkih metoda;

- ispitivanje vremenskog ograničenja primjenjivosti modela procjene troškova održavanja i uporabe;

- potvrdu dobivenih rezultata provedenog istraživanja i ispitivanje primjenjivosti modela na većem uzorku fakultetskih građevina izvan Sveučilišta u Osijeku kao i na građevinama slične namjene (npr. škole), uz primjenu strukture troškova definirane u ovom radu.

LITERATURA I IZVORI

1. Marenjak, S., M.A. El-Haram, and R.M.W. Horner, *Procjena ukupnih troskova u visokogradnji.* Građevinar, 2002. **54**: p. 393-401.
2. Langdon, D. and M. Consulting, *Life Cycle Costs in Construction, Final Report*. 2003: London, United Kingdom.
3. ISO, *Buildings and constructed assets - Service life planning - Part 5: Life cycle costing*. 2004.
4. Sterner, E., *Life-cycle costing and its use in the Swedish building sector.* Building Research & Information, 2000. **28**.
5. Asiedu, Y. and P. Gu, *Product life cycle cost analysis: state of the art review.* International Journal of Production Research, 1998. **36**(4).
6. Salonen, A., *Relational risk and relationship management in facilities management partnerships*, in *Helsinki University of Technology Construction Economics and Management*. 2006: Helsinki.
7. Biondini, F. and D.M. Frangopol. *Proceedings of the first international symposium on life-cycle civil engineering*. in *The first international symposium on life-cycle civil engineering*. 2008. Varrena, Lake Como, Italy: Taylor & Francis Group, London, UK.
8. Atkin, B. and A. Brooks, *Total Facilities Management*. Vol. 3. 2009, Singapore: Wiley-Blackwell. 305.
9. Marenjak, S., R.M.W. Horner, and M.A. El-Haram, *Privatno ulaganje za objekte visokogradnje u Hrvatskoj.* Građevinar, 2003. **55**: p. 383-389.
10. Emblemsvåg, J., *Life-cycle costing: using activity-based costing and Monte Carlo methods to manage future costs and risk*. 2003, New Jersey, USA: John Wiley & Sons, Inc.
11. Marenjak, S., et al., *Javno privatno partnerstvo i njegova primjena u Hrvatskoj.* Građevinar, 2007. **59**: p. 597-605.
12. Borković, Ž.H., et al., *Pilot projekt povecanja EE u zgradarstvu*. 2003, Energetski institut Hrvoje Požar; MZOPU;.
13. Borković, Ž.H., *EU Direktiva o energetskim karakteristikama zgrada 2002/91/EC*. 2005, Energetski institut Hrvoje Požar.
14. Khamidi, M.F., O.A. Lateef, and A. Idrus, *Building Maintenance: A path towards sustainability.* Malaysian Construction Research Journal, 2010. **7**.
15. Čulo, K. and H. Krstić, *Cost benefit analysis of energy efficient family houses*, in *Second International Conference on Harminisation Between Architecture and Nature, Eco-Architecture 2008*. 2008: Algarve, Portugal.
16. Krstić, H. and K. Čulo, *Cost efficiency comparison of classic and solar house*, in *Quality, environment, health protection and safety managememnt development trends*. 2008: Neum, Bosna i Hercegovina.
17. Consulting, D.L.M., *Life cycle costing (LCC) as a contribution to sustainable construction, Final Guidance* 2007: London, United Kingdom.
18. Ren, G. and Q. Zhang, *Benchmarking the Life Cycle Cost Management of Building Project*, in *International Conference on Intelligent Systems and Knowledge Engineering (ISKE 2007)*. 2007: China.
19. El-Haram, M.A. and M.W. Horner, *Factors affecting housing maintenance cost.* Journal of Quality in Maintenance Engineering, 2002. **8**.
20. Consulting, D.L.M., *Life cycle costing (LCC) as a contribution to sustainable construction: a common methodology, Final Report* 2007: London, United Kingdom.
21. Langdon, D.a.M.C., *Final Report Summary, Life cycle costing (LCC) as a contribution to sustainable construction: a common methodology* 2007: London, United Kingdom.
22. Al-Hajj, A.N., *Simple cost-significant models for total life-cycle costing in buildings*, in *Department of Civil Engineering*. 1991, University of Dundee: Kirkcaldy.
23. Beusker, E. and C. Stoy, *Indicators and Drivers of Occupancy Costs* in *16th Annual European Real Estate Society Conference* 2009: Stockholm, Sweden.

24. Consulting, D.L.M., *Life cycle costing (LCC) as a contribution to sustainable construction: a common methodology, Final Review* 2007: London, United Kingdom.
25. Kishk, M., et al., *Whole life costing in construction, A state of the art review*. 2003.
26. Commission, E., *Task Group 4 : Life Cycle Costs in Construction*. 2003: London, United Kingdom.
27. Consulting, D.L.M., *Life Cycle Costing (LCC) as a contribution to sustainable construction: a common methodology, Final Methodology*. 2007: London, United Kingdom.
28. Dhillon, B.S., *Life Cycle Costing for Engineers*. 2010, Boca Raton, USA: Taylor & Francis Group.
29. Cole, R.J. and E. Sterner, *Reconciling theory and practice of life-cycle costing.* Building Research & Information, 2000. **28**.
30. Christensen, P.N., G.A. Sparks, and a.K.J. Kostuk, *A method-based survey of life cycle costing literature pertinent to infrastructure design and renewal.* Canadian Journal of Civil Engineering, 2004. **32**: p. 10.
31. Rose, E.P., *Environmentally conscious design an economic life cycle approach*, in *School of Industrial and Manufacturing Science* 1997, Cranfield University.
32. May, A., O. Breitenstein, and K. Lennerts, *The latest developments in facility management research*. 1996, The Leipzig Annual Civil Engineering Report: Leipzig.
33. Kincaid, D., *Integrated Facility Management.* Facilities, 1994. **12**.
34. Wood, B., *Building Maintenance*. Vol. 1. 2009, Singapore: Blackewll Publishing. 311.
35. Kirkham, R.J., *A stochastic whole life cycle cost model for a National Health Service acute care hospital building*, in *Department of Architecture and Building Engineering, Faculty of Social and Environmental Studies, The University of Liverpool*. 2002, The University of Liverpool

Liverpool.

36. Blanchard, B.S., *Life cycle costing - a review.* Terotechnica, 1979. **9-15**.
37. Mithraratne, N., B. Vale, and R. Vale, *Sustainable Living*. 2007, Oxford Elsevier Limited.
38. Smith, J. and D. Jaggar, *Building Cost Planning for the Design Team*. 2007: Elsevier Ltd. .
39. W.Bull, J., *Life Cycle Costing for Construction*. Vol. 2. 2003: Taylor & Francis e-Library.
40. *Sustainable Federal Facilities: A Guide to Integrating Value Engineering, Life-cycle Costing, and Sustainable Development Technical Report* 2001.
41. Al-Hajj, A. and M.W. Horner, *Modelling the running costs of buildings.* Construction Management and Economics, 1998. **16**: p. 459-470.
42. Garnett, N. and K. Owen. *Life cycle costing techniques*. 1995 12/2004]; Available from: http://www.rics.org/site/scripts/download_info.aspx?fileID=1738&categoryID=450.
43. Woodward, D.G., *Life cycle costing-theory, information acquisition and application.* International Journal of Project Management, 1997. **15**: p. 335-344.
44. Sterner, E. (2002) *Combining life-cycle cost and environmental impact: a case study and model for tender evaluation*.
45. Booty, F., *Facilities Management Handbook* Vol. 3. 2006: Elsevier Science & Technology Books
46. Klarin, M., M. Misita, and V. Spasojević-Brkić, *Savremene tendencije u upravljanju održavanjem - pristup održavanju zasnovan na riziku* Tehnička dijagnostika, 2008. **3**.
47. Marenjak, S., M.A. El-Haram, and R.M.W. Horner, *Whole Life Costing in the Building Industry: A Case Study*, in *Construction in the XXI Century: Local and Global Challenges, Joint 2006 CIB Symposium*. 2006: Rome.
48. Aničić, D., *Planiranje Uporabnog vijeka građevine – prijevod norma niza ISO 15686*, in *Građevinski godišnjak 03/04*. 2004, HDGI.

49. Sterner, E., *Green Procurement of Buildings Estimation of Environmental Impact and Life-Cycle Cost* in *Department of Civil and Mining Engineering Division of Steel Structures* 2002.
50. El-Haram, M.A., S. Marenjak, and R.M.W. Horner, *Development of a generic framework for collecting whole life cost data for the building industry.* Journal of Quality in Maintenance Engineering, 2002. **8**.
51. Cerić, A. and M. Katavić, *Upravljanje održavanjem zgrada.* Građevinar, 2000. **53**: p. 83-89.
52. Sarja, A., *Lifetime engineering of buildings and civil infrastructures*. 2005.
53. Consulting, D.L.M., *Life cycle costing (LCC) as a contribution to sustainable construction: a common methodology, Final Report Summary* 2007: London, United Kingdom.
54. Krigsvoll, G. and P. Frolka, *Aiming at sustainability by use of life cycle cost assessment in decision making in planning and design of new buildings and in refurbishment* in *CESB 07*. 2007: Prague. p. 197-201.
55. Consulting, D.L.M., *Literature review of life cycle costing (LCC) and life cycle assessment (LCA)*. 2006: London, United Kingdom.
56. Perera, O., B. Morton, and T. Perfrement, *Life Cycle Costing in Sustainable Public Procurement: A Question of Value*. 2009, International Institute for Sustainable Development (IISD).
57. Langdon, D. and M. Consulting, *Life cycle costing (LCC) as a contribution to sustainable construction: Specification framework for software development* 2007: London, United Kingdom. p. 27.
58. Jabučar, D., *Primjena indikatora za analizu i usporedbu stepena efikasnosti upravljanja vodnim područjima*, in *Građevinski fakultet*. 2009, Univerzitet „Džemal Bijedić“ Mostar.
59. Bistra, Z., *Studija izvodljivosti uspostave zajedničkog prekograničnog postupanja s otpadom i infrastrukturom u zaštiti okoliša*. 2006.
60. *IPPC direktiva*. 2010.
61. *Popis prijevoda pravne stečevine EU-a za područje 06.30.10 - Općenito*. 2010.
62. Consulting, D.L.M., *Life cycle costing (LCC) as a contribution to sustainable construction, Final Specification* 2007: London, United Kingdom.
63. Consulting, D.L.M., *Life cycle costing (LCC) as a contribution to sustainable construction: a common methodology, Draft Methodology: Key issues and outline framework* 2006: London, United Kingdom.
64. Shtub, A. and R. Versano, *Estimating the cost of steel pipe bending, a comparison between neural networks and regression analysis.* International Journal of Production Economics, 1999. **Volume 62**(Issue 3): p. Pages 201-207
65. Nunen, H.v., N.A. Hendriks, and P.A. Erkelens. *Service life as main aspect in environmental assessment*. 2004 04/2005]; Available from: http://alexandria.tue.nl/openaccess/Metis211340.pdf.
66. Bescherer, F., *Established life cycle concepts in the business environment*. 2005, Helsinki: Helsinki University of Technology.
67. Soldatos, P.G., *Building the annual equivalent cost of perennial energy crops.* Options Mediteraneennes, 2002. **48**.
68. *The Surveyors' Construction Handbook*. 2003, RICS Business Services Limited

London, UK.
69. Levander, E., J. Schade, and L. Stehn, *Life cycle costing for buildings: theory and suitability for addressing uncertainties about timber housing.* 2009.
70. Ashworth, A. *Assessing the life expectancies of buildings and their components in life cycle costing*. 1996 12/2004]; Available from: http://www.rics-foundation.org/index.html.
71. DZNM, *Zgrade i druge građevine - Planiranje vijeka uporabe - 1. dio: Opća načela (ISO 15686-1:2000)*. 2002, Zagreb: Državni zavod za normizaciju i mjeriteljstvo.

72. Barringer, H.P., *A Life Cycle Cost Summary* in *International Conference of Maintenance Societies (ICOMS®-2003)* 2003: Perth, Australia
73. Folić, R. and M. Malešev, *Održavanje i sanacija konstrukcija.* Materijali i konstrukcije, 2005. **48**.
74. Vucelic, V., *Ukupni životni troškovi kod JPP/PFI projekata u školstvu u Republici Hrvatskoj*, in *Građevinski fakultet Sveučilišta u Zagrebu*. 2010: Zagreb.
75. Forsyth, M., *Understanding Historic Building Conservation*. 2007: Blackwell Publishing Ltd.
76. Brandon, P., *Best Value in Construction*. 2002: Blackwell Publishing.
77. Macedo, M.C. and P.W. Dobrow, *Value Management for Construction*. 1978: Wiley Interscience.
78. Sterner, E., *'Green procurement' of buildings: a study of Swedish clients considerations.* Construction Management and Economics, 2002. **20**.
79. Miller, J., *Facility Operations Cost Trends and the MARS 8 Life Cycle Cost Model*. 2008, Whitestone Briefings: Washington, D.C.
80. Horner, R.M.W., M.A. El-Haram, and A.K. Munns, *Building maintenance strategy: a new management approach.* Journal of Quality in Maintenance Engineering, 1997. **3**.
81. *Estimation of the need to spend on maintenance and management in the Local Authority housing stock*. 2003: London.
82. Marenjak, S., *Javno Privatno Partnerstvo*. 2011, Ekonomski fakultet: Zagreb.
83. Liu, H., et al., *Regression models for estimating product life cycle cost.* J Intell Manuf, 2009. **20**.
84. Consulting, D.L.M., *Literature review of life cycle costing (LCC) and life cycle assessment (LCA), Draft Review* 2006: London, United Kingdom.
85. Kishk, M. *On the mathematical modelling of whole-life costs*. in *21st Annual ARCOM Conference*. 2005. University of London, United Kingdom.
86. Kishk, M. and A. Al-Hajj. *Fuzzy modelling of life cycle costs of alternatives with different lives*. in *16th Annual ARCOM Conference*. 2000. Glasgow, Scotland.
87. Kishk, M. and A. Al-Hajj, *Handling Linguistic Assessments in Life-Cycle Costing - A Fuzzy Approach*, in *The Construction and Building Conference of the RICS Research Foundation. COBRA 2000*. 2000: University of Greenwich, United Kingdom.
88. Boussabaine, A.H. and R.J. Kirkham, *Whole life cycle performance measurement re-engineering for the UK National Health Service estate.* Facilities, 2006. **24**.
89. Adeli, H. and K.C. Sarma, *Cost Optimization of Structures*. 2006, West Sussex: John Wiley & Sons, Ltd.
90. Aziz, A.M.A., *Performance Analysis and Forecasting for WSDOT Highway Projects*. 2007, Washington State Transportation Center (TRAC): Washington.
91. Cheung, F.K.T. and M. Skitmore, *Application of cross validation techniques for modelling construction costs during the very early design stage* Building and Environment 2005. **41**(12): p. 1973-1990.
92. Consulting, D.L.M., *Life cycle costing (LCC) as a contribution to sustainable construction: a common methodology* 2006: London, United Kingdom.
93. Kovač-Striko, E., N. Kapetanović, and B. Ivanković, *Vjerojatnost i statistika*. 2006.
94. Buljan-August, M., S. Pivac, and A. Štambuk, *Upotreba statistike u ekonomiji*. 2007, Rijeka: Ekonomski fakultet Sveučilišta u Rijeci.
95. Amemiya, T., *Introduction to Statistics and Econometrics*. 1994, London: Harvard Univeristy Press.
96. Chan, Y.H., *Linear Regression Analysis.* Singapore Med Journal 2004 **45**.
97. Graybill, F.A. and H.K. Iyer, *Regression Analysis: Concepts and Application*. 1994: Duxbury Pr.
98. Montgomery, D.C., *Design and Analysis of Experiments*. 2001, New York: John Wiley & Sons, Inc.
99. Mason, R.D., D.A. Lind, and W.G. Marchal, *Statistical Techniques in Busines and Economics*. 1999: Irwin McGraw-Hill.

100. StatSoft. *Electronic Statistics Textbook*. 2010 12/2010]; Available from: http://www.statsoft.com/textbook/partial-least-squares/.
101. Boussabaine, H.A. and R.J. Kirkham, *Whole Life-cycle Costing Risk and Risk Responses*. 2004, Oxford: Blackwell Publishing Ltd.
102. Wilcox, R.R., *Basic Statistics*. 2009: Oxford University Press.
103. Walpole, R.E., et al., *Probability & Statistics for Engineers & Scientists*. 2007: Pearson Education International.
104. *Deskriptivna statistika*. 11/2009]; Available from: http://people.etf.unsa.ba/~ksokolija/c/ug/pees/definicije.htm.
105. *Kolinearnost*. 2010 12/2010]; Available from: www.ffri.uniri.hr/datoteke/ibrdar/kolinearnost_i_supresija.doc.
106. Dougherty, C., *Introduction to Econometrics*. 2007, New York: Oxford University Press.
107. Tobias, R.D., *An introduction to Partial Least Squares Regression*, in *SUGI Proceedings*. 1995.
108. Draper, N.R. and H. Smith, *Applied Regression Analysis*. 1998: John Wiley & Sons, Inc.
109. Dallal, G.E. *Collinearity* 2001 11/2009]; Available from: http://www.jerrydallal.com/LHSP/collin.htm.
110. Rawlings, J.O., S.G. Pantula, and D.A. Dickey, *Applied Regression Analysis: A Research Tool*. 1998: Springer-Verlag New York, Inc.
111. Yeniay, O. and A. Goktas, *A comparison of partial least squares regression with other prediction methods.* Hacettepe Journal of Mathematics and Statistics, 2001. **31**.
112. Chun, H. and S. Keles, *Sparse partial least squares regression for simultaneous dimension reduction and variable selection.* J. R. Statist. Soc., 2010. **72**.
113. Tiljak, M.K. and D. Ivanković. *Testiranje hipoteze*. 2011 08/2011]; Available from: http://cms.mef.hr/.
114. Studenmund, A.H., *Using Econometrics: A Practical Guide* 2000: Addison Wesley.
115. Marusteri, M. and V. Bacarea, *Kako odabrati pravi test za procjenu statističke značajnosti razlike između skupina?* The journal of Croatian Society of Medical Biochemists, 2009.
116. Petz, B., *Osnovne statističke metode za nematematičare*. 2004, Zagreb: Naklada Slap.
117. Baumann, K., *Cross-validation as the objective function for variable-selection techniques.* Trends in Analytical Chemistry, 2003. **22**(6).
118. Freund, R.J., W.J. Wilson, and P. Sa, *Regression Analysis Statistical Modeling of a Response Variable*. 2006, London: Elsevier Inc.
119. Pivac, S., *Metode odabira varijabli u modelu višestruke regresije*. 2005, Ekonomski fakultet Split.
120. Chatterjee, S. and A.S. Hadi, *Regression Analysis by Example*. 2006, New Jersey: John Wiley & Sons, Inc. .
121. Mason, R.L., R.F. Gunst, and J.L. Hess, *Statistical Design and Analysis of Experiments*. 2003, New J ersey: John Wile y & Sons, Inc.
122. *Elementary Concepts in Statistics*. 2011, StatSoft, Inc.: Tulsa.
123. Vukelić, A. and J.G. Kljusurić. *Napredne statističke metode za analizu podataka*. 2009 01/2010]; Available from: http://www.pbf.hr/hr/zavodi/zavod_za_procesno_inzenjerstvo/primjenjena_analiza_podataka.
124. Guszcza, J., *The Basics of Model Validation*. 2005, CAS Predictive Modeling Seminar: Chicago.
125. Mathisen, R., *On-line NIR analysis in a high density polyethene plant, evaluation of sampling system and optimal calibration strategy*. 1999: Telemark College, Department of Technology.
126. Dunn, G., et al., *Describing, explaining or predictingmental health care costs: a guide to regressionmodels.* British Journal Of Psychiatry, 2003. **183**.

127. Yu, C.H., *Resampling methods: concepts, applications, and justification.* Practical Assessment, Research & Evaluation, 2010. **8**.
128. Thomas, A. *Bootstrapping, jackkni ng and cross validation. Reusing your data*. 2009 04/2010]; Available from: www.bioinformatics.med.utah.edu/~alun/teach/stats/week08.pdf.
129. Kier, F.J. *Ways to Explore the Replicability of Multivariate Results (Since Statistical Significance Testing Does Not)*. 1997 03/2010]; Available from: http://ericae.net/ft/tamu/Kier.htm.
130. *SAS/STAT(R) 9.22 User's Guide*. 2010.
131. Vali, M., *Multivariate Data Analysis - A Mathematical Introduction*. 2007, Uppsala: Vali Consulting.
132. Garthwaite, P.H., *An Interpretation of Partial Least Squares.* Journal of the American Statistical Association, 1994. **89**.
133. Abdi, H., *Partial least squares regression and projection on latent structure regression (PLS Regression).* Wiley Interdisciplinary Reviews: Computational Statistics, 2010. **2**(1).
134. Refaeilzadeh, P., L. Tang, and H. Liu, *Cross-Validation*. 2008, Arizona State University.
135. *Stepwise Selecting Models*. 2007, The MathWorks, Inc.
136. González, J., D. Peña, and R. Romera, *A robust partial least squares method with applications*. 2007.
137. Abdel-Nour, N., et al., *Combined Maximum R and Partial Least Squares Method for Wavelengths Selection and Analysis of Spectroscopic Data* International Journal of Poultry Science 2009. **8** (2): p. 170-178.
138. Seo, K.-K., et al., *Approximate Estimation of the Product Life Cycle Cost Using Artificial Neural Networks in Conceptual Design.* The International Journal of Advamced Manufacturing Technology, 2002. **19**(461-471).
139. Vigon, B.W., et al., *Life-Cycle Assessment, Inventory Guidelines and Principles*. 1994: Lewis Publishers.
140. Boussabaine, A., *Cost Planning of PFI and PPP Building Projects*. 2007, New York: Taylor & Francis.
141. Jovanovic, P., *Application of sensitivity analysis in investment project evaluation under uncertainty and risk.* International Journal of Project Management, 1999. **17**.
142. Kartelo, R., *Analiza rizika u ekonomskoj ocjeni projekta na primjeru vodoopskrbnog sustava Zagreb* GRAĐEVINAR 2006. **58**(11): p. 889-898
143. Fuller, S.K. and S.R. Petersen, *Life-Cycle Costing Manual for the Federal Energy Management Program*. 1996, Washington: U.S. Government Printing Office.
144. Medanić, B., I. Pšunder, and V. Skendrović, *Neki aspekti financiranja i financijskog odlučivanja u građevinarstvu*. 2005, Osijek: Sveučilište J. J. Strossmayera u Osijeku, Građevinski fakultet Osijek, Osijek.
145. Schade, J., *Life cycle cost calculation models for buildings*, in *Proceedings of 4th Nordic Conference on Construction Economics and Organisation : Development Processes in Construction Mangement*. 2007: Luleå.
146. Ružđak, K., *Metode procjene isplativosti investicijskih projekata ("Capital Budgeting") i upravljanje projektnim rizicima*. 2009, Ekonomski fakultet u Zagrebu.
147. Alaska, S.o., *Life Cycle Cost Analysis Handbook*, D.o.E.E. Development, Editor. 1999, State of Alaska Juneau. p. 30.
148. Capehart, B.L., W.J. Kennedy, and W.C. Turner, *Guide to Energy Management*. 2008, Lilburn: The Fairmont Press, Inc.
149. Čulo, K., *Ekonomika investicijskih projekata*. 2010, Osijek: Sveučilište J. J. Strossmayera u Osijeku.
150. Langdon, D., *Task Group 4 : Life Cycle Costs in Construction* 2003: London, United Kingdom. p. 96.
151. Marenjak, S. and H. Krstić, *Sensitivity analysis of Facilities Life Cycle Costs.* Technical Gazette, 2010. **17**(4): p. 389-557.

152. *Total asset management, Life Cycle Costing Guideline* 2004, New South Wales Treasury.
153. Rahman, S. and D.J. Vanier, *Life cycle cost analysis as a decision support tool for managing municipal infrastructure* in *CIB 2004 Triennial Congress*. 2004: Toronto, Ontario.
154. *Discount Rate Policy*. 2005.
155. *The Green Book*. 2003, HM Treasury
156. Chandler, R.F., *Life-Cycle Cost Model for Evaluating the Sustainability of Bridge Decks*. 2004, University of Michigan.
157. *Odluka o objavljivanju pravila o utvrđivanju referentne i diskontne stope*. 2008.
158. AZTN. *Referentne stope u Republici Hrvatskoj*. 2010 11/2010]; Available from: www.aztn.hr.
159. AZTN. *Referentne stope u Republici Hrvatskoj*. 2011 06/2011]; Available from: www.aztn.hr.
160. Paunić, A., *Inflation in Croatia with outlook to future*. 2007, MPRA
161. HNB. *Ekonomski indikatori*. 2010 05/2011]; Available from: http://www.hnb.hr/statistika/hstatistika.htm.
162. HNB. *Bilten informacija o gospodarskim kretanjima*. 2011 02/2011].
163. HNB, *Annual Report 2008*. 2009: Zagreb.
164. Hall, K.T., et al., *Guidelines for Life-Cycle Cost Analysis of Pavement Rehabilitation Strategies*, in *TRB 2003 Annual Meeting*. 2003.
165. Research, B., B.C.o.S.F.C.S.t.C.B.L.-C. Costs, and N.R. Council, *Pay Now or Pay Later : Controlling Cost of Ownership From Design Throughout the Service Life of Public Buildings*. 1991, National Academies Press: Washington, USA.
166. Johnstone, N., *The environmental performance of public procurement issues of policy coherence*. 2003.
167. *The Environmental Performance of Public Procurement*. 2003: Paris.
168. Šljivac, D. and Z. Kovač, *DIE 205 EKONOMIKA EES*. 2010, ETFOS: Osijek.
169. Elsafty, A. and A.J. Al-Daini, *Economical comparison between a solarpowered vapour absorption air-conditioning system and a vapour compression system in the Middle East.* Renewable Energy, 2002. **25**.
170. Monti, A., et al., *A full economic analysis of switchgrass under different scenarios in Italy estimated by BEE model.* Biomass and Bioenergy, 2007. **31**.

PRILOZI

PRILOG 1:UPITNIK

PRILOG 2:PODATCI O TROŠKOVIMA

PRILOG 3:KORELACIJE NEOVISNIH I OVISNIH VARIJABLI

PRILOG 4:TEST KOLINEARNOSTI

PRILOG 5:DESKRIPTIVNA STATISTIKA

PRILOG 6: REZULTATI *STEPWISE* ANALIZE

1 OPĆI PODACI O GRAĐEVINI

1.1 OSNOVNI PODACI

1. Naziv ustanove:

2. Djelatnost ustanove odvija se na:

a) jednoj lokaciji
b) dvije lokacije
c) tri lokacije

3. Adresa

Lokacija 1:

Lokacija 2:

Lokacija 3:

4. Tel./Fax.:

Lokacija 1:

Lokacija 2:

Lokacija 3:

1.2 OPĆI PODACI O GRAĐEVINI

1. Vlasništvo nad građevinom:

Lokacija 1	Lokacija 2	Lokacija 3
a) privatno	a) privatno	a) privatno
b) javno	b) javno	b) javno
c) vlasnik=korisnik	c) vlasnik=korisnik	c) vlasnik=korisnik
d) ostalo, _____	d) ostalo, _____	d) ostalo, _____
_____	_____	_____
_____	_____	_____

2. Godina završetka izgradnje građevine:

Lokacija 1:

Lokacija 2:

Lokacija 3:

3. Godina od koje je građevina u uporabi za potrebe ustanove:

Lokacija 1:

Lokacija 2:

Lokacija 3:

4. Površina parcele na kojoj se nalazi građevina:

Lokacija 1:

Lokacija 2:

Lokacija 3:

5. Neto površina građevine:

Lokacija 1:

Lokacija 2:

Lokacija 3:

6. Broj etaža građevine uključujući podrume i suterene:

Lokacija 1:

Lokacija 2:

Lokacija 3:

2 PLANIRANJE ODRŽAVANJA GRAĐEVINE

1. Koliko dugo planirate koristiti građevinu za obavljanje djelatnosti:

Lokacija 1	Lokacija 2	Lokacija 3
a) 0 – 10 godina	a) 0 – 10 godina	a) 0 – 10 godina
b) 11 – 20 godina	b) 11 – 20 godina	b) 11 – 20 godina
c) 21 – 30 godina	c) 21 – 30 godina	c) 21 – 30 godina
d) 31 – 40 godina	d) 31 – 40 godina	d) 31 – 40 godina
e) 41 – 50 godina	e) 41 – 50 godina	e) 41 – 50 godina
f) preko 50 godina	f) preko 50 godina	f) preko 50 godina
g) ne znam	g) ne znam	g) ne znam

2. Postoji li financijski plan održavanja građevine za predviđeno razdoblje uporabe?

a) da
b) ne

3. Ukoliko je Vaš odgovor na 2. pitanje da, koje službe su zadužene za izradu plana održavanja?

4. Postoji li osoba/osobe zadužena za planiranje i praćenje održavanje i troškova održavanja građevine?

a) da
b) ne

5. Ukoliko je Vaš odgovor na 4. pitanje da, molim Vas da osoba zadužena za održavanje građevine prema vlastitom mišljenju ocijeni važnost planiranja i praćenja troškova održavanja građevine?

a) nije važno
b) uglavnom nevažno
c) uglavnom važno
d) jako važno
e) ne znam

6. Provodi li se dodatna edukacija osobe/osoba zadužene za održavanje građevine?

a) da
b) ne

7. Dogradnja građevine planira se u slijedećem vremenskom razdoblju:

Lokacija 1	Lokacija 2	Lokacija 3
a) 0 – 10 godina	a) 0 – 10 godina	a) 0 – 10 godina
b) 11 – 20 godina	b) 11 – 20 godina	b) 11 – 20 godina
c) 21 – 30 godina	c) 21 – 30 godina	c) 21 – 30 godina
d) 31 – 40 godina	d) 31 – 40 godina	d) 31 – 40 godina
e) 41 – 50 godina	e) 41 – 50 godina	e) 41 – 50 godina
f) ne planira se	f) ne planira se	f) ne planira se

8. Rekonstrukcija građevine planira se u slijedećem vremenskom razdoblju:

Lokacija 1	Lokacija 2	Lokacija 3
a) 0 – 10 godina	a) 0 – 10 godina	a) 0 – 10 godina
b) 11 – 20 godina	b) 11 – 20 godina	b) 11 – 20 godina
c) 21 – 30 godina	c) 21 – 30 godina	c) 21 – 30 godina
d) 31 – 40 godina	d) 31 – 40 godina	d) 31 – 40 godina
e) 41 – 50 godina	e) 41 – 50 godina	e) 41 – 50 godina
f) ne planira se	f) ne planira se	f) ne planira se

9. Postoje li predviđanja o broju upisanih studenata na prve godine svih studija za naredno razdoblje od pet godina (od 2009. godine do 2014. godine)?

a) da
b) ne

10. Ako je Vaš odgovor na prethodno pitanje da, molimo Vas da unesete podatke o predviđenom broju studenata za razdoblje od 2009. godine do 2014. godine u tablicu!

Godina	2009	2010	2011	2012	2013	2014
Lokacija 1						
Lokacija 2						
Lokacija 3						

11. Postoje predviđanja o broju djelatnika za naredno razdoblje od pet godina (od 2009. godine do 2014. godine)?

a) da
b) ne

12. Ako je Vaš odgovor na prethodno pitanje da, molimo Vas da unesete podatke o predviđenom broju djelatnika za razdoblje od 2009. godine do 2014. godine u tablicu!

Godina	2009	2010	2011	2012	2013	2014
Lokacija 1						
Lokacija 2						
Lokacija 3						

3 PODACI O UPORABI GRAĐEVINI

1. Funkcionalni prostori i pripadajuće površine:

Lokacija 1

Predavaonice: _____ m^2
Laboratoriji: _____ m^2
Kabineti: _____ m^2
Komunikacije: _____ m^2
Uredi: _____ m^2
Knjižnica: _____ m^2
Kantina: _____ m^2
Sanitarije: _____ m^2
Ostali funkcionalni prostori (molimo nabrojati):

_____
_____
_____
_____
_____

Lokacija 2

Predavaonice: _____ m^2
Laboratoriji: _____ m^2
Kabineti: _____ m^2
Komunikacije: _____ m^2
Uredi: _____ m^2
Knjižnica: _____ m^2
Kantina: _____ m^2
Sanitarije: _____ m^2
Ostali funkcionalni prostori (molimo nabrojati):

_____
_____
_____
_____
_____

Lokacija 3

Predavaonice: _____ m^2

Laboratoriji: _____ m^2

Kabineti: _____ m^2

Komunikacije: _____ m^2

Uredi: _____ m^2

Knjižnica: _____ m^2

Kantina: _____ m^2

Sanitarije: _____ m^2

Ostali funkcionalni prostori (molimo nabrojati):

_____

_____

_____

_____

_____

2. Vodite li evidenciju o broju djelatnika po lokacijama na kojima se odvija djelatnost?

a) da
b) ne

3. Vodite li evidenciju o broju studenata po lokacijama na kojima se odvija djelatnost?

a) da
b) ne

4. Broj djelatnika po godinama:
Ukoliko ne vodite evidenciju po lokacijama molim Vas da podatke unesete za Lokaciju 1.

Godina	1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008
Lokacija 1												
Lokacija 2												
Lokacija 3												

5. Broj studenata po godinama:
Ukoliko ne vodite evidenciju po lokacijama molim Vas da podatke unesete za Lokaciju 1.

Godina	1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008
Lokacija 1												
Lokacija 2												
Lokacija 3												

6. Djelatnost u građevini odvija se u:

Lokacija 1

a) jednoj smjeni
b) dvije smjene
c) ostalo, što? _____
_____

Lokacija 2

a) jednoj smjeni
b) dvije smjene
c) ostalo, što? _____
_____

Lokacija 3

a) jednoj smjeni
b) dvije smjene
c) ostalo, što? _____
_____

7. Podaci o broju radnih sati u građevini:

Lokacija 1

a) dnevno: _____
b) tjedno: _____
c) godišnje: _____

Lokacija 2

a) dnevno: _____
b) tjedno: _____
c) godišnje: _____

Lokacija 3

a) dnevno: _____
b) tjedno: _____
c) godišnje: _____

8. Način grijanja građevine:

Lokacija 1

a) pojedinačne peći
b) etažno centr. grijanje
c) centr. grijanje iz kotlovnice
d) centr. grijanje iz toplane
e) Ostalo, _____
_____

Lokacija 2

a) pojedinačne peći
b) etažno centr. grijanje
c) centr. grijanje iz kotlovnice
d) centr. grijanje iz toplane
e) Ostalo, _____
_____

Lokacija 3

a) pojedinačne peći
b) etažno centr. grijanje
c) centr. grijanje iz kotlovnice
d) centr. grijanje iz toplane
e) Ostalo, _____
_____

9. Vrsta izvora energije za grijanje:

Lokacija 1

a) loživo ulje
b) plin
c) drvo
d) ugljen
e) električna energija
f) Ostalo, _____
_____

Lokacija 2

a) loživo ulje
b) plin
c) drvo
d) ugljen
e) električna energija
f) Ostalo, _____
_____

Lokacija 3

a) loživo ulje
b) plin
c) drvo
d) ugljen
e) električna energija
f) Ostalo, _____
_____

4 PODACI O TROŠKOVIMA ŽIVOTNOG CIKLUSA GRAĐEVINE

4.1 OSNOVNI PODACI

1. Naziv ustanove:

2. Zaokružite lokaciju građevine na koju se odnose podaci o troškovima životnog ciklusa koje ćete unositi:
Ako se djelatnost odvija samo na jednoj lokaciji preskočite ovo pitanje!

a) Lokacija 1
b) Lokacija 2
c) Lokacija 3

3. Adresa

4. Tel./Fax.:

4.2 PODACI O TROŠKOVIMA PERIODIČNIH PREGLEDA GRAĐEVINE

Tablični prikaz troškova održavanja i uporabe

RB	AKTIVNOST	1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008
1	Pregled i ispitivanje zaštite od električnog udara												
2	Ispitivanje neprekinutosti zaštitnog vodiča te glavnog i dodatnog vodiča za izjednačenje potencijala												
3	Ispitivanje izolacijskog otpora električne instalacije												
4	Ispitivanje panik rasvjete												
5	Ispitivanje telefonske instalacije												
6	Ispitivanje stabilnog sustava za dojavu požara												
7	Održavanje sistema vatrodojave												
8	Ispitivanje protupožarnog tipkala za daljinsko isključivanje glavne sklopke												
9	Ispitivanje vatrogasnih aparata												
10	Ispitivanje i održavanje protupožarnih pumpi												
11	Ispitivanje unutarnje hidrantske mreže												
12	Ispitivanje vanjske hidrantske mreže												
13	Ispitivanje posuda pod tlakom (hidrofor)												
14	Ispitivanje gromobranske instalacije												
15	Ispitivanje dimnjaka												
16	Ispitivanje ventilacijskih kanala kuhinje i kantine												
17	Ispitivanje nepropusnosti plinovoda												
18	Ispitivanje strojeva i uređaja s povećanim opasnostima												
19	Ispitivanje toplinske podstanice												
20	Pregled klimatizacijskih uređaja												
21	Ispitivanje štetnosti na radnom mjestu - mikro klima (relativna vlažnost, temperatura i brzina strujanja zraka)												
22	Deratizacija i dezinsekcija												

UKUPNO:												

4.3 PODACI O TROŠKOVIMA ZAMJENE ISTROŠENIH MATERIJALA I ELEMENATA GRAĐEVINE

Tablični prikaz troškova održavanja i uporabe

RB	AKTIVNOST	1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008
1	Zamjena pokrova od pocinčanog lima												
2	Zamjena vanjskih prozora-drvenih												
3	Zamjena vanjskih PVC prozora												
4	Zamjena vanjskih vrata - drvenih												
5	Zamjena vanjskih PVC vrata												
6	Zamjena odvodnih vertikala i hoizontala oborinske odvodnje												
7	Zamjena snjegobrana												
8	Zamjena elektroinstalacija												
9	Zamjena telefonskih instalacija												
10	Zamjena instalacije vodovoda i kanalizacije												
11	Zamjena opreme za grijanje - radijatori, podstanica												
12	Zamjena plastičnih roleta												
13	Zamjena metalnih roleta												
14	Zamjena pvc tende												
15	Zamjena električnih bojlera												
16	Zamjena kupaonskih baterija												
17	Zamjena umivaonika												
18	Zamjena unutarnje stolarije-metalne												
19	Zamjena unutarnje stolarije-plastične												
20	Zamjena unutarnje stolarije-drvene												
21	Zamjena zidnih i podnih pločica												
22	Zamjena wc školjki												
23	Zamjena nadstrešnica												
24	Zamjena rešetaka na prozorima												
25	Zamjena vanjskih površina (Pločnici)												
26	Zamjena parketa												
27	Zamjena laminata												
28	Zamjena klima uređaja												
29	Zamjena vatrodojave (centrala, javljači)												

UKUPNO:												

4.4 PODACI O TROŠKOVIMA PERIODIČNIH RADOVA I POPRAVAKA NA GRAĐEVINI

Tablični prikaz troškova održavanja i uporabe

RB	AKTIVNOST	1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008
1	Bojanje zidova i stropova												
2	Lakiranje parketa												
3	Brušenje stubišta, hodnika i podesta												
4	Ličenje radijatora												
5	Ličenje opšava strehe												
6	Bojanje zidova uljanim bojama												
7	Ličenje metalne konstrukcije												
8	Ličenje vanjske stolarije												
9	Impregnacija površina prije završne obrade fasade												
10	Bojanje fasade												
11	Obrada dijelova fasade (cokl)												
12	Ličenje ograde stubišta,protupožarnih stuba, zaštitnih rešetki												
13	Ličenje unutarnje stolarije												
14	Zidarski popravci žbuke, cementna glazura												
15	Troškovi skele												

UKUPNO:												

4.5 PODACI O TROŠKOVIMA REAKTIVNOG ODRŽAVANJA GRAĐEVINE

Tablični prikaz troškova održavanja i uporabe

RB	AKTIVNOST	1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008
1	Ostakljenje razbijenih staklenih površina												
2	Popravak vatrodojave												
3	Zamjena rasvjetnih tijela												
4	Stolarski popravci prozora i vrata												
5	Popravci ili zamjena okova, brava, kvaka												
6	Popravak krova, limarski radovi												
8	Popravak ili zamjena vodokotlića												
9	Popravak ili zamjena jednoručnih miješalica za vodu												
10	Zamjena wc daske												
11	Popravak gromobranske instalacije												
12	Popravak klima uređaja												
13	Popravak telefona i instalacije telekomunikacija												
14	Popravak poda od parketa, pločica, PVC-a, laminata												
15	Popravak radijatora toplotne podstanice												
16	Popravak roleta												
17	Održavanje kanalizacije i vodovodne instalacije												
18	Održavanje elektroinstalacija												
19	Održavanje i popravci dizala												
20	Popravci dijelova hidrantske mreže												

UKUPNO:												

4.6 PODACI O POGONSKIM TROŠKOVIMA GRAĐEVINE (TROŠKOVI UPORABE)

Tablični prikaz troškova održavanja i uporabe

RB	AKTIVNOST	1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008
1	Opskrba električnom energijom												
2	Opskrba pitkom vodom												
3	Troškovi kanalizacije												
4	Troškovi plina												
5	Opskrba toplinskom energijom												
6	Telefonske i internetske usluge												
7	Odvoz komunalnog otpada												
8	Čišćenje zgrade i okoliša												
9	Komunalna naknada												
10	Naknada za slivne vode												
11	Troškovi osiguranja												
12	Porezi, lokalni doprinosi i sl.												
13	Troškovi čuvarske službe i zaštitara												

UKUPNO:												

UKUPNI NOMINALNI TROŠKOVI ODRŽAVANJA I UPORABE GRAĐEVINA SVEUČILIŠTA U OSIJEKU

ŠIFRA GRAĐEVINE: F4

GRUPA TROŠKOVA	1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008	UKUPNO	TROŠKOVI / REF.PERIOD REF. PERIOD = 8
TROŠKOVI PERIODIČNIH PREGLEDA GRAĐEVINE	0,0	0,0	0,0	0,0	8.436	8.384	16.145	21.521	25.603	23.833	23.562	24.114	151.597	18.950
TROŠKOVI ZAMJENE ISTROŠENIH MATERIJALA I ELEMENATA GRAĐEVINE	0,0	0,0	0,0	0,0	388.101	260.550	83.104	288.596	168.317	5.201	9.170	656	1.203.695	150.462
TROŠKOVI PERIODIČNIH RADOVA I POPRAVAKA NA GRAĐEVINI	0,0	0,0	0,0	0,0	28.020	17.607	30.872	96.764	30.540	7.590	71.004	20.509	302.907	37.863
TROŠKOVI REAKTIVNOG ODRŽAVANJA GRAĐEVINE	0,0	0,0	0,0	0,0	43.606	15.128	15.903	9.304	5.617	11.068	6.254	13.402	120.281	15.035
TROŠKOVI UPORABE	0,0	0,0	0,0	0,0	251.073	325.793	332.832	348.965	365.741	417.396	417.029	450.800	2.909.628	363.703
UKUPNO:	0,0	0,0	0,0	0,0	719.234	627.463	478.856	765.149	595.818	465.087	527.019	509.481	4.688.107	586.013
KUMULATIVNO:	0,0	0,0	0,0	0,0	719.234	1.346.697	1.825.553	2.590.702	3.186.520	3.651.607	4.178.626	4.688.107		

ŠIFRA GRAĐEVINE: F9

GRUPA TROŠKOVA	1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008	UKUPNO	TROŠKOVI / REF.PERIOD REF. PERIOD = 10
TROŠKOVI PERIODIČNIH PREGLEDA GRAĐEVINE	0,0	0,0	1.717	2.394	2.196	3.500	2.836	10.556	25.559	23.376	24.369	26.747	123.251	12.325
TROŠKOVI ZAMJENE ISTROŠENIH MATERIJALA I ELEMENATA GRAĐEVINE	0,0	0,0	771	0	1.253	5.248	2.086	2.024	1.530	5.244	18.134	0	36.290	3.629
TROŠKOVI PERIODIČNIH RADOVA I POPRAVAKA NA GRAĐEVINI	0,0	0,0	0	0	1.439	21.066	1.837	27.420	22.210	0	0	0	73.972	7.397
TROŠKOVI REAKTIVNOG ODRŽAVANJA GRAĐEVINE	0,0	0,0	27.453	2.111	1.437	2.801	1.092	48.813	44.807	369.914	2.949.900	0	3.448.328	344.833
TROŠKOVI UPORABE	0,0	0,0	395.377	330.150	357.221	378.725	439.816	412.704	472.005	451.955	490.286	511.963	4.240.202	424.020
UKUPNO:	0,0	0,0	425.318	334.655	363.546	411.340	447.666	501.518	566.112	850.489	3.482.689	538.710	7.922.043	792.204
KUMULATIVNO:	0,0	0,0	425.318	759.972	1.123.519	1.534.858	1.982.525	2.484.042	3.050.154	3.900.643	7.383.332	7.922.043		

ŠIFRA GRAĐEVINE: F10

GRUPA TROŠKOVA	1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008	UKUPNO	TROŠKOVI / REF.PERIOD REF. PERIOD = 12
TROŠKOVI PERIODIČNIH PREGLEDA GRAĐEVINE	9.834	5.185	7.967	4.343	18.081	7.113	4.275	8.199	13.094	22.205	14.132	30.872	145.300	12.108
TROŠKOVI ZAMJENE ISTROŠENIH MATERIJALA I ELEMENATA GRAĐEVINE	386.028	39.300	0	133.230	193.894	250.795	218.320	0	0	496.513	0	0	1.718.080	143.173
TROŠKOVI PERIODIČNIH RADOVA I POPRAVAKA NA GRAĐEVINI	0	152.007	0	0	0	0	0	0	1.083.383	0	0	0	1.235.390	102.949
TROŠKOVI REAKTIVNOG ODRŽAVANJA GRAĐEVINE	49.429	28.234	89.840	14.597	16.042	36.493	9.783	25.358	76.243	33.097	2.200	30.526	411.842	34.320
TROŠKOVI UPORABE	396.958	338.464	326.766	415.831	346.505	288.390	332.485	350.618	398.186	342.549	337.685	319.885	4.194.322	349.527
UKUPNO:	842.249	563.190	424.573	568.001	574.522	582.791	564.863	384.175	1.570.906	894.364	354.017	381.283	7.704.934	642.078
KUMULATIVNO:	842.249	1.405.439	1.830.012	2.398.013	2.972.535	3.555.326	4.120.189	4.504.364	6.075.270	6.969.634	7.323.651	7.704.934		

ŠIFRA GRAĐEVINE: F14

GRUPA TROŠKOVA	1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008	UKUPNO	TROŠKOVI / REF.PERIOD REF. PERIOD = 4
TROŠKOVI PERIODIČNIH PREGLEDA GRAĐEVINE	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	14.624	11.578	151	2.379	28.731	7.183
TROŠKOVI ZAMJENE ISTROŠENIH MATERIJALA I ELEMENATA GRAĐEVINE	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	398.027	53.037	60.589	10.953	522.605	130.651
TROŠKOVI PERIODIČNIH RADOVA I POPRAVAKA NA GRAĐEVINI	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	1.189.456	198.955	518.250	910.545	2.817.207	704.302
TROŠKOVI REAKTIVNOG ODRŽAVANJA GRAĐEVINE	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	220.979	23.676	0	12.267	256.922	64.230
TROŠKOVI UPORABE	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	60.891	290.064	621.523	612.148	1.584.626	396.157
UKUPNO:	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	1.883.977	577.310	1.200.512	1.548.292	5.210.091	1.302.523
KUMULATIVNO:	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	1.883.977	2.461.286	3.661.799	5.210.091		

ŠIFRA GRAĐEVINE: F18

GRUPA TROŠKOVA	1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008	UKUPNO	TROŠKOVI / REF.PERIOD REF. PERIOD = 8
TROŠKOVI PERIODIČNIH PREGLEDA GRAĐEVINE	0,0	0,0	0,0	0,0	810	850	970	2.700	3.276	7.956	7.479	9.696	33.737	4.217
TROŠKOVI ZAMJENE ISTROŠENIH MATERIJALA I ELEMENATA GRAĐEVINE	0,0	0,0	0,0	0,0	100	0	1.672	330	5.655	410	3.085	1.369.698	1.380.950	172.619
TROŠKOVI PERIODIČNIH RADOVA I POPRAVAKA NA GRAĐEVINI	0,0	0,0	0,0	0,0	1.518.140	3.234.817	6.135.633	1.168.725	782.494	91.949	3.100	2.900	12.937.758	1.617.220
TROŠKOVI REAKTIVNOG ODRŽAVANJA GRAĐEVINE	0,0	0,0	0,0	0,0	1.800	3.869	3.800	5.626	10.090	22.285	21.302	41.087	109.859	13.732
TROŠKOVI UPORABE	0,0	0,0	0,0	0,0	103.179	377.287	405.138	423.580	357.664	437.986	432.975	445.347	2.983.156	372.894
UKUPNO:	0,0	0,0	0,0	0,0	1.624.029	3.616.823	6.547.213	1.600.961	1.159.180	560.586	467.941	1.868.728	17.445.461	2.180.683
KUMULATIVNO:	0,0	0,0	0,0	0,0	1.624.029	5.240.852	11.788.065	13.389.026	14.548.206	15.108.792	15.576.733	17.445.461		

ŠIFRA GRAĐEVINE: F8

GRUPA TROŠKOVA	1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008	UKUPNO	TROŠKOVI / REF.PERIOD REF. PERIOD = 12
TROŠKOVI PERIODIČNIH PREGLEDA GRAĐEVINE	350	4.484	13.377	37.348	50.502	47.579	38.402	47.404	43.509	33.954	39.556	34.426	390.890	32.574
TROŠKOVI ZAMJENE ISTROŠENIH MATERIJALA I ELEMENATA GRAĐEVINE	560	1.122	356	0	3.680	0	0	0	19.434	17.267	7.359	50.859	100.637	8.386
TROŠKOVI PERIODIČNIH RADOVA I POPRAVAKA NA GRAĐEVINI	79.717	14.017	88.036	2.357	23.446	0	0	64.614	30.936	68.000	69.956	91.957	533.036	44.420
TROŠKOVI REAKTIVNOG ODRŽAVANJA GRAĐEVINE	17.489	207.433	4.976	72.598	229.349	14.212	66.024	2.178	38.475	18.341	31.838	34.532	737.443	61.454
TROŠKOVI UPORABE	356.377	348.463	366.294	448.821	472.545	519.969	502.393	479.890	508.457	499.077	491.198	573.601	5.567.085	463.924
UKUPNO:	454.493	575.518	473.040	561.125	779.521	581.759	606.818	594.085	640.811	636.638	639.906	785.375	7.329.090	610.758
KUMULATIVNO:	454.493	1.030.011	1.503.051	2.064.176	2.843.697	3.425.456	4.032.274	4.626.359	5.267.171	5.903.808	6.543.715	7.329.090		

ŠIFRA GRAĐEVINE: F16

GRUPA TROŠKOVA	1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008	UKUPNO	TROŠKOVI / REF.PERIOD REF. PERIOD = 10
TROŠKOVI PERIODIČNIH PREGLEDA GRAĐEVINE	0,0	0,0	15.829	11.526	7.730	40.118	17.265	18.683	17.290	17.520	20.858	18.050	184.869	18.487
TROŠKOVI ZAMJENE ISTROŠENIH MATERIJALA I ELEMENATA GRAĐEVINE	0,0	0,0	0	43.735	0	299.380	66.750	379.961	4.917	0	620.352	155.008	1.570.103	157.010
TROŠKOVI PERIODIČNIH RADOVA I POPRAVAKA NA GRAĐEVINI	0,0	0,0	1.381.307	1.060.813	471.788	743.794	717.937	359.822	1.623.877	1.564.790	547.577	1.293.776	9.765.481	976.548
TROŠKOVI REAKTIVNOG ODRŽAVANJA GRAĐEVINE	0,0	0,0	4.221	0	161.107	0	18.568	3.148	14.324	80.929	891.754	464.017	1.638.068	163.807
TROŠKOVI UPORABE	0,0	0,0	430.630	460.445	487.533	538.422	538.012	570.627	847.627	891.065	864.625	822.934	6.451.920	645.192
UKUPNO:	0,0	0,0	1.831.987	1.576.519	1.128.158	1.621.714	1.358.532	1.332.241	2.508.035	2.554.304	2.945.166	2.753.785	19.610.441	1.961.044
KUMULATIVNO:	0,0	0,0	1.831.987	3.408.506	4.536.664	6.158.378	7.516.910	8.849.151	11.357.186	13.911.490	16.856.656	19.610.441		

ŠIFRA GRAĐEVINE: F6

GRUPA TROŠKOVA	1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008	UKUPNO	TROŠKOVI / REF.PERIOD REF. PERIOD = 6
TROŠKOVI PERIODIČNIH PREGLEDA GRAĐEVINE	0,0	0,0	0,0	0,0	0,0	0,0	15.176	14.376	17.382	15.598	16.096	15.981	94.609	15.768
TROŠKOVI ZAMJENE ISTROŠENIH MATERIJALA I ELEMENATA GRAĐEVINE	0,0	0,0	0,0	0,0	0,0	0,0	0	0	0	500	10.500	500	11.500	1.917
TROŠKOVI PERIODIČNIH RADOVA I POPRAVAKA NA GRAĐEVINI	0,0	0,0	0,0	0,0	0,0	0,0	15.000	2.000	0	0	38.000	12.000	67.000	11.167
TROŠKOVI REAKTIVNOG ODRŽAVANJA GRAĐEVINE	0,0	0,0	0,0	0,0	0,0	0,0	0	7.000	43.000	43.800	413.200	92.000	599.000	99.833
TROŠKOVI UPORABE	0,0	0,0	0,0	0,0	0,0	0,0	1.228.850	482.470	669.700	512.600	589.400	839.700	4.322.720	720.453
UKUPNO:	0,0	0,0	0,0	0,0	0,0	0,0	1.259.026	505.846	730.082	572.498	1.067.196	960.181	5.094.829	849.138
KUMULATIVNO:	0,0	0,0	0,0	0,0	0,0	0,0	1.259.026	1.764.872	2.494.954	3.067.452	4.134.648	5.094.829		

Korelacija varijabli

Variable	Correlations (Podloga StatSoft 8 uzoraka) Marked correlations are significant at p < ,05000 N=8 (Casewise deletion of missing data)										
	Means	Std.Dev.	Starost gradjevine	Broj godine uporabe	Ref. period	Etaze	Pov. predavaonica	Pov. kabineta	Pov. komunikacija	Pov. sanitarija	Pov. ureda
Starost gradjevine	123,0	97,5	1,000000	-0,027703	0,275896	-0,638035	0,379180	0,470485	0,590904	-0,019915	0,506670
Broj godine uporabe	14,1	9,4	-0,027703	1,000000	*0,836340*	0,278530	0,336446	0,472358	-0,093988	0,532032	-0,405559
Ref. period	8,8	2,8	0,275896	*0,836340*	1,000000	0,219199	0,309582	0,480233	0,116824	0,647884	-0,152070
Etaze	4,0	0,9	-0,638035	0,278530	0,219199	1,000000	-0,526670	-0,323351	-0,463013	0,358364	-0,156387
Pov. predavaonica	846,7	281,2	0,379180	0,336446	0,309582	-0,526670	1,000000	*0,794262*	0,249074	0,511287	0,022247
Pov. kabineta	735,1	291,9	0,470485	0,472358	0,480233	-0,323351	*0,794262*	1,000000	0,641716	0,382406	0,396663
Pov. komunikacija	966,3	681,5	0,590904	-0,093988	0,116824	-0,463013	0,249074	0,641716	1,000000	-0,262835	*0,758758*
Pov. sanitarija	222,2	197,3	-0,019915	0,532032	0,647884	0,358364	0,511287	0,382406	-0,262835	1,000000	-0,153776
Pov. ureda	337,1	192,0	0,506670	-0,405559	-0,152070	-0,156387	0,022247	0,396663	*0,758758*	-0,153776	1,000000
Pov. knjiznica	85,9	45,5	0,433185	0,257332	0,633146	-0,304726	0,441283	0,428537	0,415064	0,383014	0,017933
Pov. laboratorija	471,8	494,9	-0,145176	0,192575	0,440191	0,427205	0,268153	0,142689	-0,205985	*0,862009*	-0,001980
Ostale povrsine	585,3	444,8	0,386789	-0,464048	-0,392432	-0,180435	-0,109513	0,104404	0,359794	-0,323781	0,642705
Ukupna povrsina	4315,3	1481,5	0,667683	0,058862	0,344536	-0,324135	0,609850	*0,824747*	*0,748292*	0,361629	*0,735122*
Djelatnici	90,4	54,0	0,189418	-0,001509	0,048602	0,262785	-0,038431	0,367426	0,428769	0,087573	*0,751782*
Studenti	788,4	740,2	0,053540	*0,824384*	0,545870	0,041485	0,190212	0,490734	0,210263	0,004942	-0,199772
Smjene	1,9	0,4	0,468479	0,176977	0,394623	-0,436436	0,426286	0,311530	0,205321	0,209183	-0,132385
Troskovi uporabe	466983,8	139485,0	0,028066	-0,051673	-0,158298	0,266174	-0,199966	0,222712	0,353483	-0,178420	0,650592

Korelacija varijabli

Variable	Correlations (Podloga StatSoft 8 uzoraka) Marked correlations are significant at p < ,05000 N=8 (Casewise deletion of missing data)							
	Pov. knjiznica	Pov. laboratorija	Ostale povrsine	Ukupna povrsina	Djelatnici	Studenti	Smjene	Troskovi uporabe
Starost gradjevine	0,433185	-0,145176	0,386789	0,667683	0,189418	0,053540	0,468479	0,028066
Broj godine uporabe	0,257332	0,192575	-0,464048	0,058862	-0,001509	*0,824384*	0,176977	-0,051673
Ref. period	0,633146	0,440191	-0,392432	0,344536	0,048602	0,545870	0,394623	-0,158298
Etaze	-0,304726	0,427205	-0,180435	-0,324135	0,262785	0,041485	-0,436436	0,266174
Pov. predavaonica	0,441283	0,268153	-0,109513	0,609850	-0,038431	0,190212	0,426286	-0,199966
Pov. kabineta	0,428537	0,142689	0,104404	*0,824747*	0,367426	0,490734	0,311530	0,222712
Pov. komunikacija	0,415064	-0,205985	0,359794	*0,748292*	0,428769	0,210263	0,205321	0,353483
Pov. sanitarija	0,383014	*0,862009*	-0,323781	0,361629	0,087573	0,004942	0,209183	-0,178420
Pov. ureda	0,017933	-0,001980	0,642705	*0,735122*	*0,751782*	-0,199772	-0,132385	0,650592
Pov. knjiznica	1,000000	0,368568	-0,218654	0,519529	-0,297758	0,032064	*0,762307*	-0,549411
Pov. laboratorija	0,368568	1,000000	-0,415682	0,310732	0,196477	-0,312761	-0,031186	-0,087622
Ostale povrsine	-0,218654	-0,415682	1,000000	0,351931	0,237945	-0,250151	0,186533	0,276763
Ukupna povrsina	0,519529	0,310732	0,351931	1,000000	0,496123	0,016108	0,334182	0,250506
Djelatnici	-0,297758	0,196477	0,237945	0,496123	1,000000	0,121703	-0,595571	*0,936251*
Studenti	0,032064	-0,312761	-0,250151	0,016108	0,121703	1,000000	0,017128	0,219144
Smjene	*0,762307*	-0,031186	0,186533	0,334182	-0,595571	0,017128	1,000000	*-0,734252*
Troskovi uporabe	-0,549411	-0,087622	0,276763	0,250506	*0,936251*	0,219144	*-0,734252*	1,000000

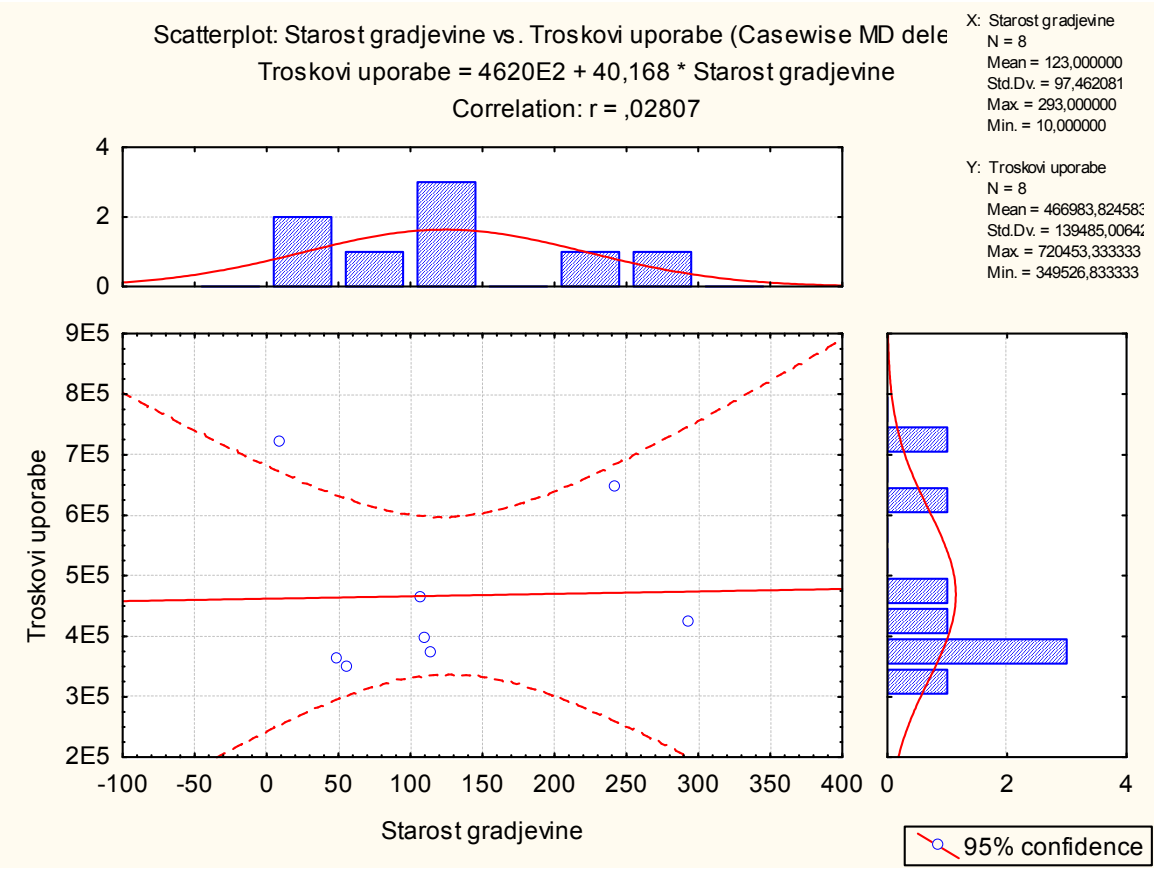
Scatterplot: Starost gradjevine vs. Troskovi uporabe (Casewise MD dele
Troskovi uporabe = 4620E2 + 40,168 * Starost gradjevine
Correlation: r = ,02807
X: Starost gradjevine
N = 8
Mean = 123,000000
Std.Dv. = 97,462081
Max. = 293,000000
Min. = 10,000000
Y: Troskovi uporabe
N = 8
Mean = 466983,824583
Std.Dv. = 139485,00642
Max. = 720453,333333
Min. = 349526,833333
Troskovi uporabe
Starost gradjevine
95% confidence

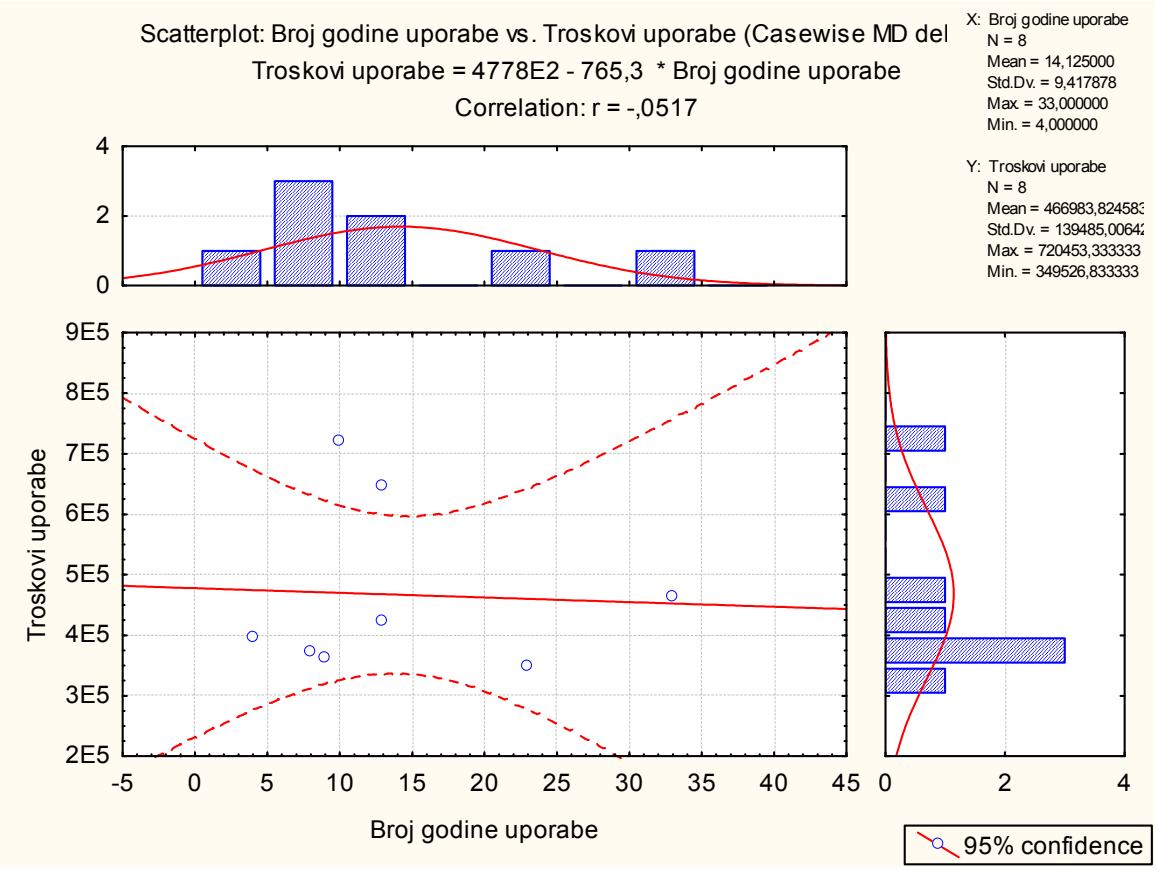
Scatterplot: Broj godine uporabe vs. Troskovi uporabe (Casewise MD del
Troskovi uporabe = 4778E2 - 765,3 * Broj godine uporabe
Correlation: r = -,0517
X: Broj godine uporabe
N = 8
Mean = 14,125000
Std.Dv. = 9,417878
Max. = 33,000000
Min. = 4,000000
Y: Troskovi uporabe
N = 8
Mean = 466983,824583
Std.Dv. = 139485,00642
Max. = 720453,333333
Min. = 349526,833333
Troskovi uporabe
Broj godine uporabe
95% confidence

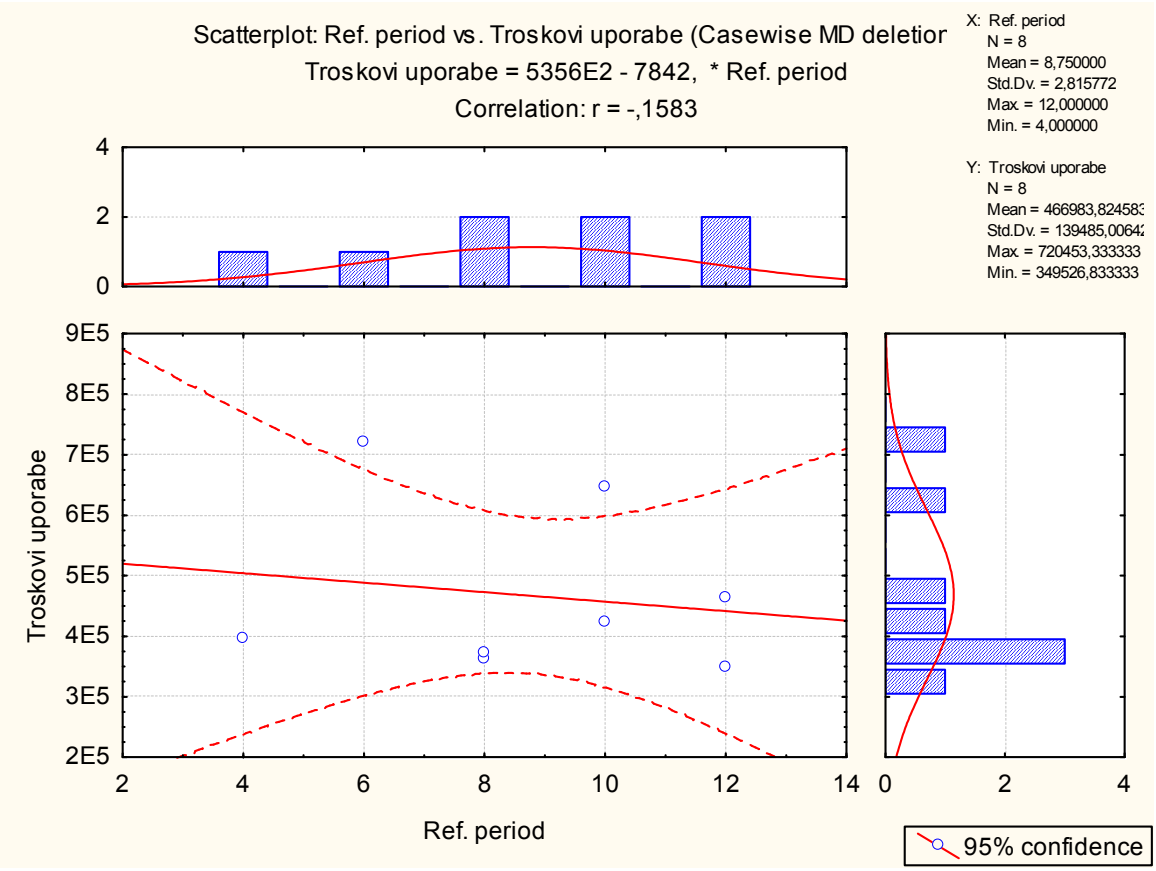
Scatterplot: Ref. period vs. Troskovi uporabe (Casewise MD deletior
Troskovi uporabe = 5356E2 - 7842, * Ref. period
Correlation: r = -,1583
X: Ref. period
N = 8
Mean = 8,750000
Std.Dv. = 2,815772
Max. = 12,000000
Min. = 4,000000
Y: Troskovi uporabe
N = 8
Mean = 466983,824583
Std.Dv. = 139485,00642
Max. = 720453,333333
Min. = 349526,833333
Troskovi uporabe
Ref. period
95% confidence

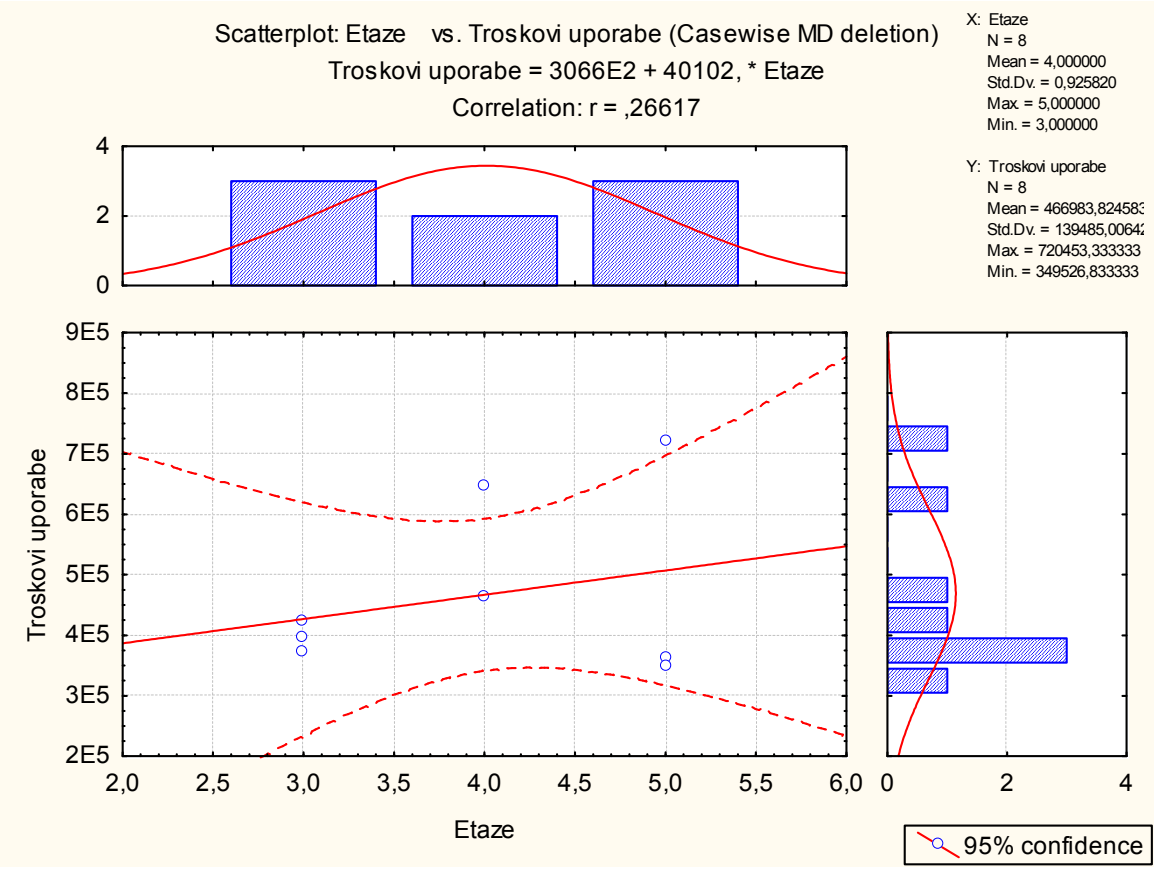
Scatterplot: Etaze vs. Troskovi uporabe (Casewise MD deletion)
Troskovi uporabe = 3066E2 + 40102, * Etaze
Correlation: r = ,26617
X: Etaze
N = 8
Mean = 4,000000
Std.Dv. = 0,925820
Max. = 5,000000
Min. = 3,000000
Y: Troskovi uporabe
N = 8
Mean = 466983,824583
Std.Dv. = 139485,00642
Max. = 720453,333333
Min. = 349526,833333
Troskovi uporabe
Etaze
95% confidence

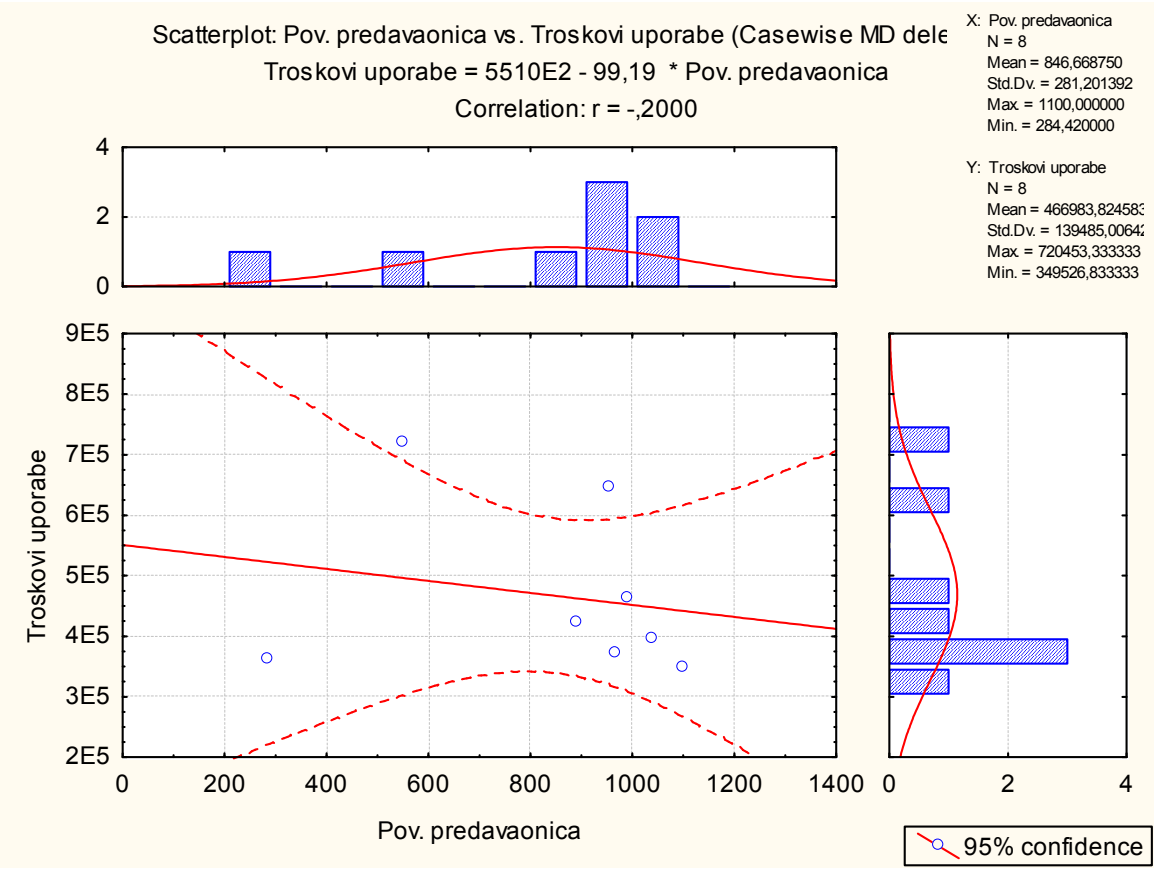
Scatterplot: Pov. predavaonica vs. Troskovi uporabe (Casewise MD dele
Troskovi uporabe = 5510E2 - 99,19 * Pov. predavaonica
Correlation: r = -,2000
X: Pov. predavaonica
N = 8
Mean = 846,668750
Std.Dv. = 281,201392
Max. = 1100,000000
Min. = 284,420000
Y: Troskovi uporabe
N = 8
Mean = 466983,824583
Std.Dv. = 139485,00642
Max. = 720453,333333
Min. = 349526,833333
Troskovi uporabe
Pov. predavaonica
95% confidence

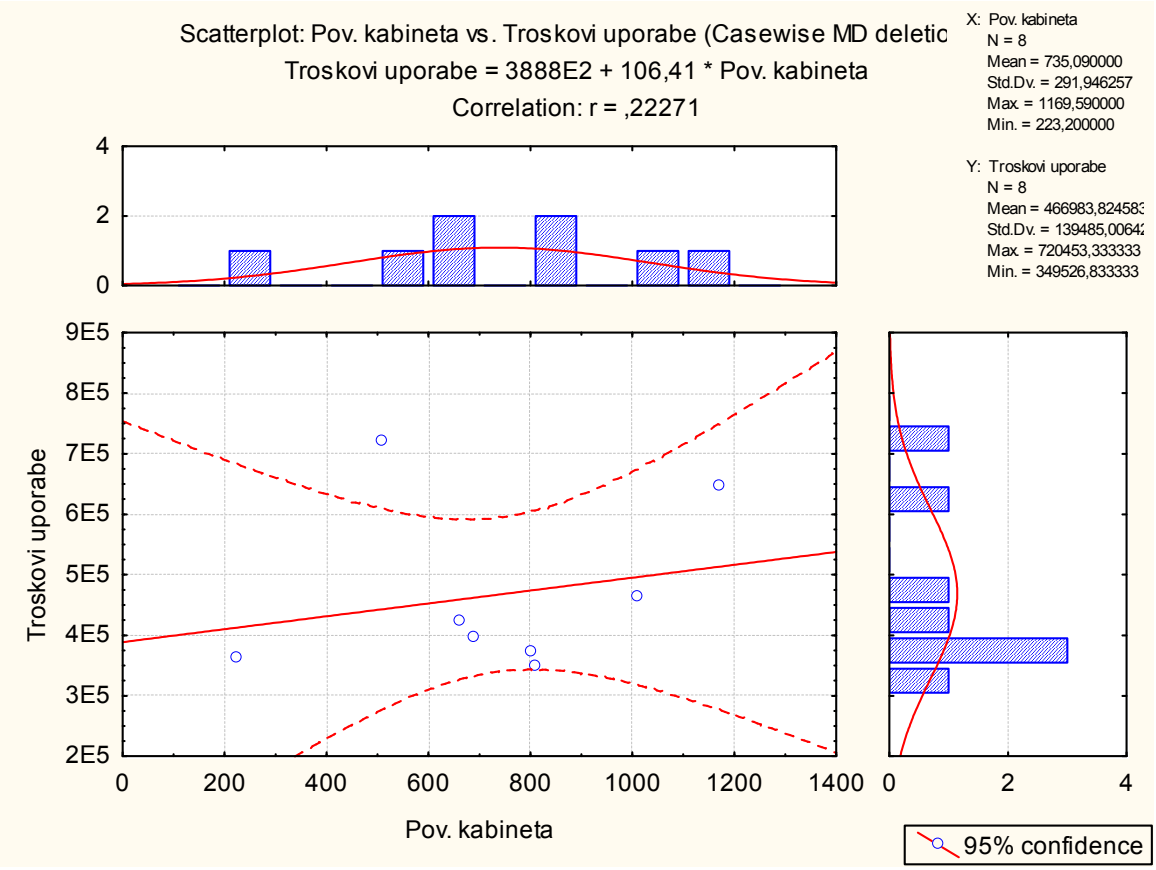
Scatterplot: Pov. kabineta vs. Troskovi uporabe (Casewise MD deletic
Troskovi uporabe = 3888E2 + 106,41 * Pov. kabineta
Correlation: r = ,22271
X: Pov. kabineta
N = 8
Mean = 735,090000
Std.Dv. = 291,946257
Max. = 1169,590000
Min. = 223,200000
Y: Troskovi uporabe
N = 8
Mean = 466983,824583
Std.Dv. = 139485,00642
Max. = 720453,333333
Min. = 349526,833333
Troskovi uporabe
Pov. kabineta
95% confidence

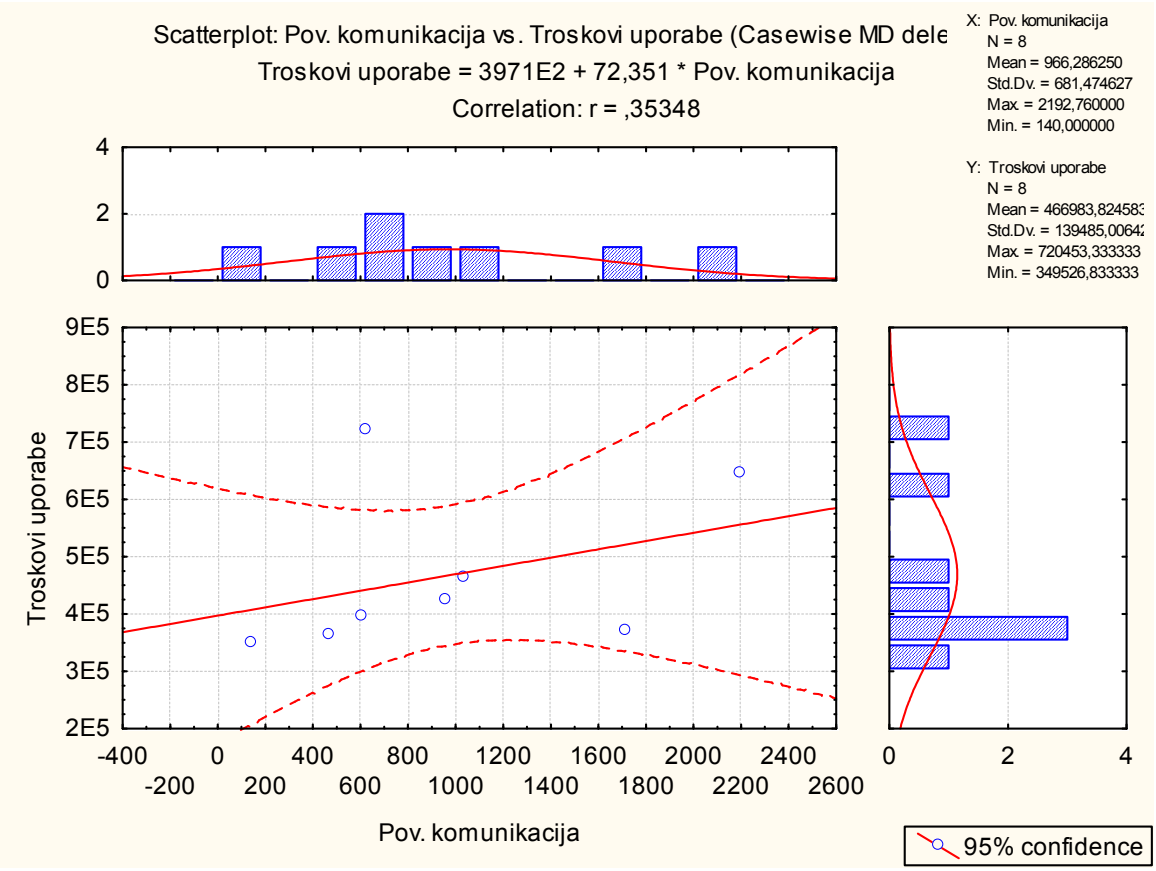
Scatterplot: Pov. komunikacija vs. Troskovi uporabe (Casewise MD dele
Troskovi uporabe = 3971E2 + 72,351 * Pov. komunikacija
Correlation: r = ,35348
X: Pov. komunikacija
N = 8
Mean = 966,286250
Std.Dv. = 681,474627
Max. = 2192,760000
Min. = 140,000000
Y: Troskovi uporabe
N = 8
Mean = 466983,824583
Std.Dv. = 139485,00642
Max. = 720453,333333
Min. = 349526,833333
Troskovi uporabe
Pov. komunikacija
95% confidence

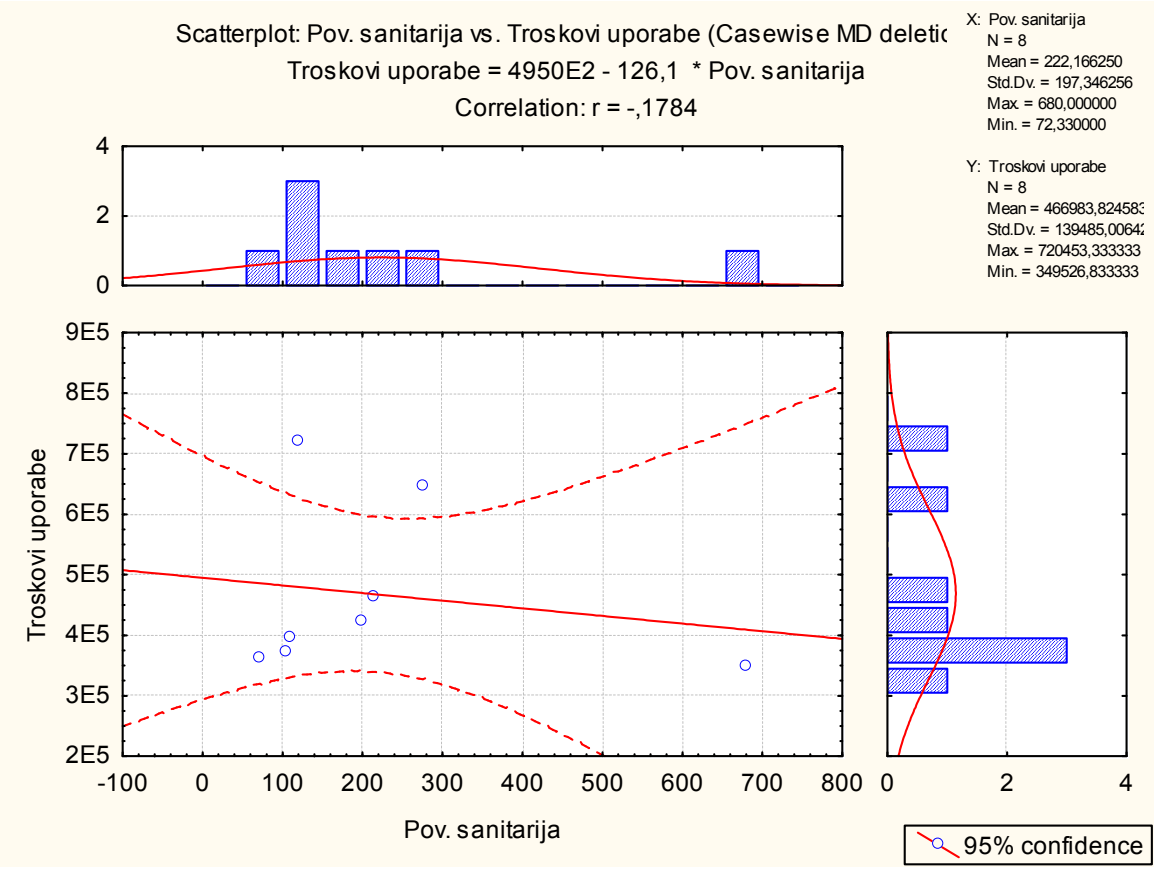
Scatterplot: Pov. sanitarija vs. Troskovi uporabe (Casewise MD deletic
Troskovi uporabe = 4950E2 - 126,1 * Pov. sanitarija
Correlation: r = -,1784
X: Pov. sanitarija
N = 8
Mean = 222,166250
Std.Dv. = 197,346256
Max. = 680,000000
Min. = 72,330000
Y: Troskovi uporabe
N = 8
Mean = 466983,824583
Std.Dv. = 139485,00642
Max. = 720453,333333
Min. = 349526,833333
Troskovi uporabe
Pov. sanitarija
95% confidence

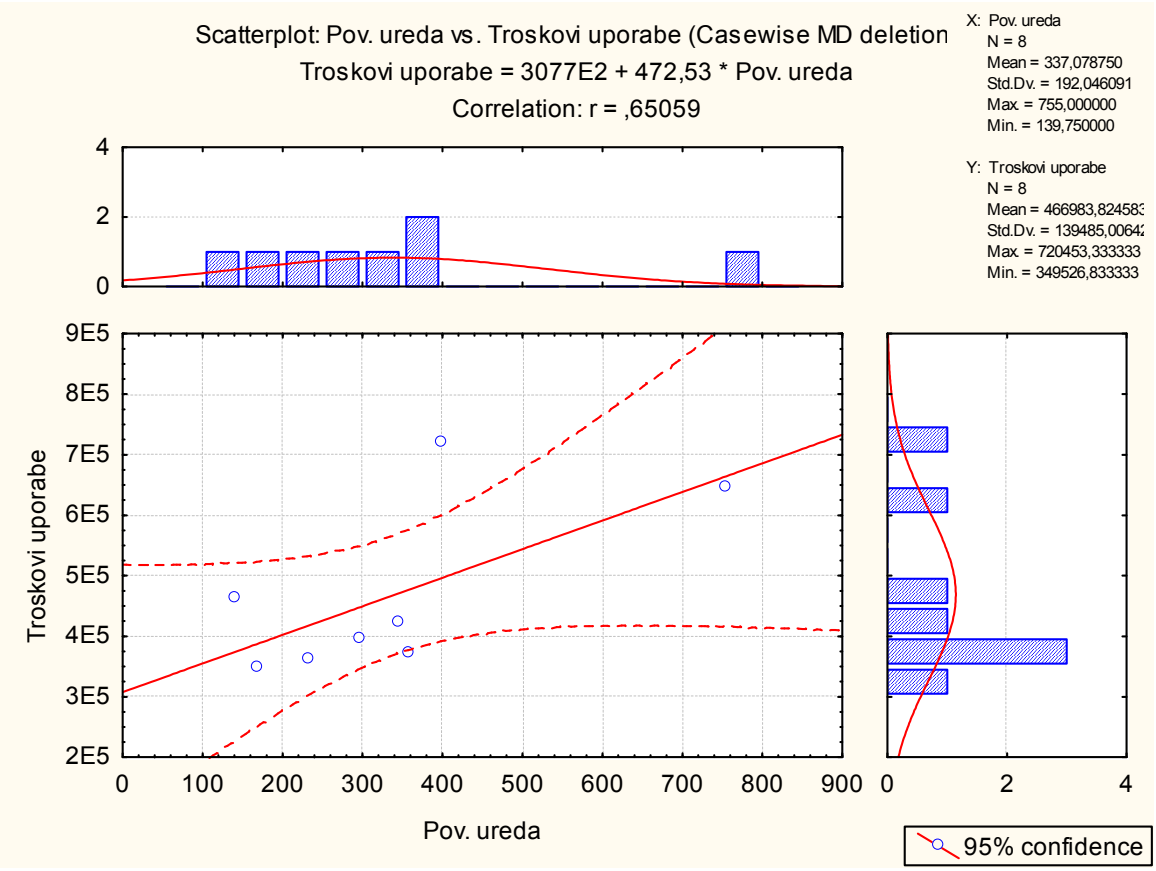
Scatterplot: Pov. ureda vs. Troskovi uporabe (Casewise MD deletion
Troskovi uporabe = 3077E2 + 472,53 * Pov. ureda
Correlation: r = ,65059
X: Pov. ureda
N = 8
Mean = 337,078750
Std.Dv. = 192,046091
Max. = 755,000000
Min. = 139,750000
Y: Troskovi uporabe
N = 8
Mean = 466983,824583
Std.Dv. = 139485,00642
Max. = 720453,333333
Min. = 349526,833333
Troskovi uporabe
Pov. ureda
95% confidence

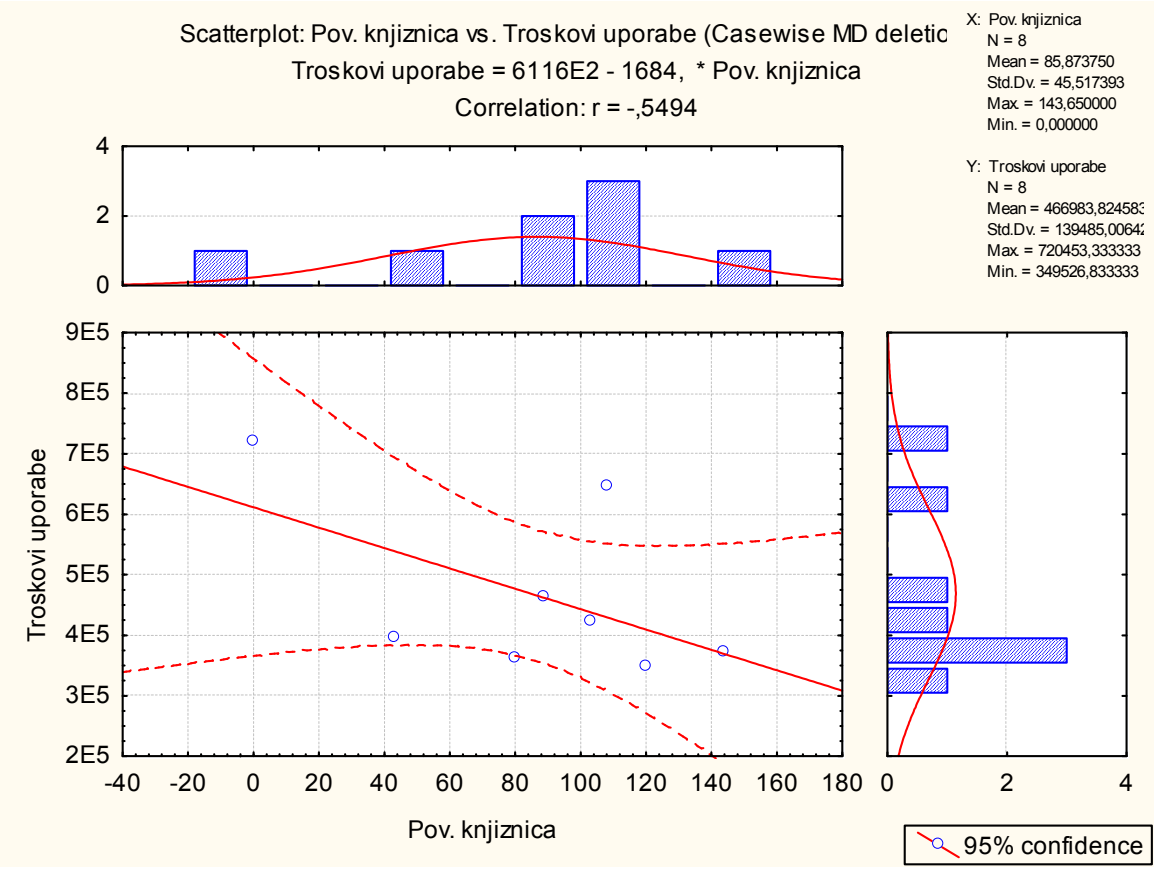
Scatterplot: Pov. knjiznica vs. Troskovi uporabe (Casewise MD deletic
Troskovi uporabe = 6116E2 - 1684, * Pov. knjiznica
Correlation: r = -,5494
X: Pov. knjiznica
N = 8
Mean = 85,873750
Std.Dv. = 45,517393
Max. = 143,650000
Min. = 0,000000
Y: Troskovi uporabe
N = 8
Mean = 466983,824583
Std.Dv. = 139485,00642
Max. = 720453,333333
Min. = 349526,833333
Troskovi uporabe
Pov. knjiznica
95% confidence

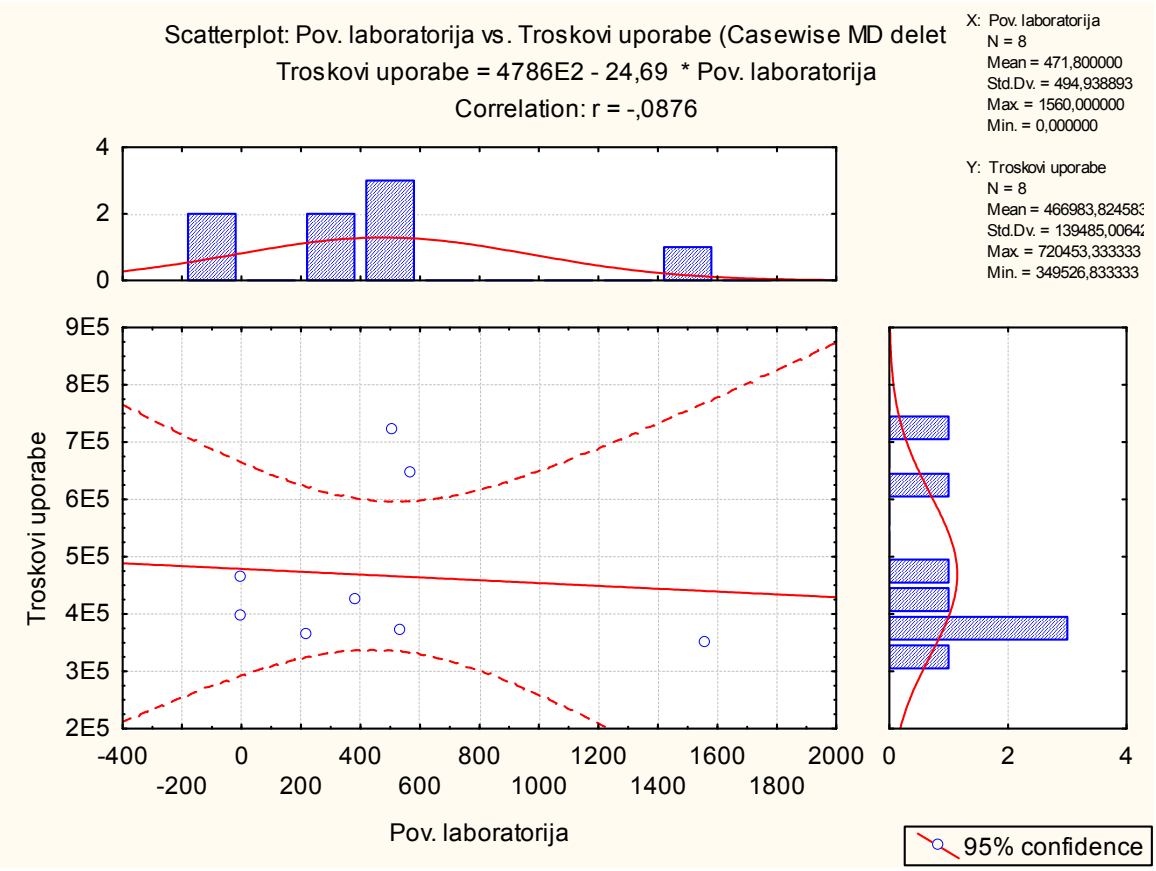
Scatterplot: Pov. laboratorija vs. Troskovi uporabe (Casewise MD delet
Troskovi uporabe = 4786E2 - 24,69 * Pov. laboratorija
Correlation: r = -,0876
X: Pov. laboratorija
N = 8
Mean = 471,800000
Std.Dv. = 494,938893
Max. = 1560,000000
Min. = 0,000000
Y: Troskovi uporabe
N = 8
Mean = 466983,824583
Std.Dv. = 139485,00642
Max. = 720453,333333
Min. = 349526,833333
Troskovi uporabe
Pov. laboratorija
95% confidence

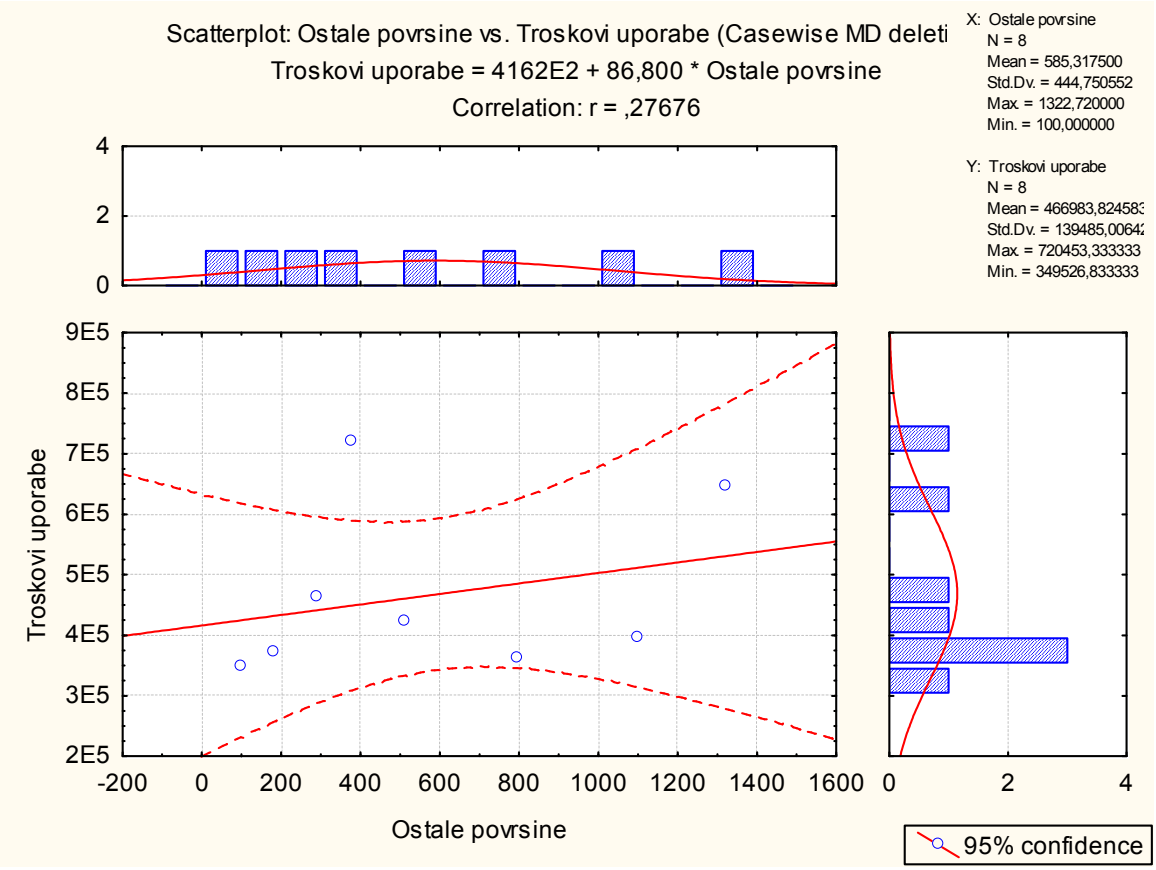
Scatterplot: Ostale povrsine vs. Troskovi uporabe (Casewise MD deleti
Troskovi uporabe = 4162E2 + 86,800 * Ostale povrsine
Correlation: r = ,27676
X: Ostale povrsine
N = 8
Mean = 585,317500
Std.Dv. = 444,750552
Max. = 1322,720000
Min. = 100,000000
Y: Troskovi uporabe
N = 8
Mean = 466983,824583
Std.Dv. = 139485,00642
Max. = 720453,333333
Min. = 349526,833333
Troskovi uporabe
Ostale povrsine
95% confidence

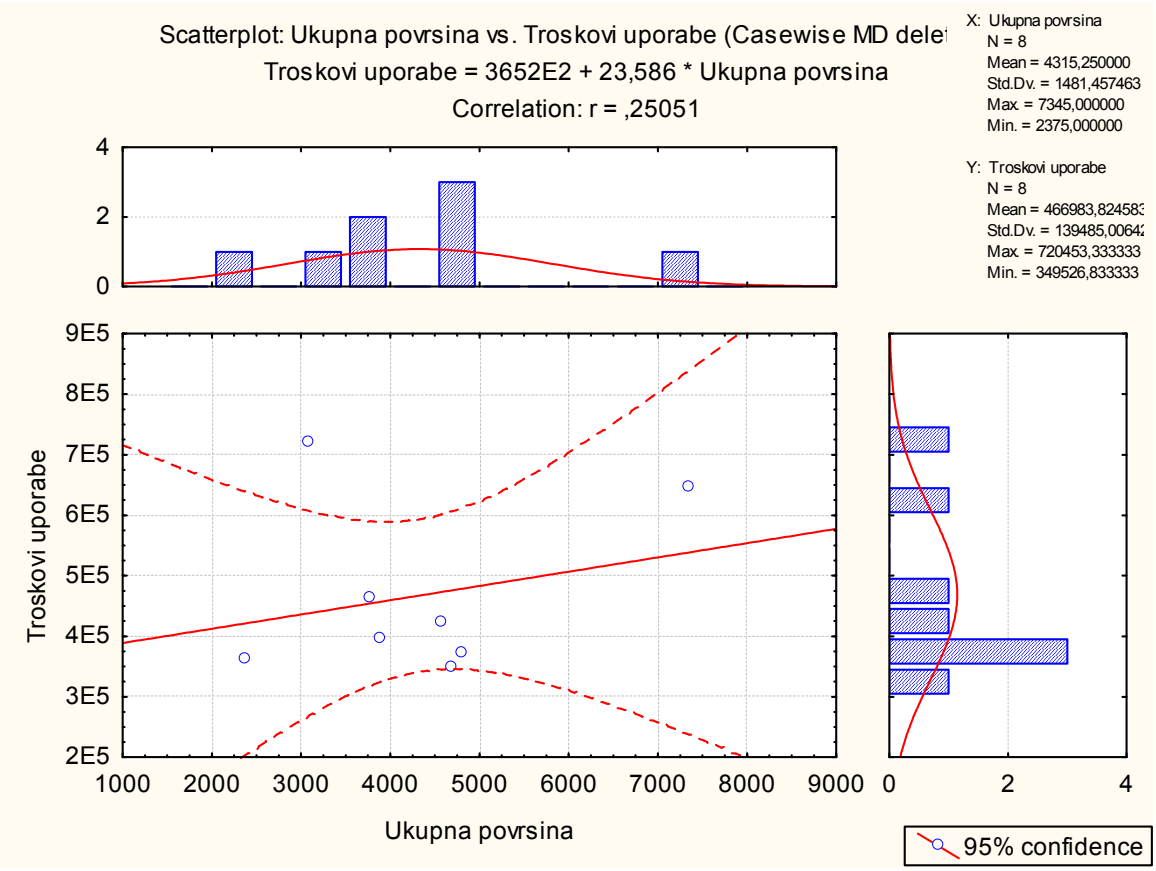
Scatterplot: Ukupna povrsina vs. Troskovi uporabe (Casewise MD dele
Troskovi uporabe = 3652E2 + 23,586 * Ukupna povrsina
Correlation: r = ,25051
X: Ukupna povrsina
N = 8
Mean = 4315,250000
Std.Dv. = 1481,457463
Max. = 7345,000000
Min. = 2375,000000
Y: Troskovi uporabe
N = 8
Mean = 466983,824583
Std.Dv. = 139485,00642
Max. = 720453,333333
Min. = 349526,833333
Troskovi uporabe
Ukupna povrsina
95% confidence

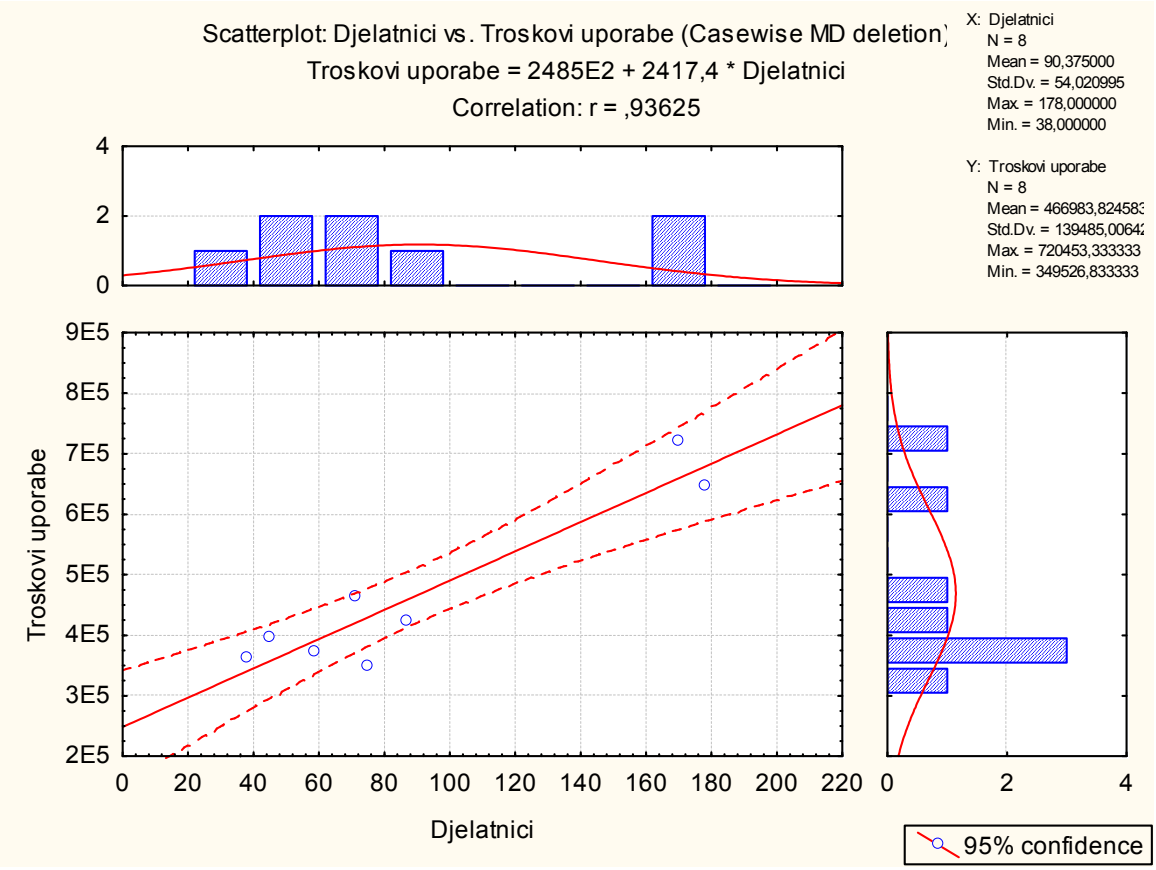
Scatterplot: Djelatnici vs. Troskovi uporabe (Casewise MD deletion)
Troskovi uporabe = 2485E2 + 2417,4 * Djelatnici
Correlation: r = ,93625
X: Djelatnici
N = 8
Mean = 90,375000
Std.Dv. = 54,020995
Max. = 178,000000
Min. = 38,000000
Y: Troskovi uporabe
N = 8
Mean = 466983,824583
Std.Dv. = 139485,00642
Max. = 720453,333333
Min. = 349526,833333
Troskovi uporabe
Djelatnici
95% confidence

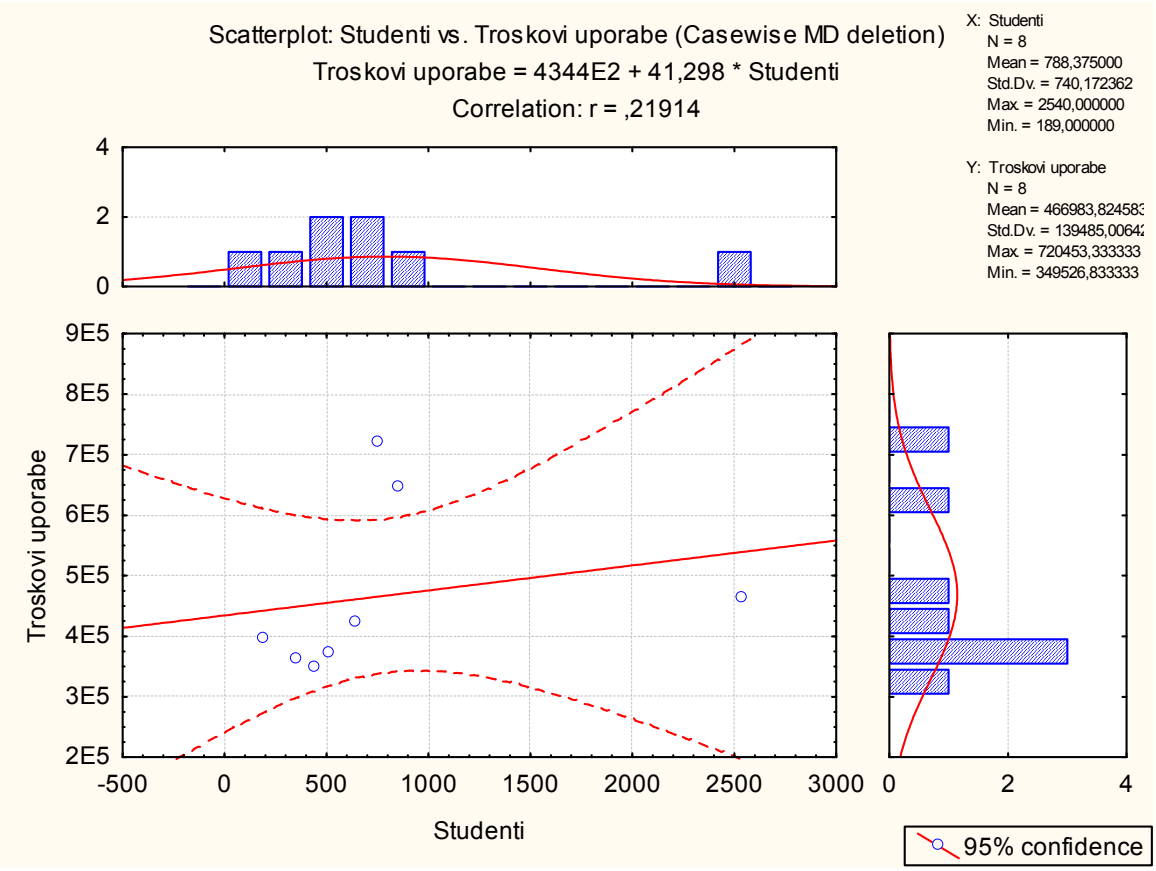
Scatterplot: Studenti vs. Troskovi uporabe (Casewise MD deletion)
Troskovi uporabe = 4344E2 + 41,298 * Studenti
Correlation: r = ,21914
X: Studenti
N = 8
Mean = 788,375000
Std.Dv. = 740,172362
Max. = 2540,000000
Min. = 189,000000
Y: Troskovi uporabe
N = 8
Mean = 466983,824583
Std.Dv. = 139485,00642
Max. = 720453,333333
Min. = 349526,833333
Troskovi uporabe
Studenti
95% confidence

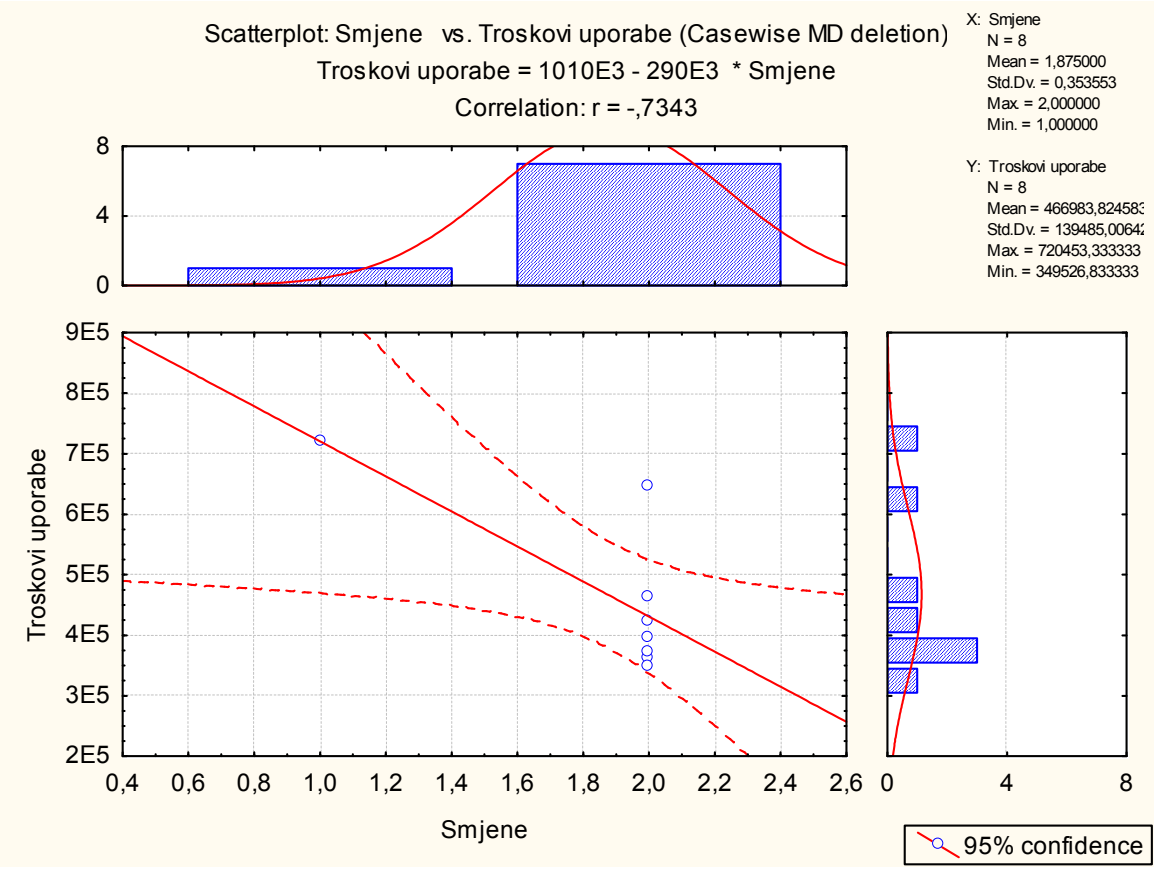
Scatterplot: Smjene vs. Troskovi uporabe (Casewise MD deletion)
Troskovi uporabe = 1010E3 - 290E3 * Smjene
Correlation: r = -,7343
X: Smjene
N = 8
Mean = 1,875000
Std.Dv. = 0,353553
Max. = 2,000000
Min. = 1,000000
Y: Troskovi uporabe
N = 8
Mean = 466983,824583
Std.Dv. = 139485,00642
Max. = 720453,333333
Min. = 349526,833333
Troskovi uporabe
Smjene
95% confidence

Korelacija varijabli

Variable	Correlations (Podloga StatSoft 8 uzoraka) Marked correlations are significant at p < ,05000 N=8 (Casewise deletion of missing data)									
	Means	Std.Dev.	Starost gradjevine	Broj godine uporabe	Ref. period	Etaze	Pov. predavaonica	Pov. kabineta	Pov. komunikacija	Pov. sanitarija
Starost gradjevine	123	97,5	1,000000	-0,027703	0,275896	-0,638035	0,379180	0,470485	0,590904	-0,019915
Broj godine uporabe	14	9,4	-0,027703	1,000000	*0,836340*	0,278530	0,336446	0,472358	-0,093988	0,532032
Ref. period	9	2,8	0,275896	*0,836340*	1,000000	0,219199	0,309582	0,480233	0,116824	0,647884
Etaze	4	0,9	-0,638035	0,278530	0,219199	1,000000	-0,526670	-0,323351	-0,463013	0,358364
Pov. predavaonica	847	281,2	0,379180	0,336446	0,309582	-0,526670	1,000000	*0,794262*	0,249074	0,511287
Pov. kabineta	735	291,9	0,470485	0,472358	0,480233	-0,323351	*0,794262*	1,000000	0,641716	0,382406
Pov. komunikacija	966	681,5	0,590904	-0,093988	0,116824	-0,463013	0,249074	0,641716	1,000000	-0,262835
Pov. sanitarija	222	197,3	-0,019915	0,532032	0,647884	0,358364	0,511287	0,382406	-0,262835	1,000000
Pov. ureda	337	192,0	0,506670	-0,405559	-0,152070	-0,156387	0,022247	0,396663	*0,758758*	-0,153776
Pov. knjiznica	86	45,5	0,433185	0,257332	0,633146	-0,304726	0,441283	0,428537	0,415064	0,383014
Pov. laboratorija	472	494,9	-0,145176	0,192575	0,440191	0,427205	0,268153	0,142689	-0,205985	*0,862009*
Ostale povrsine	585	444,8	0,386789	-0,464048	-0,392432	-0,180435	-0,109513	0,104404	0,359794	-0,323781
Ukupna povrsina	4315	1481,5	0,667683	0,058862	0,344536	-0,324135	0,609850	*0,824747*	*0,748292*	0,361629
Djelatnici	90	54,0	0,189418	-0,001509	0,048602	0,262785	-0,038431	0,367426	0,428769	0,087573
Studenti	788	740,2	0,053540	*0,824384*	0,545870	0,041485	0,190212	0,490734	0,210263	0,004942
Smjene	2	0,4	0,468479	0,176977	0,394623	-0,436436	0,426286	0,311530	0,205321	0,209183
Troskovi odrzavanja i uporabe	1115555	634626,4	0,332877	-0,452262	-0,246536	-0,534467	0,338337	0,471739	*0,818448*	-0,226372

Korelacija varijabli

Variable	Correlations (Podloga StatSoft 8 uzoraka) Marked correlations are significant at p < ,05000 N=8 (Casewise deletion of missing data)								
	Pov. ureda	Pov. knjiznica	Pov. laboratorija	Ostale povrsine	Ukupna povrsina	Djelatnici	Studenti	Smjene	Troskovi odrzavanja i uporabe
Starost gradjevine	0,506670	0,433185	-0,145176	0,386789	0,667683	0,189418	0,053540	0,468479	0,332877
Broj godine uporabe	-0,405559	0,257332	0,192575	-0,464048	0,058862	-0,001509	*0,824384*	0,176977	-0,452262
Ref. period	-0,152070	0,633146	0,440191	-0,392432	0,344536	0,048602	0,545870	0,394623	-0,246536
Etaze	-0,156387	-0,304726	0,427205	-0,180435	-0,324135	0,262785	0,041485	-0,436436	-0,534467
Pov. predavaonica	0,022247	0,441283	0,268153	-0,109513	0,609850	-0,038431	0,190212	0,426286	0,338337
Pov. kabineta	0,396663	0,428537	0,142689	0,104404	*0,824747*	0,367426	0,490734	0,311530	0,471739
Pov. komunikacija	*0,758758*	0,415064	-0,205985	0,359794	*0,748292*	0,428769	0,210263	0,205321	*0,818448*
Pov. sanitarija	-0,153776	0,383014	*0,862009*	-0,323781	0,361629	0,087573	0,004942	0,209183	-0,226372
Pov. ureda	1,000000	0,017933	-0,001980	0,642705	*0,735122*	*0,751782*	-0,199772	-0,132385	0,681456
Pov. knjiznica	0,017933	1,000000	0,368568	-0,218654	0,519529	-0,297758	0,032064	*0,762307*	0,371205
Pov. laboratorija	-0,001980	0,368568	1,000000	-0,415682	0,310732	0,196477	-0,312761	-0,031186	-0,031309
Ostale povrsine	0,642705	-0,218654	-0,415682	1,000000	0,351931	0,237945	-0,250151	0,186533	0,322329
Ukupna povrsina	*0,735122*	0,519529	0,310732	0,351931	1,000000	0,496123	0,016108	0,334182	0,664086
Djelatnici	*0,751782*	-0,297758	0,196477	0,237945	0,496123	1,000000	0,121703	-0,595571	0,236921
Studenti	-0,199772	0,032064	-0,312761	-0,250151	0,016108	0,121703	1,000000	0,017128	-0,236554
Smjene	-0,132385	*0,762307*	-0,031186	0,186533	0,334182	-0,595571	0,017128	1,000000	0,169625
Troskovi odrzavanja i uporabe	0,681456	0,371205	-0,031309	0,322329	0,664086	0,236921	-0,236554	0,169625	1,000000

Korelacija varijabli

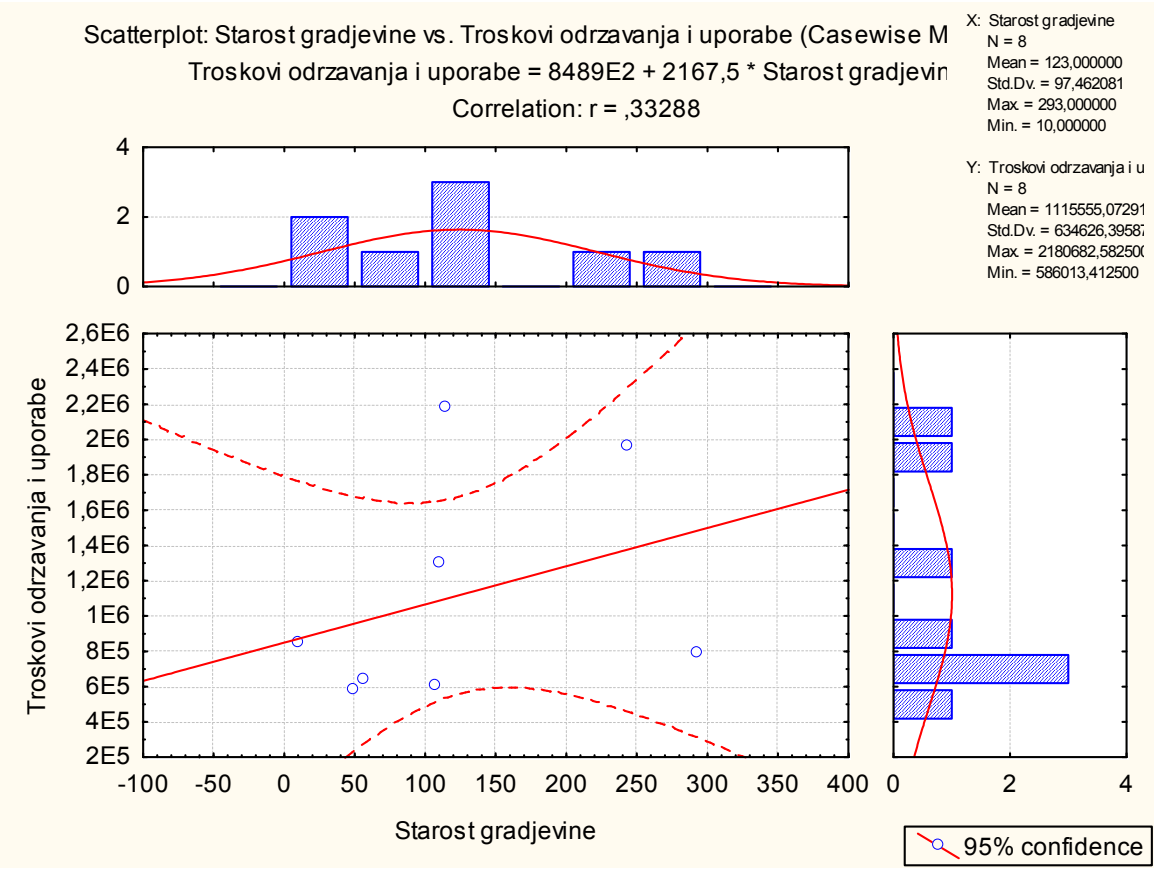

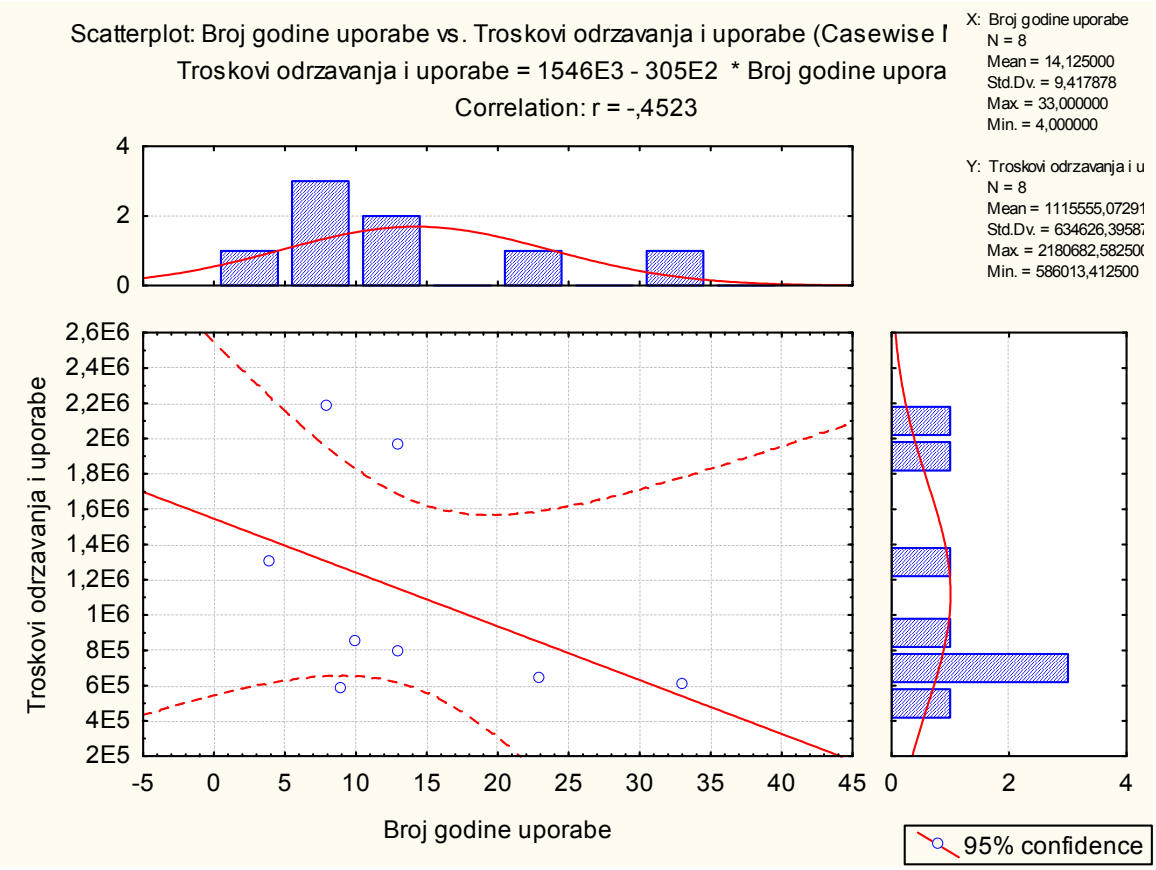

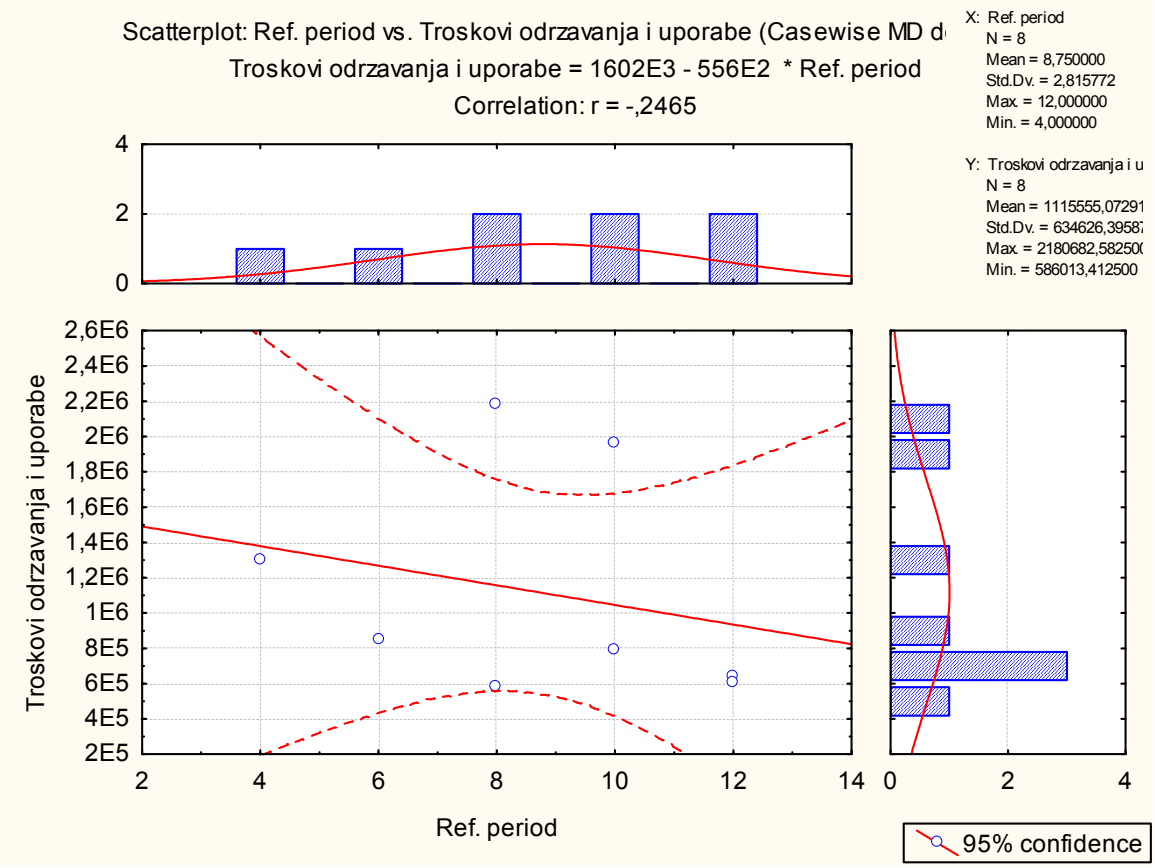
Scatterplot: Ref. period vs. Troskovi odrzavanja i uporabe (Casewise MD d
Troskovi odrzavanja i uporabe = 1602E3 - 556E2 * Ref. period
Correlation: r = -,2465
X: Ref. period
N = 8
Mean = 8,750000
Std.Dv. = 2,815772
Max. = 12,000000
Min. = 4,000000
Y: Troskovi odrzavanja i u
N = 8
Mean = 1115555,07291
Std.Dv. = 634626,39587
Max. = 2180682,58250
Min. = 586013,412500
Troskovi odrzavanja i uporabe
Ref. period
95% confidence

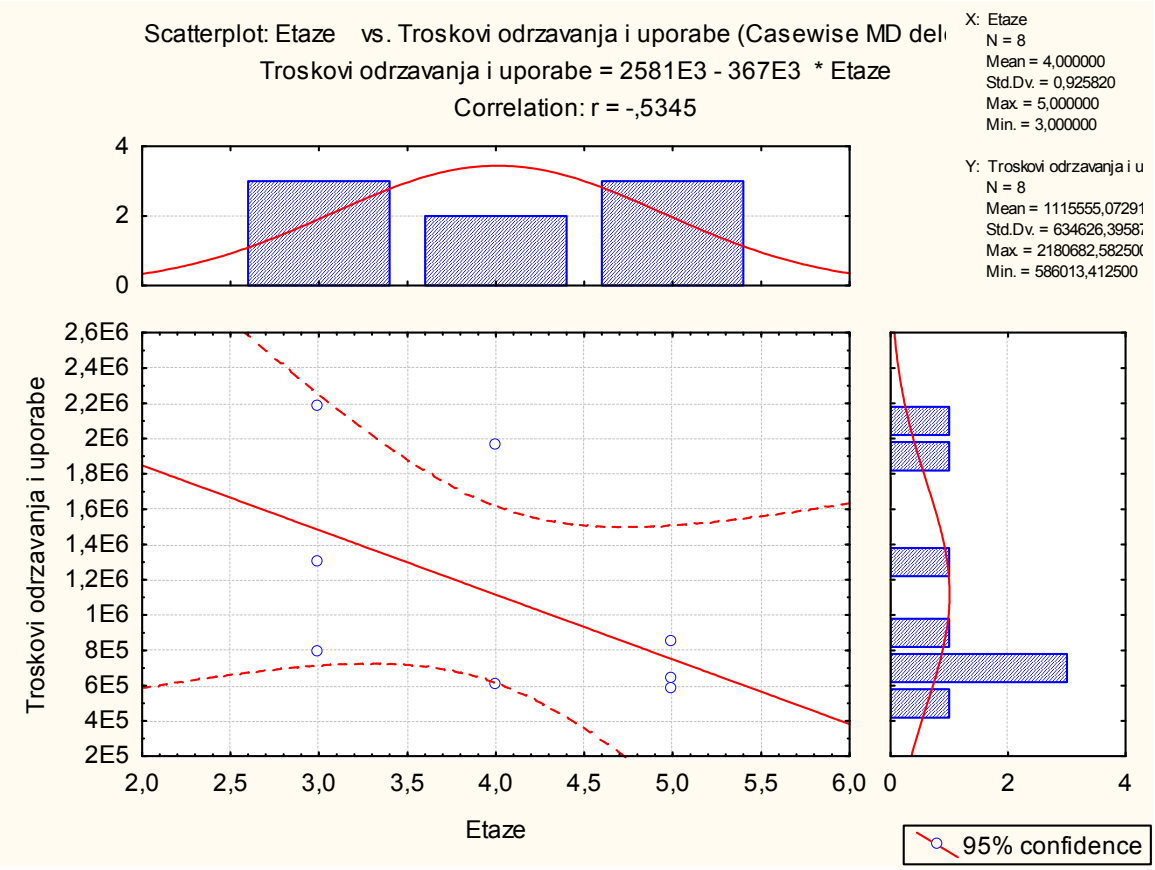
Scatterplot: Etaze vs. Troskovi odrzavanja i uporabe (Casewise MD del
Troskovi odrzavanja i uporabe = 2581E3 - 367E3 * Etaze
Correlation: r = -,5345
X: Etaze
N = 8
Mean = 4,000000
Std.Dv. = 0,925820
Max. = 5,000000
Min. = 3,000000
Y: Troskovi odrzavanja i u
N = 8
Mean = 1115555,07291
Std.Dv. = 634626,39587
Max. = 2180682,58250
Min. = 586013,412500
Troskovi odrzavanja i uporabe
Etaze
95% confidence

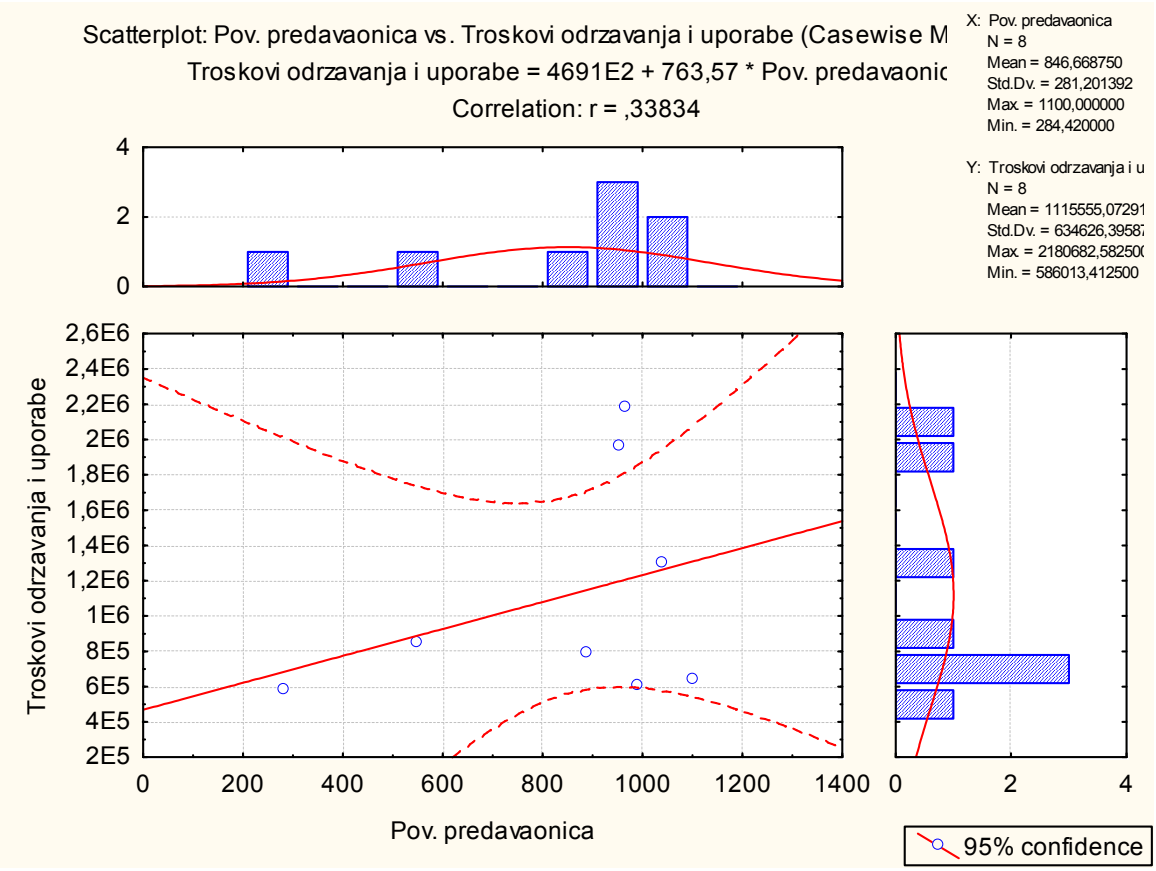
Scatterplot: Pov. predavaonica vs. Troskovi odrzavanja i uporabe (Casewise M
Troskovi odrzavanja i uporabe = 4691E2 + 763,57 * Pov. predavaonic
Correlation: r = ,33834
X: Pov. predavaonica
N = 8
Mean = 846,668750
Std.Dv. = 281,201392
Max. = 1100,000000
Min. = 284,420000
Y: Troskovi odrzavanja i u
N = 8
Mean = 1115555,07291
Std.Dv. = 634626,39587
Max. = 2180682,582500
Min. = 586013,412500
Troskovi odrzavanja i uporabe
Pov. predavaonica
95% confidence

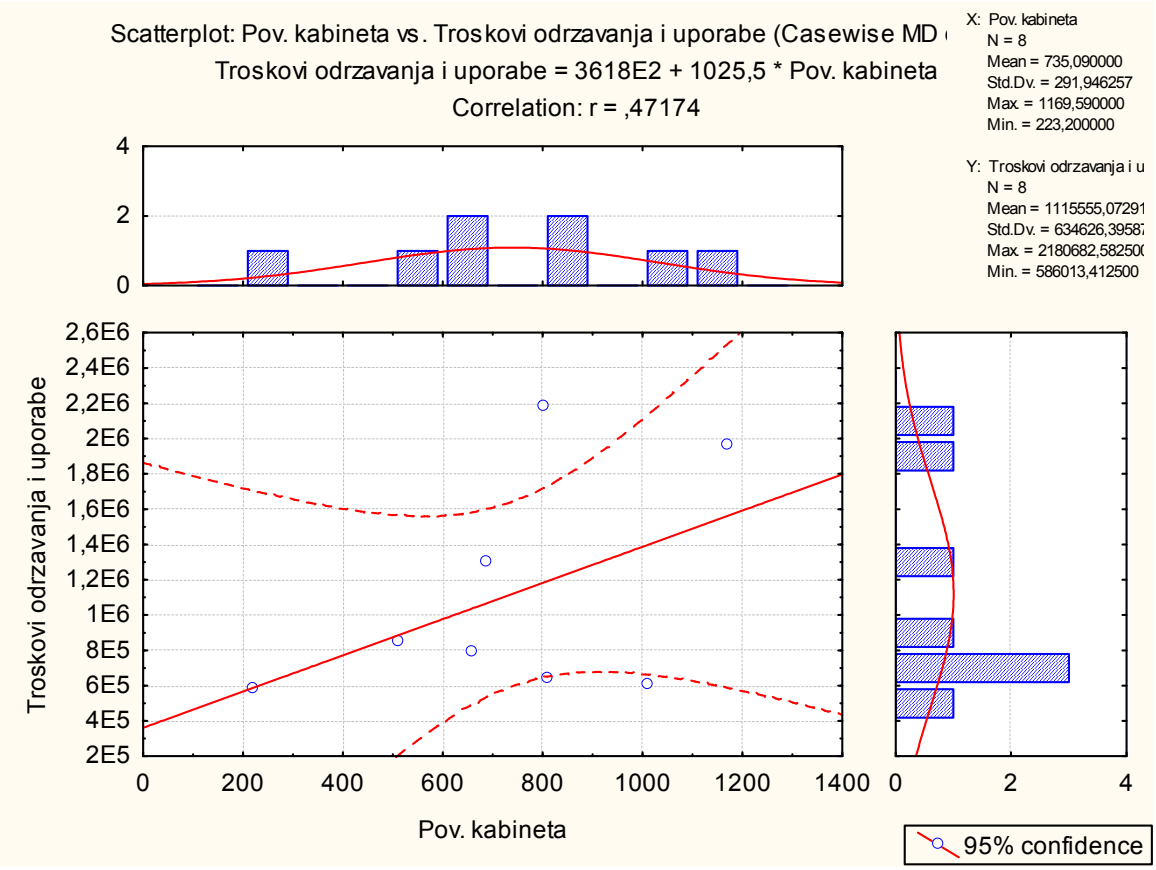
Scatterplot: Pov. kabineta vs. Troskovi odrzavanja i uporabe (Casewise MD
Troskovi odrzavanja i uporabe = 3618E2 + 1025,5 * Pov. kabineta
Correlation: r = ,47174
X: Pov. kabineta
N = 8
Mean = 735,090000
Std.Dv. = 291,946257
Max. = 1169,590000
Min. = 223,200000
Y: Troskovi odrzavanja i u
N = 8
Mean = 1115555,07291
Std.Dv. = 634626,39587
Max. = 2180682,582500
Min. = 586013,412500
Troskovi odrzavanja i uporabe
Pov. kabineta
95% confidence

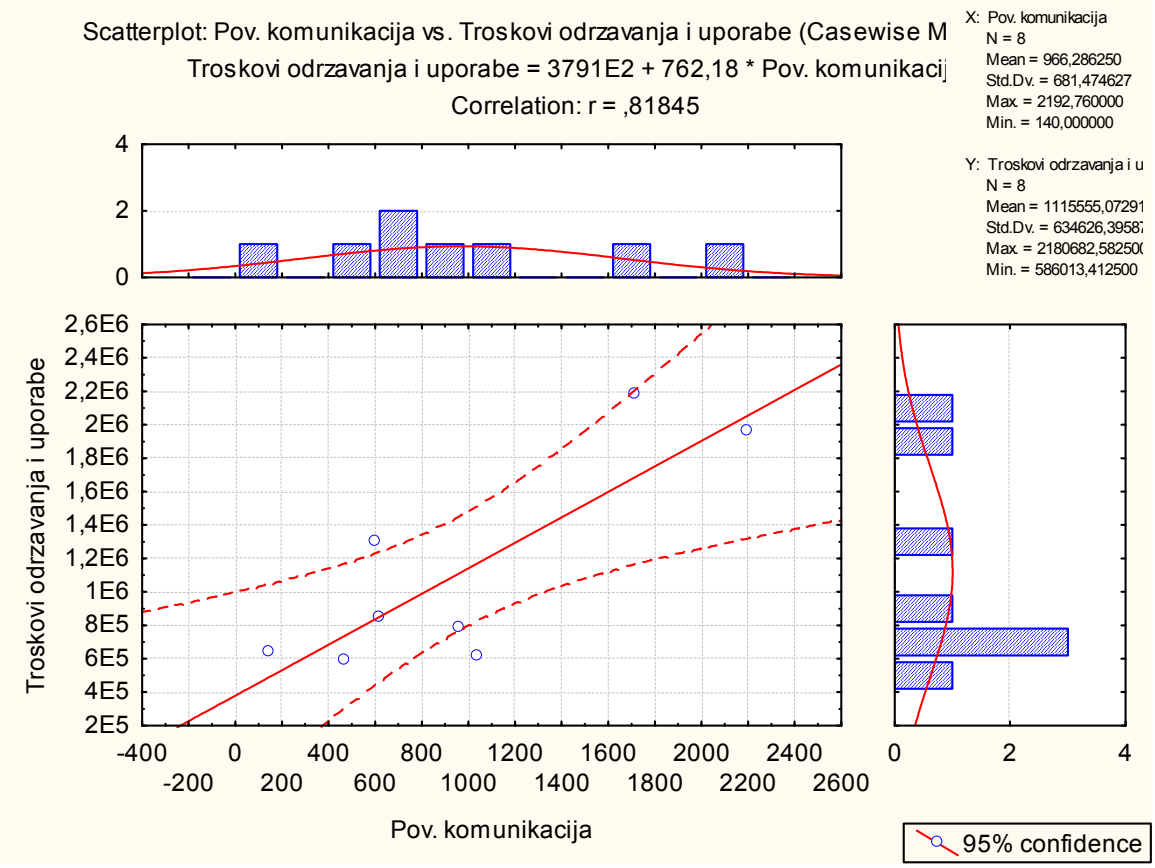
Scatterplot: Pov. komunikacija vs. Troskovi odrzavanja i uporabe (Casewise M
Troskovi odrzavanja i uporabe = 3791E2 + 762,18 * Pov. komunikacij
Correlation: r = ,81845
X: Pov. komunikacija
N = 8
Mean = 966,286250
Std.Dv. = 681,474627
Max. = 2192,760000
Min. = 140,000000
Y: Troskovi odrzavanja i u
N = 8
Mean = 1115555,07291
Std.Dv. = 634626,39587
Max. = 2180682,582500
Min. = 586013,412500
Troskovi odrzavanja i uporabe
Pov. komunikacija
95% confidence

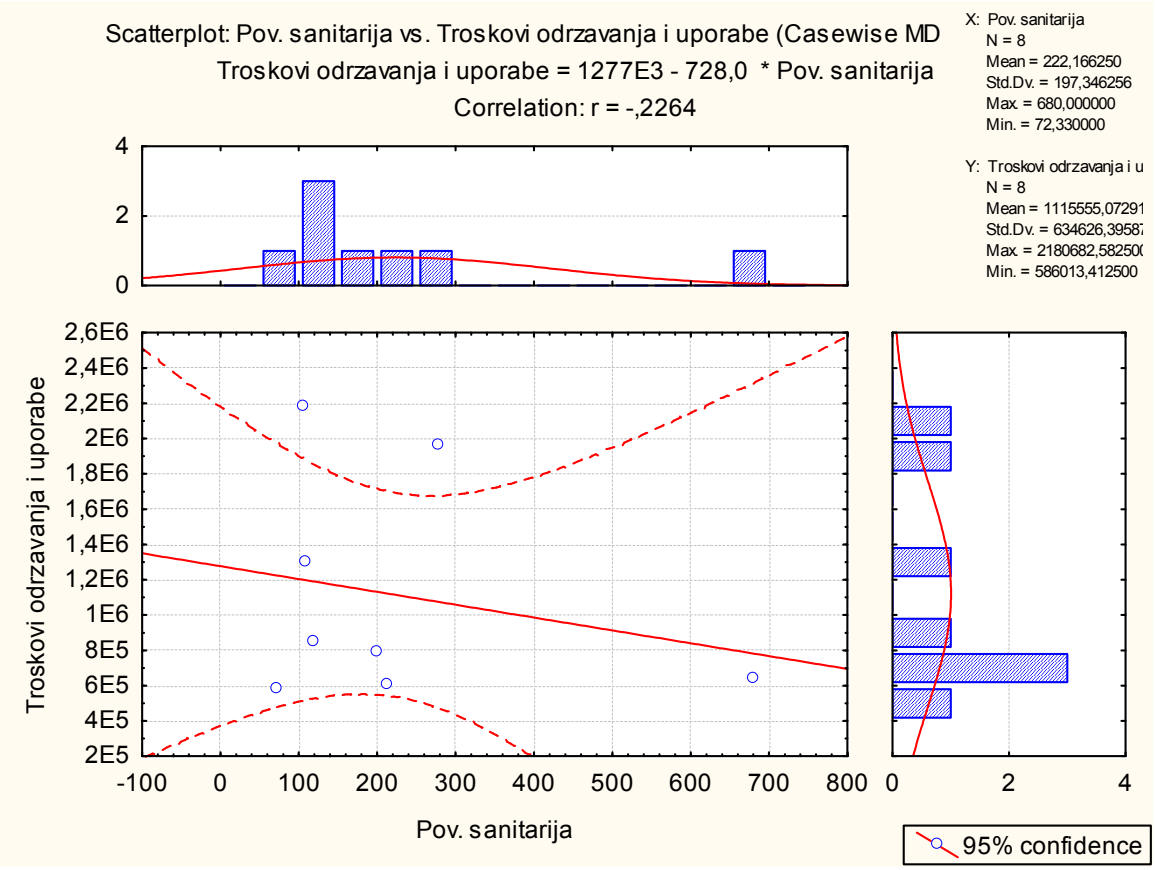
Scatterplot: Pov. sanitarija vs. Troskovi odrzavanja i uporabe (Casewise MD
Troskovi odrzavanja i uporabe = 1277E3 - 728,0 * Pov. sanitarija
Correlation: r = -,2264
X: Pov. sanitarija
N = 8
Mean = 222,166250
Std.Dv. = 197,346256
Max. = 680,000000
Min. = 72,330000
Y: Troskovi odrzavanja i u
N = 8
Mean = 1115555,07291
Std.Dv. = 634626,39587
Max. = 2180682,582500
Min. = 586013,412500
Troskovi odrzavanja i uporabe
Pov. sanitarija
95% confidence

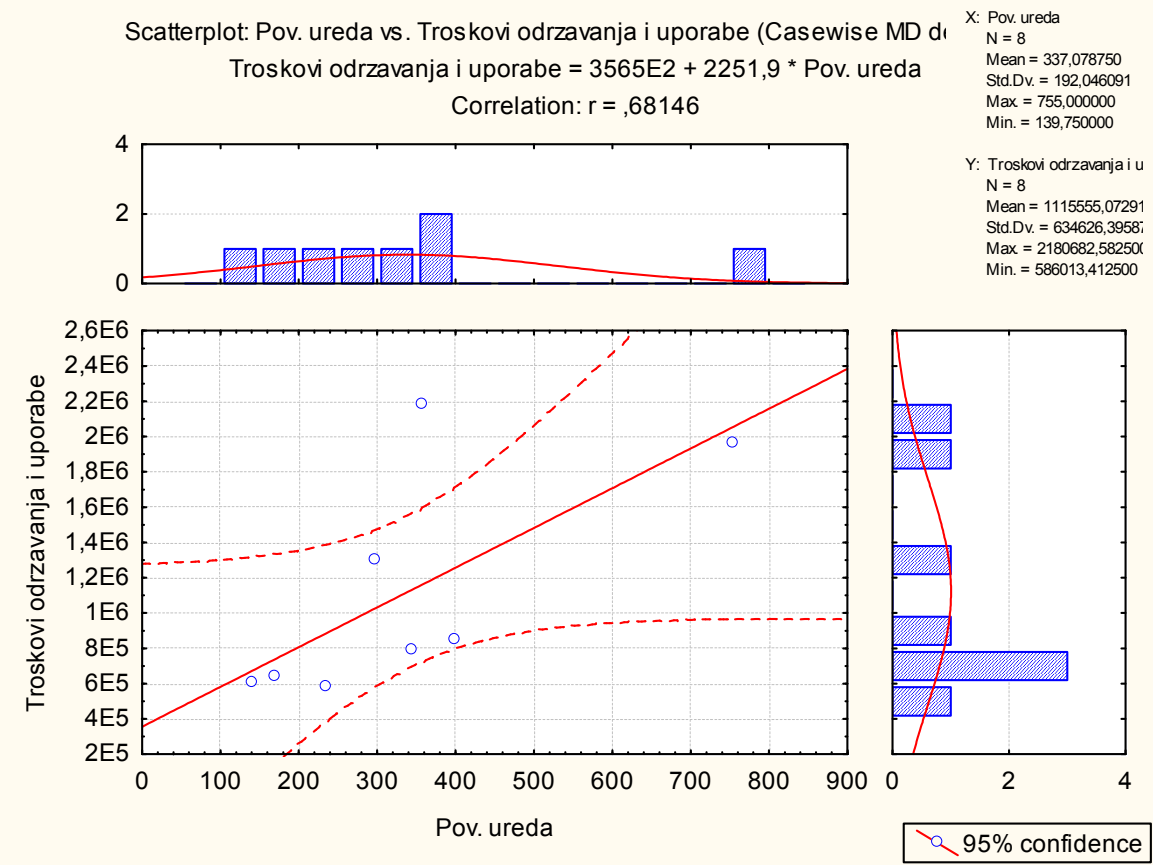
Scatterplot: Pov. ureda vs. Troskovi odrzavanja i uporabe (Casewise MD d
Troskovi odrzavanja i uporabe = 3565E2 + 2251,9 * Pov. ureda
Correlation: r = ,68146
X: Pov. ureda
N = 8
Mean = 337,078750
Std.Dv. = 192,046091
Max. = 755,000000
Min. = 139,750000
Y: Troskovi odrzavanja i u
N = 8
Mean = 1115555,07291
Std.Dv. = 634626,39587
Max. = 2180682,58250
Min. = 586013,412500
Troskovi odrzavanja i uporabe
Pov. ureda
95% confidence

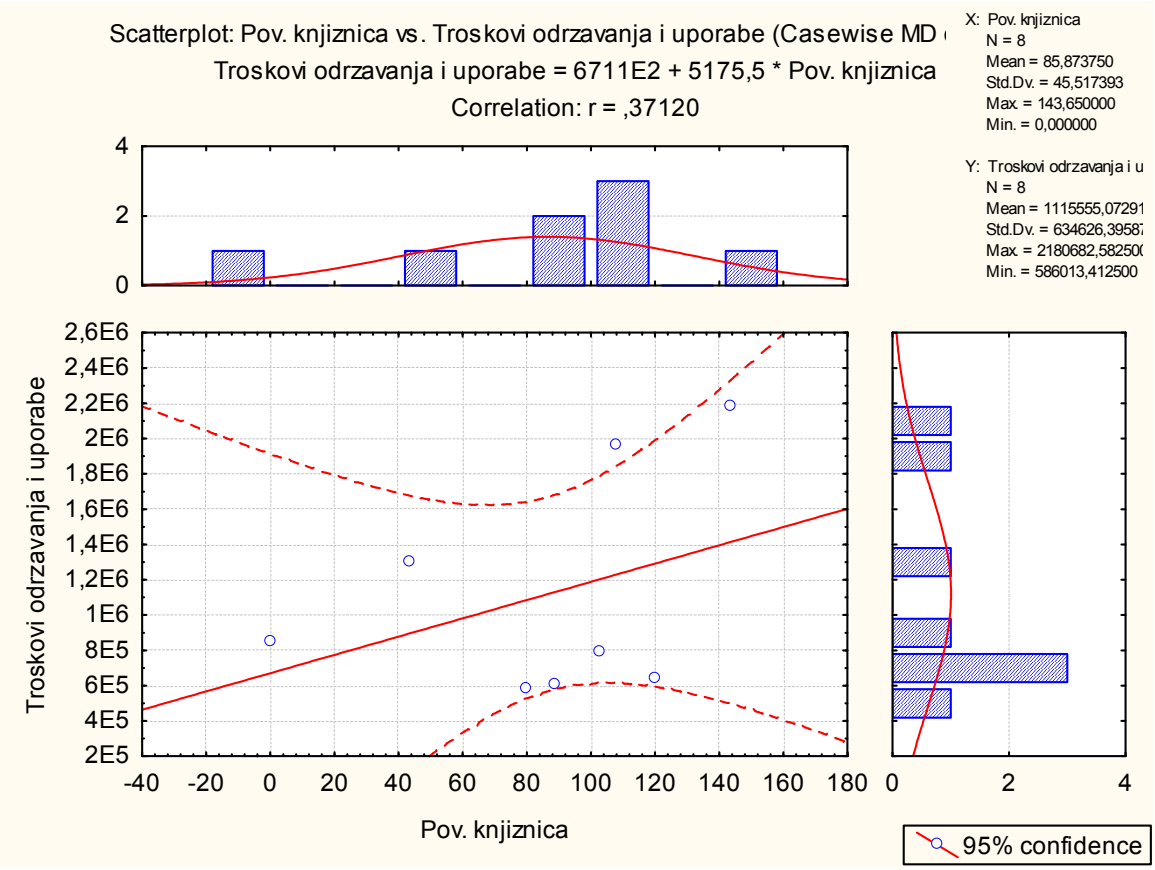
Scatterplot: Pov. knjiznica vs. Troskovi odrzavanja i uporabe (Casewise MD
Troskovi odrzavanja i uporabe = 6711E2 + 5175,5 * Pov. knjiznica
Correlation: r = ,37120
X: Pov. knjiznica
N = 8
Mean = 85,873750
Std.Dv. = 45,517393
Max. = 143,650000
Min. = 0,000000
Y: Troskovi odrzavanja i u
N = 8
Mean = 1115555,07291
Std.Dv. = 634626,39587
Max. = 2180682,58250
Min. = 586013,412500
Troskovi odrzavanja i uporabe
Pov. knjiznica
95% confidence

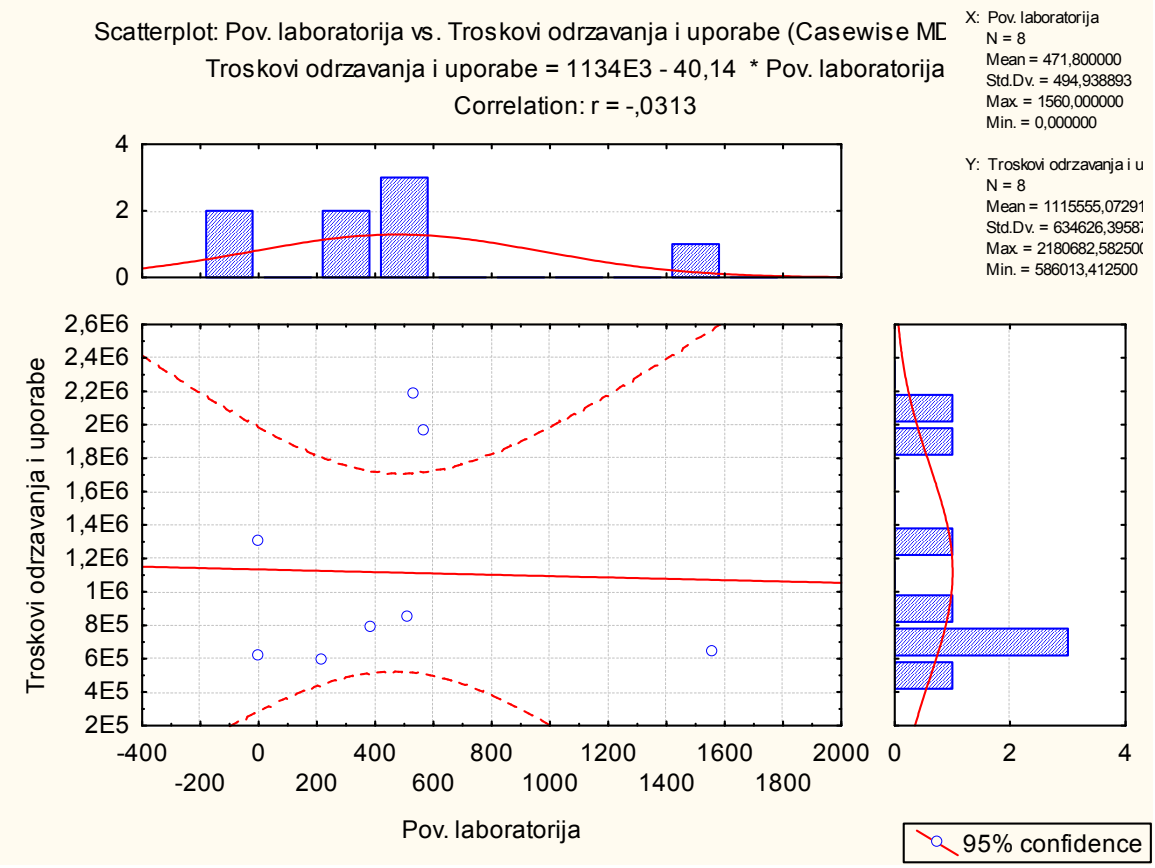
Scatterplot: Pov. laboratorija vs. Troskovi odrzavanja i uporabe (Casewise MD
Troskovi odrzavanja i uporabe = 1134E3 - 40,14 * Pov. laboratorija
Correlation: r = -,0313
X: Pov. laboratorija
N = 8
Mean = 471,800000
Std.Dv. = 494,938893
Max. = 1560,000000
Min. = 0,000000
Y: Troskovi odrzavanja i u
N = 8
Mean = 1115555,07291
Std.Dv. = 634626,39587
Max. = 2180682,582500
Min. = 586013,412500
Troskovi odrzavanja i uporabe
Pov. laboratorija
95% confidence

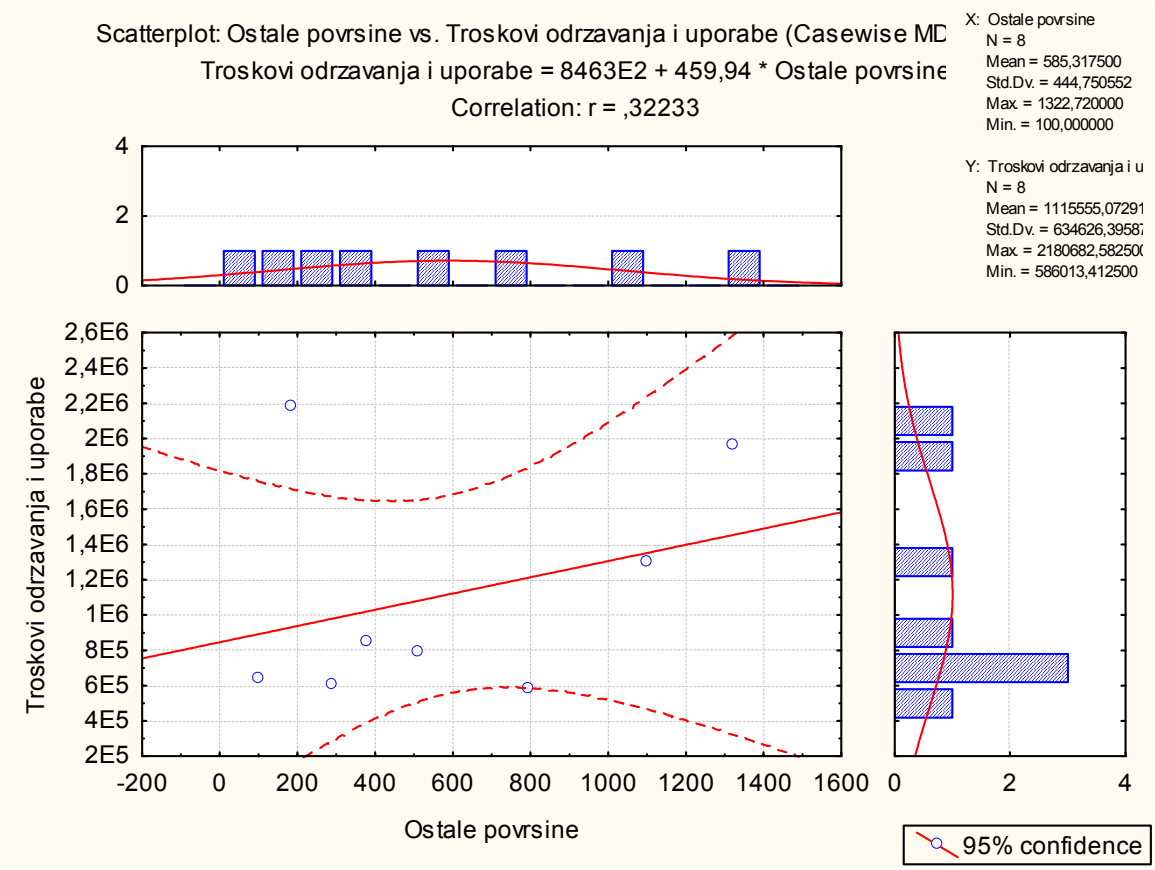
Scatterplot: Ostale povrsine vs. Troskovi odrzavanja i uporabe (Casewise MD
Troskovi odrzavanja i uporabe = 8463E2 + 459,94 * Ostale povrsine
Correlation: r = ,32233
X: Ostale povrsine
N = 8
Mean = 585,317500
Std.Dv. = 444,750552
Max. = 1322,720000
Min. = 100,000000
Y: Troskovi odrzavanja i u
N = 8
Mean = 1115555,07291
Std.Dv. = 634626,39587
Max. = 2180682,582500
Min. = 586013,412500
Troskovi odrzavanja i uporabe
Ostale povrsine
95% confidence

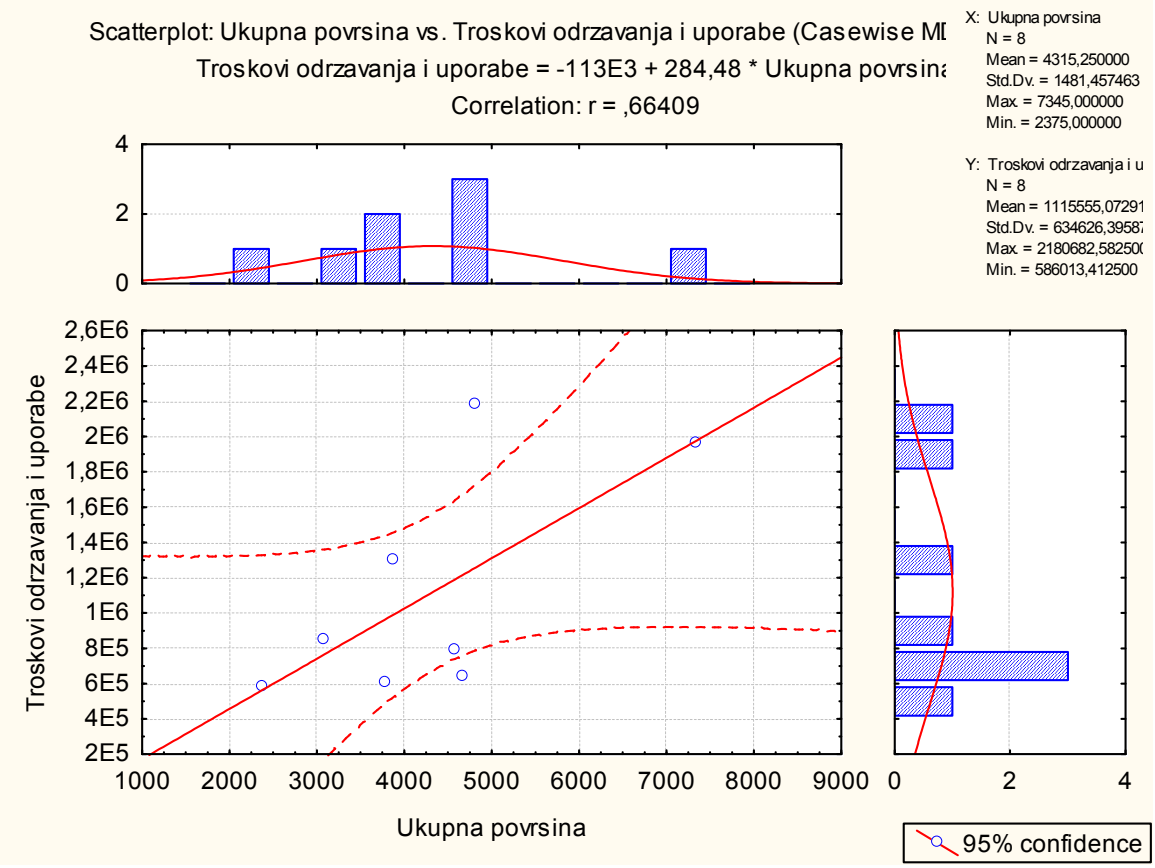
Scatterplot: Ukupna povrsina vs. Troskovi odrzavanja i uporabe (Casewise MI
Troskovi odrzavanja i uporabe = -113E3 + 284,48 * Ukupna povrsina
Correlation: r = ,66409
X: Ukupna povrsina
N = 8
Mean = 4315,250000
Std.Dv. = 1481,457463
Max. = 7345,000000
Min. = 2375,000000
Y: Troskovi odrzavanja i u
N = 8
Mean = 1115555,07291
Std.Dv. = 634626,39587
Max. = 2180682,582500
Min. = 586013,412500
Troskovi odrzavanja i uporabe
Ukupna povrsina
95% confidence

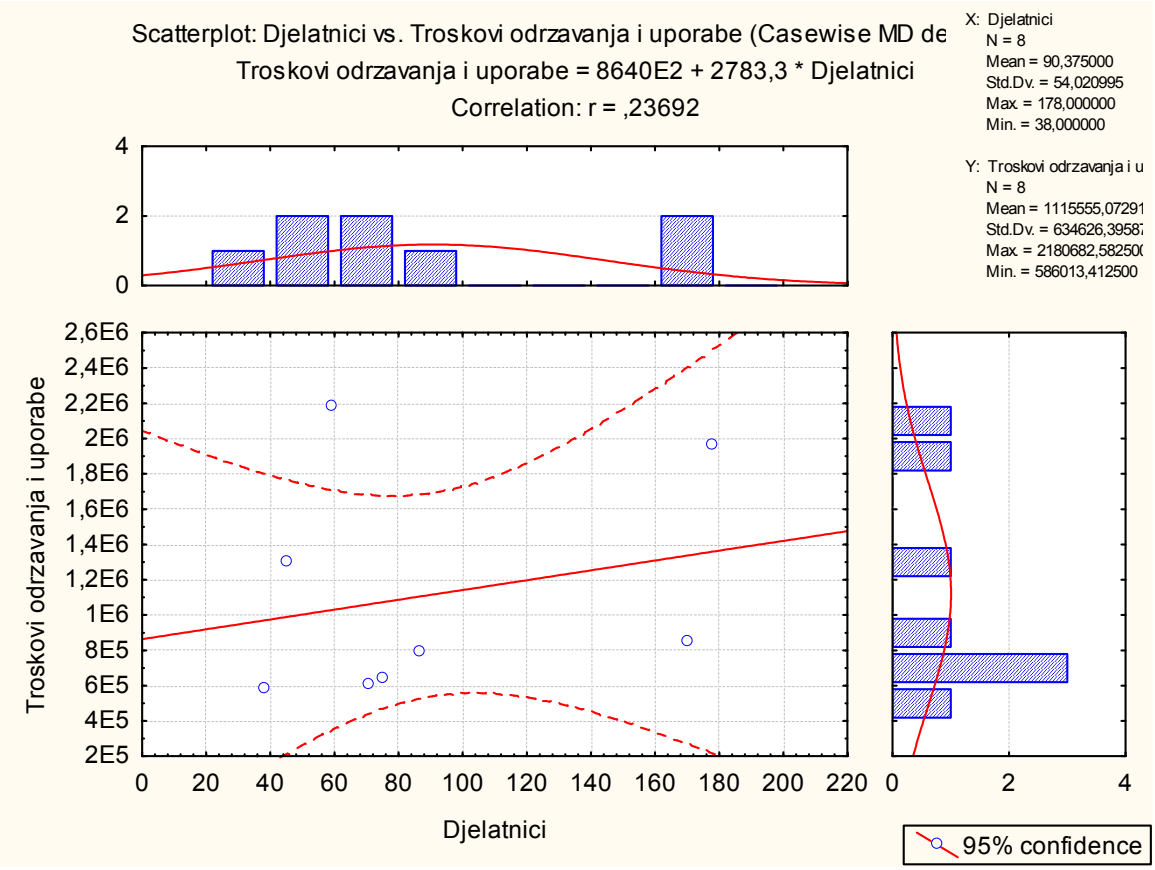
Scatterplot: Djelatnici vs. Troskovi odrzavanja i uporabe (Casewise MD de
Troskovi odrzavanja i uporabe = 8640E2 + 2783,3 * Djelatnici
Correlation: r = ,23692
X: Djelatnici
N = 8
Mean = 90,375000
Std.Dv. = 54,020995
Max. = 178,000000
Min. = 38,000000
Y: Troskovi odrzavanja i u
N = 8
Mean = 1115555,07291
Std.Dv. = 634626,39587
Max. = 2180682,582500
Min. = 586013,412500
Troskovi odrzavanja i uporabe
Djelatnici
95% confidence

Korelacija varijabli

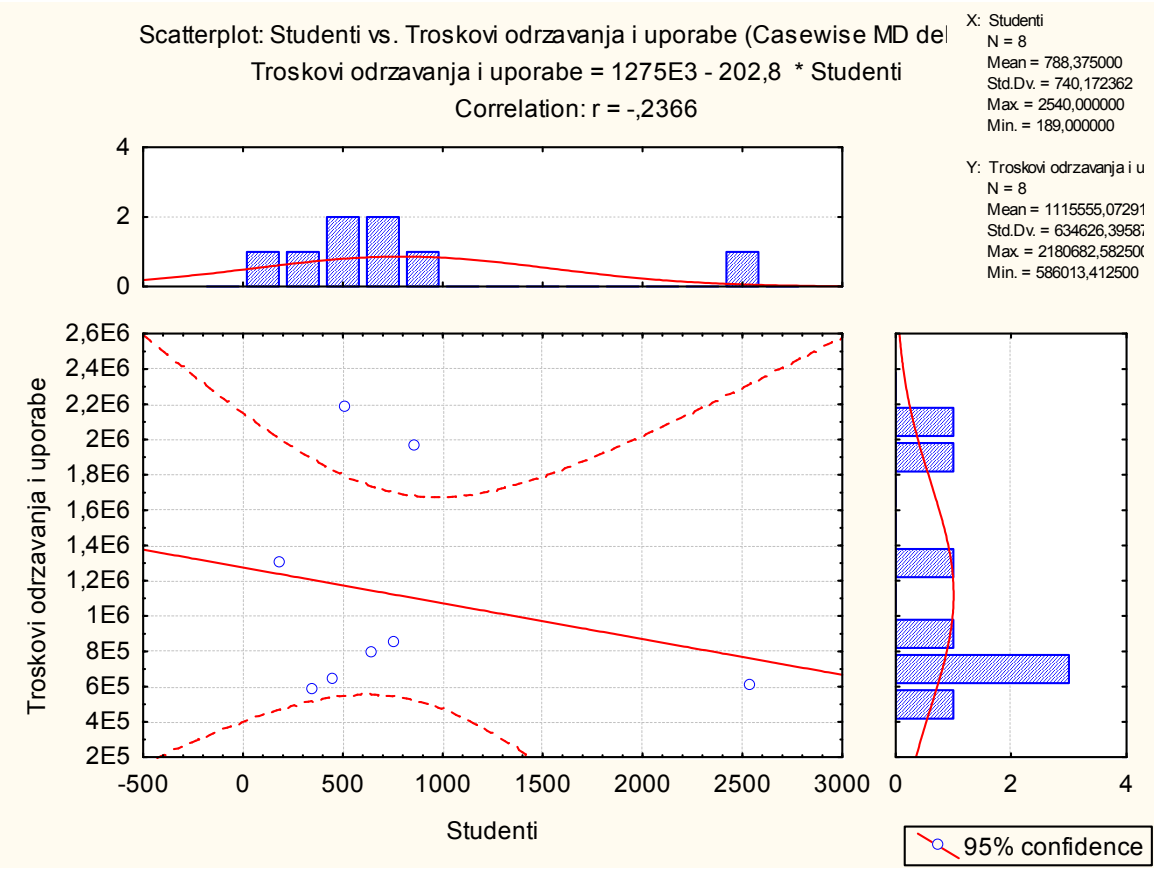

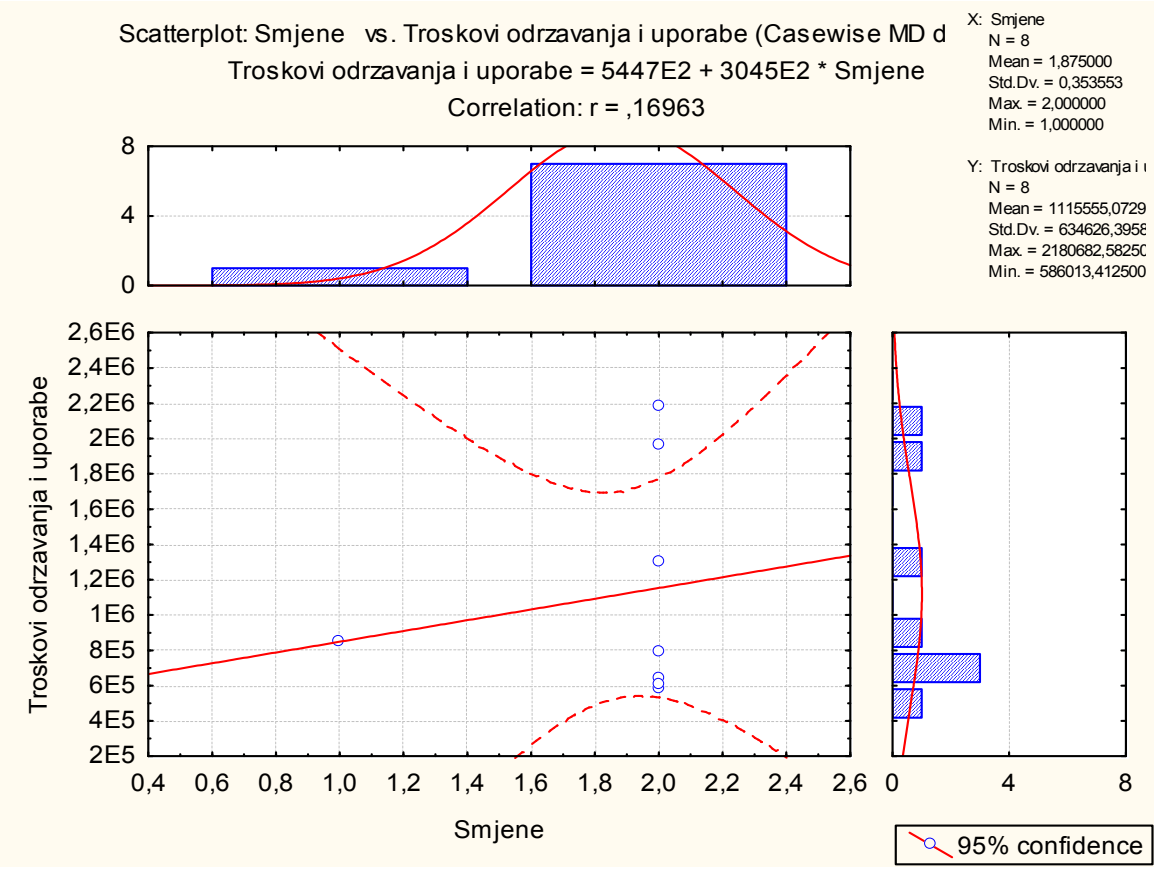

Effect	Collinearity statistics for terms in the equation (Podloga StatSoft 8 uzoraka) Sigma-restricted parameterization								
	Comment (B/Z/P)	Tolernce	Variance Infl fac	R square	Troskovi uporabe Beta in	Troskovi uporabe Partial	Troskovi uporabe Semi-par	Troskovi uporabe t	Troskovi uporabe p
Starost gradjevine		0,392677	2,546625	0,607323	*-0,148558*	*-1,00000*	*-0,093092*	*-75679*	*0,000008*
Ref. period		0,362894	2,755627	0,637106	*-0,058860*	*-1,00000*	*-0,035458*	*-28825*	*0,000022*
Pov. kabineta		0,528153	1,893390	0,471847	*0,002917*	*1,00000*	*0,002120*	*1723*	*0,000369*
Pov. ureda		0,187130	5,343875	0,812870	*-0,129256*	*-1,00000*	*-0,055914*	*-45455*	*0,000014*
Pov. laboratorija		0,645171	1,549977	0,354829	*-0,304635*	*-1,00000*	*-0,244691*	*-198921*	*0,000003*
Djelatnici		0,305696	3,271223	0,694304	*1,123206*	*1,00000*	*0,621018*	*504855*	*0,000001*

Collinearity statistics

Effect	Collinearity statistics for terms not in the equation (Podloga StatSoft 8 uzoraka) Sigma-restricted parameterization								
	Comment (B/Z/P)	Tolernce	Variance Infl fac	Minimum Tolernce	Troskovi uporabe	Troskovi uporabe Partial	Troskovi uporabe Semi-par	Troskovi uporabe t	Troskovi uporabe p
Broj godine uporabe	Pooled	0,010227	97,78	0,010227	0,000012	1,00015	0,000001		
Etaze	Pooled	0,101059	9,90	0,101059	0,000004	1,00015	0,000001		
Pov. predavaonica	Pooled	0,000028	35190,69	0,000022	0,000231	1,00015	0,000001		
Pov. komunikacija	Pooled	0,135122	7,40	0,069825	-0,000003	-1,00015	-0,000001		
Pov. sanitarija	Pooled	0,096795	10,33	0,096795	0,000004	1,00015	0,000001		
Pov. knjiznica	Pooled	0,090662	11,03	0,059182	-0,000004	-1,00015	-0,000001		
Ostale povrsine	Pooled	0,337438	2,96	0,121609	0,000002	1,00015	0,000001		
Ukupna povrsina	Pooled	0,000490	2039,39	0,000490	0,000056	1,00015	0,000001		
Studenti	Pooled	0,006312	158,42	0,006312	-0,000015	-1,00015	-0,000001		
Smjene	Pooled	0,039177	25,53	0,021519	0,000006	1,00015	0,000001		

Effect	Collinearity statistics for terms in the equation (Podloga StatSoft 8 uzoraka) (*Zeroed predictors failed tolerance check) Sigma-restricted parameterization								
	Comment (B/Z/P)	Tolernce	Variance Infl fac	R square	Troskovi uporabe Beta in	Troskovi uporabe Partial	Troskovi uporabe Semi-par	Troskovi uporabe t	Troskovi uporabe p
Starost gradjevine		0,024686	40,5089	0,975314					
Broj godine uporabe		0,006309	158,5078	0,993691					
Ref. period		0,008927	112,0226	0,991073					
Etaze		0,007162	139,6218	0,992838					
Pov. predavaonica		0,002841	351,9412	0,997159					
Pov. kabineta		0,001625	615,2979	0,998375					
Pov. komunikacija		0,004172	239,6663	0,995828					
Pov. sanitarija	Zeroed*	0,000000							
Pov. ureda	Zeroed*	0,000000							
Pov. knjiznica	Biased	-0,000000							
Pov. laboratorija	Biased	-0,000000							
Ostale povrsine	Biased	-0,000000							
Ukupna povrsina	Biased	-0,000000							
Djelatnici	Biased	-0,000000							
Studenti	Zeroed*	0,000000							
Smjene	Biased	-0,000000							

Effect	Collinearity statistics for terms in the equation (Podloga StatSoft 8 uzoraka) Sigma-restricted parameterization								
	Comment (B/Z/P)	Tolernce	Variance Infl fac	R square	Troskovi odrzavanja i uporabe Beta in	Troskovi odrzavanja i uporabe Partial	Troskovi odrzavanja i uporabe Semi-par	Troskovi odrzavanja i uporabe t	Troskovi odrzavanja i uporabe p
Starost gradjevine		0,317322	3,151370	0,682678	*-0,631676*	*-1,00000*	*-0,355832*	*-7762,36*	*0,000082*
Etaze		0,432708	2,311028	0,567292	*-0,449903*	*-1,00000*	*-0,295949*	*-6456,02*	*0,000099*
Pov. komunikacija		0,210661	4,746965	0,789339	*0,824489*	*1,00000*	*0,378422*	*8255,16*	*0,000077*
Pov. laboratorija		0,281270	3,555301	0,718730	*0,029128*	*1,00000*	*0,015448*	*337,00*	*0,001889*
Ukupna povrsina		0,127332	7,853499	0,872668	*0,319701*	*1,00000*	*0,114081*	*2488,63*	*0,000256*
Studenti		0,791405	1,263576	0,208595	*-0,353469*	*-1,00000*	*-0,314449*	*-6859,61*	*0,000093*

Effect	Collinearity statistics for terms not in the equation (Podloga StatSoft 8 uzoraka) Sigma-restricted parameterization								
	Comment (B/Z/P)	Tolernce	Variance Infl fac	Minimum Tolernce	Troskovi odrzavanja i uporabe	Troskovi odrzavanja i uporabe Partial	Troskovi odrzavanja i uporabe Semi-par	Troskovi odrzavanja i uporabe t	Troskovi odrzavanja i uporabe p
Broj godine uporabe	Pooled	0,033056	30	0,030086	0,000252	1,000000	0,000046		
Ref. period	Pooled	0,116538	9	0,098723	0,000134	1,000000	0,000046		
Pov. predavaonica	Pooled	0,000511	1956	0,000313	0,002028	1,000000	0,000046		
Pov. kabineta	Pooled	0,000001	1604221	0,000000	-0,058061	-1,000000	-0,000046		
Pov. sanitarija	Pooled	0,020681	48	0,020681	0,000319	1,000000	0,000046		
Pov. ureda	Pooled	0,093967	11	0,080617	-0,000150	-1,000000	-0,000046		
Pov. knjiznica	Pooled	0,399168	3	0,109378	0,000073	1,000000	0,000046		
Ostale povrsine	Pooled	0,007053	142	0,002673	0,000546	1,000000	0,000046		
Djelatnici	Pooled	0,461565	2	0,118854	-0,000067	-1,000000	-0,000046		
Smjene	Pooled	0,698688	1	0,124679	0,000055	1,000000	0,000046		

Effect	Collinearity statistics for terms in the equation (Podloga StatSoft 8 uzoraka) (*Zeroed predictors failed tolerance check) Sigma-restricted parameterization								
	Comment (B/Z/P)	Tolernce	Variance Infl fac	R square	Troskovi odrzavanja i uporabe Beta in	Troskovi odrzavanja i uporabe Partial	Troskovi odrzavanja i uporabe Semi-par	Troskovi odrzavanja i uporabe t	Troskovi odrzavanja i uporabe p
Starost gradjevine		0,024686	40,5089	0,975314					
Broj godine uporabe		0,006309	158,5078	0,993691					
Ref. period		0,008927	112,0226	0,991073					
Etaze		0,007162	139,6218	0,992838					
Pov. predavaonica		0,002841	351,9412	0,997159					
Pov. kabineta		0,001625	615,2979	0,998375					
Pov. komunikacija		0,004172	239,6663	0,995828					
Pov. sanitarija	Zeroed*	0,000000							
Pov. ureda	Zeroed*	0,000000							
Pov. knjiznica	Biased	-0,000000							
Pov. laboratorija	Biased	-0,000000							
Ostale povrsine	Biased	-0,000000							
Ukupna povrsina	Biased	-0,000000							
Djelatnici	Biased	-0,000000							
Studenti	Zeroed*	0,000000							
Smjene	Biased	-0,000000							

Variable	Descriptive Statistics (Podloga za StatSoft 8 uzoraka) (Casewise Deletion of Missing Data)										
	Valid N	% Valid obs.	Mean	Geometric Mean	Harmonic Mean	Median	Mode	Frequency of Mode	Sum	Minimum	Maximum
Starost gradjevine	8,00	100,00	123,00	84,78	46,29	109,00	Multiple	1,00	984,00	10,00	293,00
Broj godine uporabe	8,00	100,00	14,13	11,77	9,83	11,50	13,00000	2,00	113,00	4,00	33,00
Ref. period	8,00	100,00	8,75	8,28	7,74	9,00	Multiple	2,00	70,00	4,00	12,00
Etaze	8,00	100,00	4,00	3,90	3,81	4,00	Multiple	3,00	32,00	3,00	5,00
Pov. predavaonica	8,00	100,00	846,67	785,65	700,35	959,47	Multiple	1,00	6773,35	284,42	1100,00
Pov. kabineta	8,00	100,00	735,09	668,85	582,92	747,00	Multiple	1,00	5880,72	223,20	1169,59
Pov. komunikacija	8,00	100,00	966,29	741,22	512,63	788,50	Multiple	1,00	7730,29	140,00	2192,76
Pov. sanitarija	8,00	100,00	222,17	172,95	143,85	160,00	Multiple	1,00	1777,33	72,33	680,00
Pov. ureda	8,00	100,00	337,08	297,40	264,78	320,77	Multiple	1,00	2696,63	139,75	755,00
Pov. knjiznica	8,00	100,00	85,87			95,87	Multiple	1,00	686,99	0,00	143,65
Pov. laboratorija	8,00	100,00	471,80			448,00	0,000000	2,00	3774,40	0,00	1560,00
Ostale povrsine	8,00	100,00	585,32	431,08	302,67	446,50	Multiple	1,00	4682,54	100,00	1322,72
Ukupna povrsina	8,00	100,00	4315,25	4108,46	3914,00	4227,00	Multiple	1,00	34522,00	2375,00	7345,00
Djelatnici	8,00	100,00	90,38	78,31	69,03	73,00	Multiple	1,00	723,00	38,00	178,00
Studenti	8,00	100,00	788,38	598,05	477,83	583,00	Multiple	1,00	6307,00	189,00	2540,00
Smjene	8,00	100,00	1,88	1,83	1,78	2,00	2,000000	7,00	15,00	1,00	2,00
Troskovi uporabe	8,00	100,00	466983,82	451181,30	437916,38	410088,37	Multiple	1,00	3735870,60	349526,83	720453,33
Troskovi odrzavanja i uporabe	8,00	100,00	1115555,07	981478,04	881308,56	820671,17	Multiple	1,00	8924440,58	586013,41	2180682,58

Variable	Descriptive Statistics (Podloga za StatSoft 8 uzoraka) (Casewise Deletion of Missing Data)									
	Lower Quartile	Upper Quartile	Percentile 10,00000	Percentile 90,00000	Range	Quartile Range	Variance	Std.Dev.	Confidence SD -95,000%	Confidence SD +95,000%
Starost gradjevine	52,50	179,00	10,00	293,00	283,00	126,50	9498,86	97,46	64,44	198,36
Broj godine uporabe	8,50	18,00	4,00	33,00	29,00	9,50	88,70	9,42	6,23	19,17
Ref. period	7,00	11,00	4,00	12,00	8,00	4,00	7,93	2,82	1,86	5,73
Etaze	3,00	5,00	3,00	5,00	2,00	2,00	0,86	0,93	0,61	1,88
Pov. predavaonica	720,00	1015,00	284,42	1100,00	815,58	295,00	79074,22	281,20	185,92	572,32
Pov. kabineta	585,50	911,47	223,20	1169,59	946,39	325,97	85232,62	291,95	193,03	594,19
Pov. komunikacija	534,53	1375,74	140,00	2192,76	2052,76	841,21	464407,67	681,47	450,57	1386,99
Pov. sanitarija	107,00	245,50	72,33	680,00	607,67	138,50	38945,54	197,35	130,48	401,65
Pov. ureda	201,81	378,36	139,75	755,00	615,25	176,55	36881,70	192,05	126,98	390,87
Pov. knjiznica	61,80	114,00	0,00	143,65	143,65	52,20	2071,83	45,52	30,09	92,64
Pov. laboratorija	109,54	549,66	0,00	1560,00	1560,00	440,12	244964,51	494,94	327,24	1007,34
Ostale povrsine	236,13	947,29	100,00	1322,72	1222,72	711,16	197803,05	444,75	294,06	905,19
Ukupna povrsina	3432,50	4741,50	2375,00	7345,00	4970,00	1309,00	2194716,21	1481,46	979,50	3015,17
Djelatnici	52,00	128,50	38,00	178,00	140,00	76,50	2918,27	54,02	35,72	109,95
Studenti	398,50	807,50	189,00	2540,00	2351,00	409,00	547855,12	740,17	489,38	1506,45
Smjene	2,00	2,00	1,00	2,00	1,00	0,00	0,13	0,35	0,23	0,72
Troskovi uporabe	368298,97	554557,88	349526,83	720453,33	370926,50	186258,91	19456067017,02	139485,01	92223,88	283889,94
Troskovi odrzavanja i uporabe	626417,67	1631783,45	586013,41	2180682,58	1594669,17	1005365,77	402750662345,37	634626,40	419598,57	1291637,39

Variable	Descriptive Statistics (Podloga za StatSoft 8 uzoraka) (Casewise Deletion of Missing Data)					
	Coef.Var.	Standard Error	Skewness	Std.Err. Skewness	Kurtosis	Std.Err. Kurtosis
Starost gradjevine	79,24	34,46	0,92	0,75	-0,13	1,48
Broj godine uporabe	66,68	3,33	1,36	0,75	1,46	1,48
Ref. period	32,18	1,00	-0,48	0,75	-0,56	1,48
Etaze	23,15	0,33	0,00	0,75	-2,10	1,48
Pov. predavaonica	33,21	99,42	-1,49	0,75	1,35	1,48
Pov. kabineta	39,72	103,22	-0,32	0,75	0,43	1,48
Pov. komunikacija	70,53	240,94	0,89	0,75	0,08	1,48
Pov. sanitarija	88,83	69,77	2,20	0,75	5,25	1,48
Pov. ureda	56,97	67,90	1,61	0,75	3,40	1,48
Pov. knjiznica	53,01	16,09	-0,93	0,75	0,73	1,48
Pov. laboratorija	104,90	174,99	1,67	0,75	3,70	1,48
Ostale povrsine	75,98	157,24	0,72	0,75	-0,88	1,48
Ukupna povrsina	34,33	523,77	1,09	0,75	2,28	1,48
Djelatnici	59,77	19,10	1,09	0,75	-0,39	1,48
Studenti	93,89	261,69	2,35	0,75	6,07	1,48
Smjene	18,86	0,13	-2,83	0,75	8,00	1,48
Troskovi uporabe	29,87	49315,40	1,26	0,75	0,12	1,48
Troskovi odrzavanja i uporabe	56,89	224374,31	1,03	0,75	-0,65	1,48

Summary: Starost gradjevine

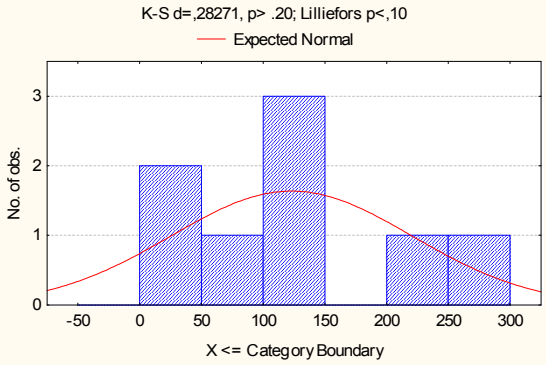

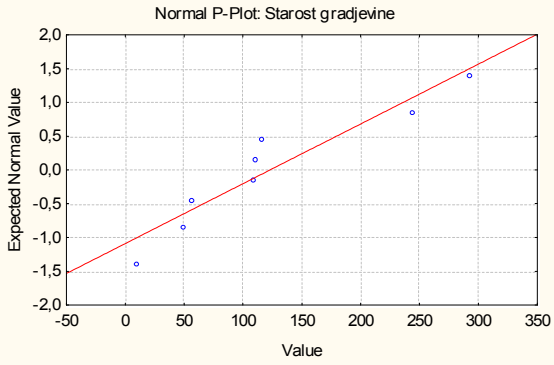

Summary Statistics:Starost gradjevine
Valid N=8
% Valid obs.=100,000000
Mean=123,000000
Geometric Mean= 84,780610
Harmonic Mean= 46,285764
Median=109,000000
Mode= 1,000000
Frequency of Mode= 1,000000
Sum=984,000000
Minimum= 10,000000
Maximum=293,000000
Lower Quartile= 52,500000
Upper Quartile=179,000000
Range=283,000000
Quartile Range=126,500000
Variance=9498,857143
Std.Dev.= 97,462081

Coef.Var.= 79,237464
Skewness= 0,922988
Kurtosis= -0,127958

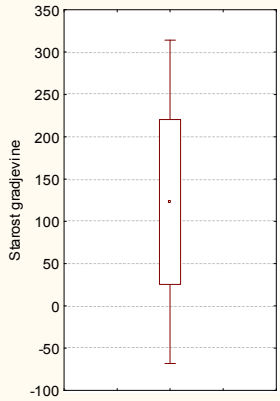

Summary: Broj godine uporabe

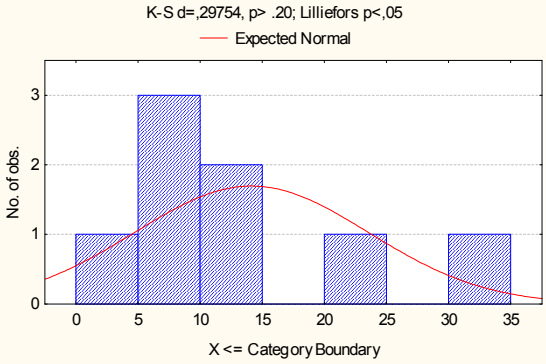

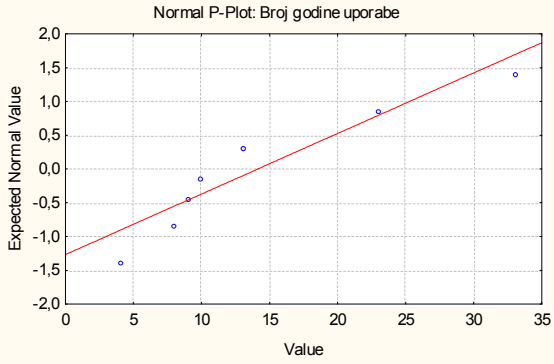

Summary Statistics:Broj godine uporabe
Valid N=8
% Valid obs.=100,000000
Mean= 14,125000
Geometric Mean= 11,774436
Harmonic Mean= 9,831167
Median= 11,500000
Mode= 1,000000
Frequency of Mode= 2,000000
Sum=113,000000
Minimum= 4,000000
Maximum= 33,000000
Lower Quartile= 8,500000
Upper Quartile= 18,000000
Range= 29,000000

Coef.Var.= 66,675243
Skewness= 1,356325
Kurtosis= 1,464132

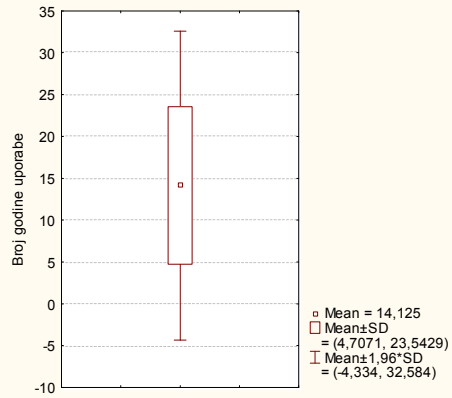

Summary: Ref. period

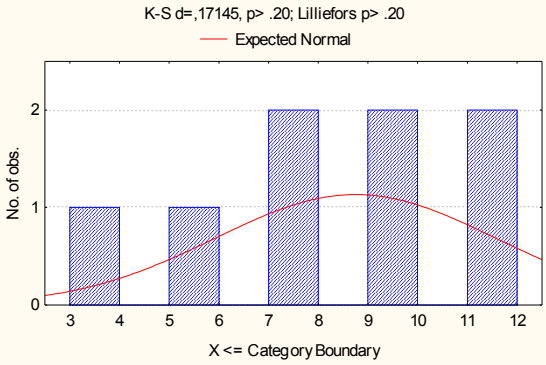

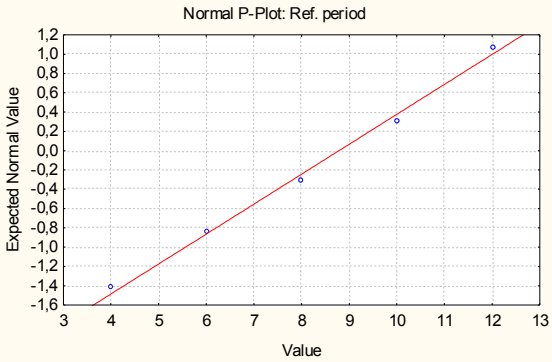

Summary Statistics: Ref. period

Valid N=8	Coef.Var.= 32,180250
% Valid obs.=100,000000	Skewness= -0,479922
Mean= 8,750000	Kurtosis= -0,564500
Geometric Mean= 8,281218	
Harmonic Mean= 7,741935	
Median= 9,000000	
Mode= 1,000000	
Frequency of Mode= 2,000000	
Sum= 70,000000	
Minimum= 4,000000	
Maximum= 12,000000	
Lower Quartile= 7,000000	
Upper Quartile= 11,000000	
Range= 8,000000	

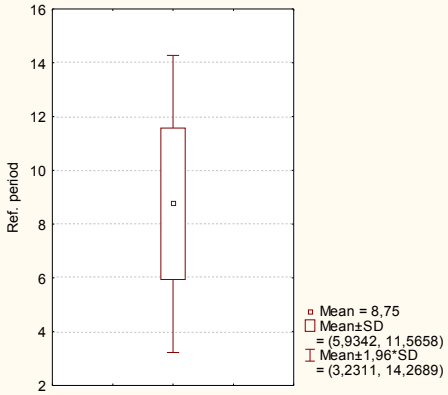

Summary: Etaze

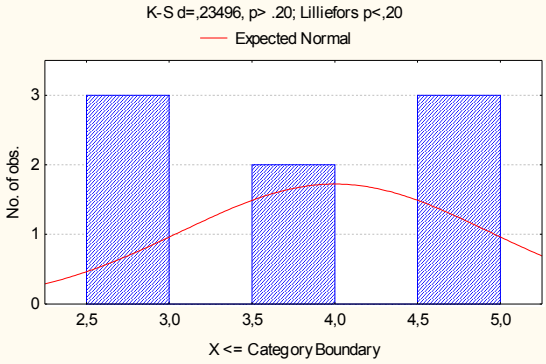

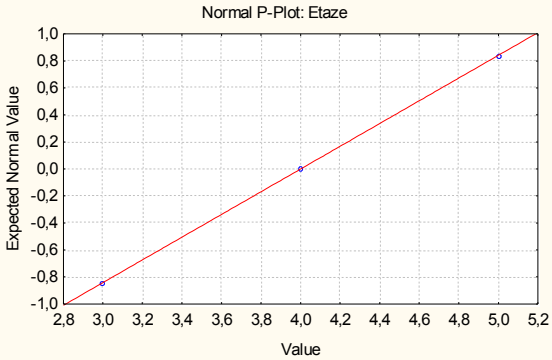

Summary Statistics: Etaze

Valid N=8	Coef.Var.= 23,145502
% Valid obs.=100,000000	Skewness= -0,000000
Mean= 4,000000	Kurtosis= -2,100000
Geometric Mean= 3,904354	
Harmonic Mean= 3,809524	
Median= 4,000000	
Mode= 1,000000	
Frequency of Mode= 3,000000	
Sum= 32,000000	
Minimum= 3,000000	
Maximum= 5,000000	
Lower Quartile= 3,000000	
Upper Quartile= 5,000000	
Range= 2,000000	

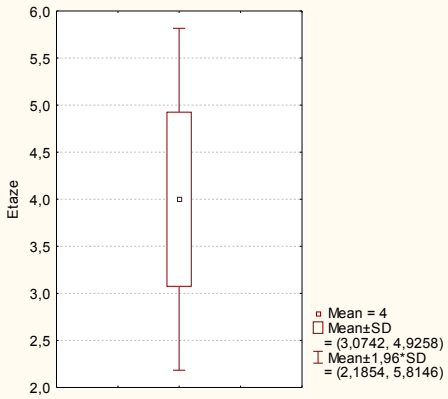

Summary: Pov. predavaonica

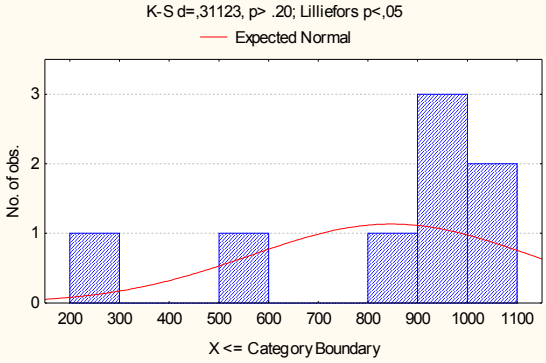

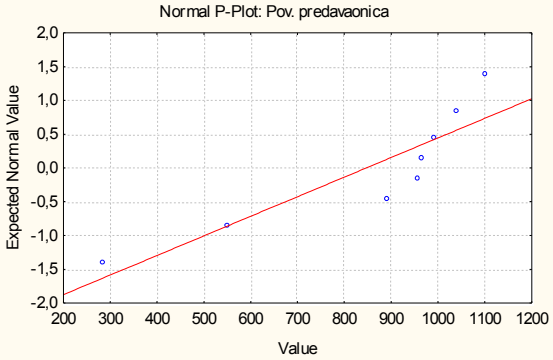

Summary Statistics: Pov. predavaonica

Valid N=8	Coef.Var.= 33,212681
% Valid obs.=100,000000	Skewness= -1,494808
Mean=846,668750	Kurtosis= 1,347278
Geometric Mean=785,651272	
Harmonic Mean=700,347193	
Median=959,465000	
Mode= 1,000000	
Frequency of Mode= 1,000000	
Sum=6773,350000	
Minimum=284,420000	
Maximum=1100,000000	
Lower Quartile=720,000000	
Upper Quartile=1015,000000	
Range=815,580000	

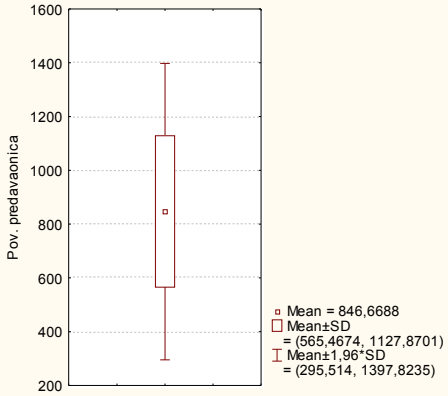

Summary: Pov. kabineta

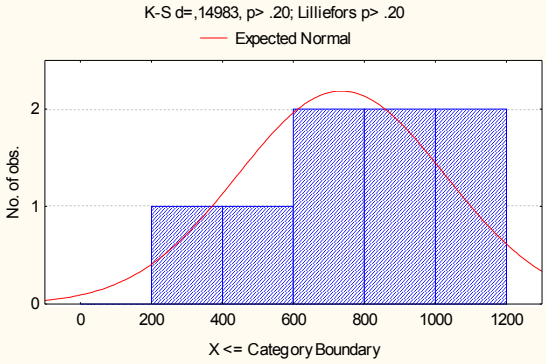

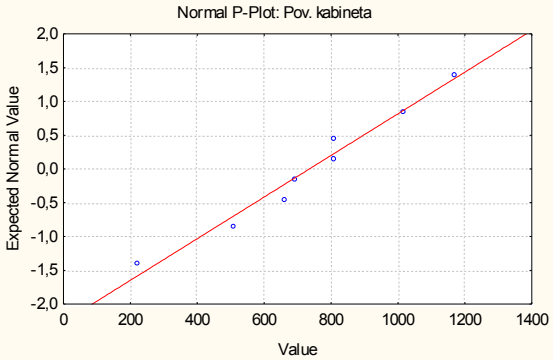

Summary Statistics: Pov. kabineta

Valid N=8	Coef.Var.= 39,715716
% Valid obs.=100,000000	Skewness= -0,320006
Mean=735,090000	Kurtosis= 0,429227
Geometric Mean=668,852858	
Harmonic Mean=582,922973	
Median=746,995000	
Mode= 1,000000	
Frequency of Mode= 1,000000	
Sum=5880,720000	
Minimum=223,200000	
Maximum=1169,590000	
Lower Quartile=585,500000	
Upper Quartile=911,470000	
Range=946,390000	

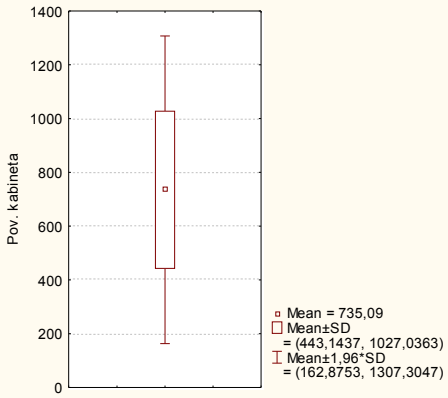

Summary: Pov. komunikacija

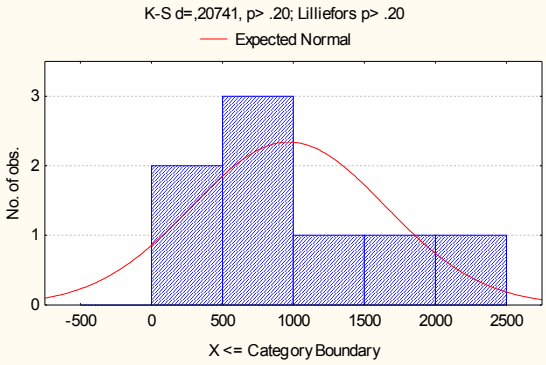

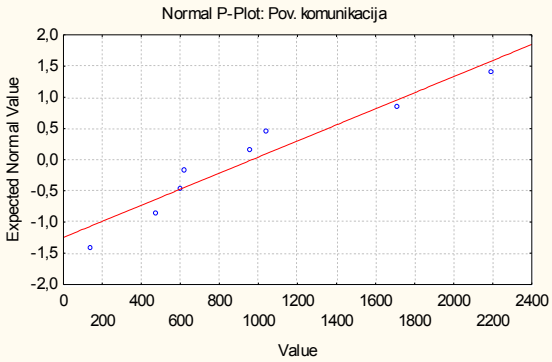

Summary Statistics:Pov. komunikacija

Valid N=8	Coef.Var.= 70,525129
% Valid obs.=100,000000	Skewness= 0,891908
Mean=966,286250	Kurtosis= 0,080268
Geometric Mean=741,223092	
Harmonic Mean=512,629181	
Median=788,500000	
Mode= 1,000000	
Frequency of Mode= 1,000000	
Sum=7730,290000	
Minimum=140,000000	
Maximum=2192,760000	
Lower Quartile=534,530000	
Upper Quartile=1375,735000	
Range=2052,760000	

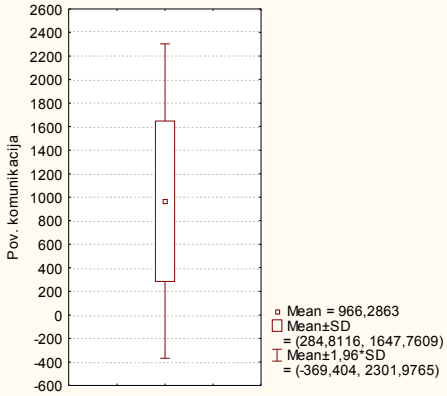

Summary: Pov. sanitarija

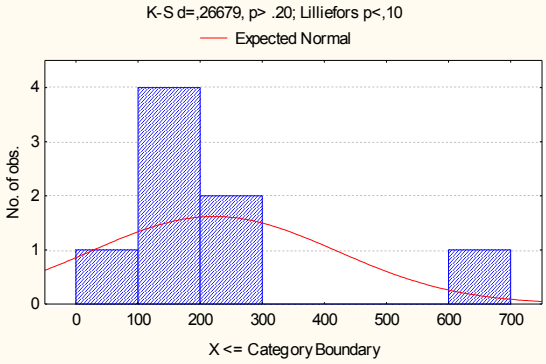

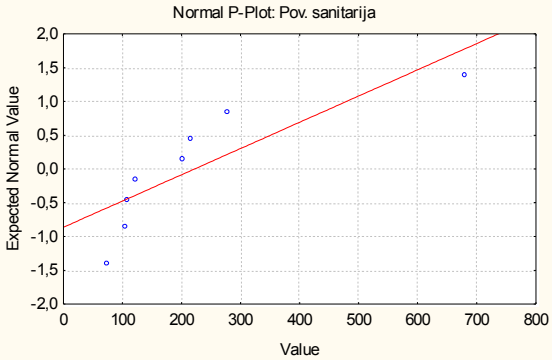

Summary Statistics:Pov. sanitarija

Valid N=8	Coef.Var.= 88,828189
% Valid obs.=100,000000	Skewness= 2,196604
Mean=222,166250	Kurtosis= 5,252201
Geometric Mean=172,954731	
Harmonic Mean=143,851716	
Median=160,000000	
Mode= 1,000000	
Frequency of Mode= 1,000000	
Sum=1777,330000	
Minimum= 72,330000	
Maximum=680,000000	
Lower Quartile=107,000000	
Upper Quartile=245,500000	
Range=607,670000	

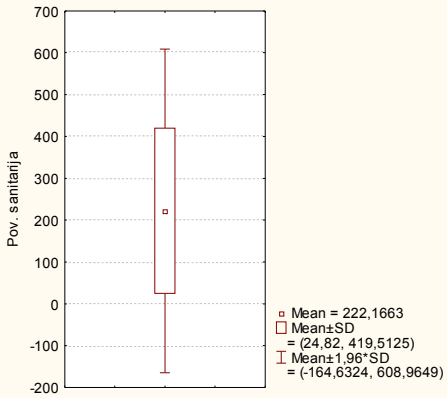

Summary: Pov. ureda

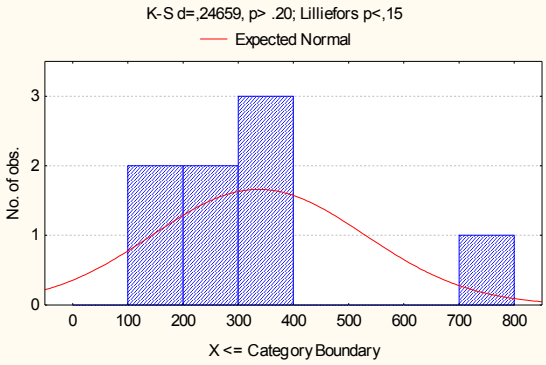

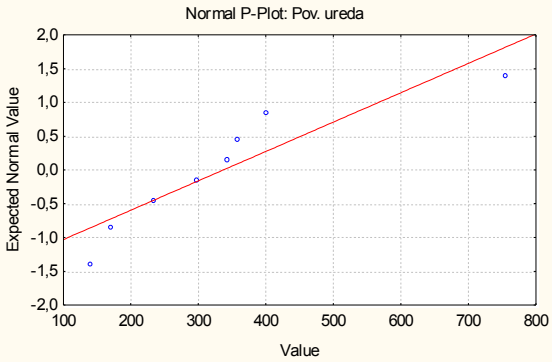

Summary Statistics:Pov. ureda
Valid N=8
% Valid obs.=100,000000
Mean=337,078750
Geometric Mean=297,401819
Harmonic Mean=264,776732
Median=320,770000
Mode= 1,000000
Frequency of Mode= 1,000000
Sum=2696,630000
Minimum=139,750000
Maximum=755,000000
Lower Quartile=201,810000
Upper Quartile=378,360000
Range=615,250000

Coef.Var.= 56,973657
Skewness= 1,606355
Kurtosis= 3,401052

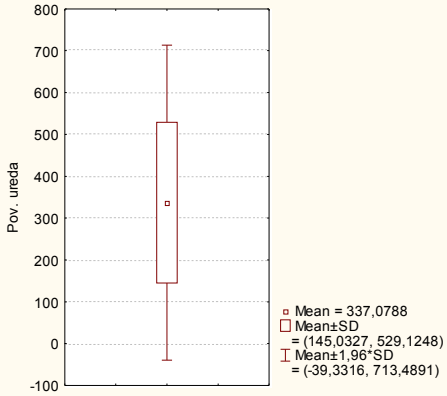

Summary: Pov. knjiznica

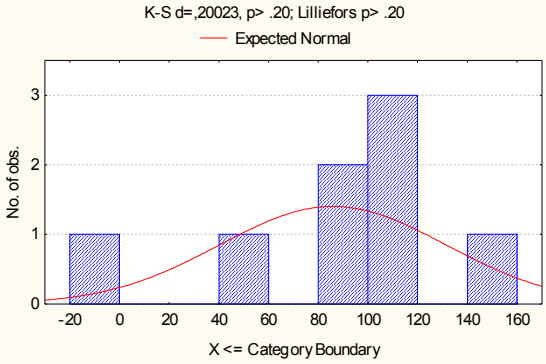

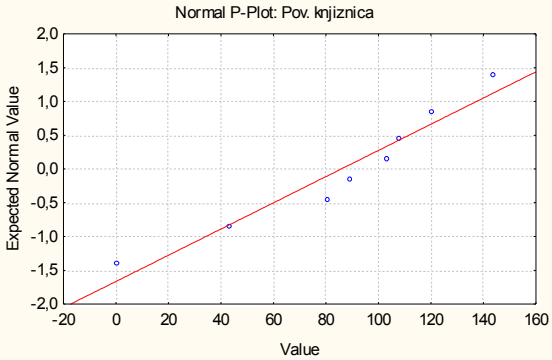

Summary Statistics:Pov. knjiznica
Valid N=8
% Valid obs.=100,000000
Mean= 85,873750
Geometric Mean=N/A
Harmonic Mean=N/A
Median= 95,870000
Mode= 1,000000
Frequency of Mode= 1,000000
Sum=686,990000
Minimum= 0,000000
Maximum=143,650000
Lower Quartile= 61,800000
Upper Quartile=114,000000
Range=143,650000

Coef.Var.= 53,005014
Skewness= -0,932085
Kurtosis= 0,727474

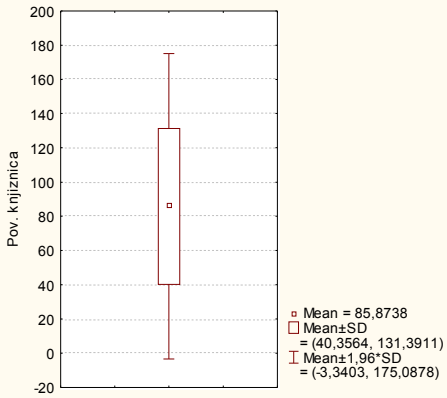

Summary: Pov. laboratorija

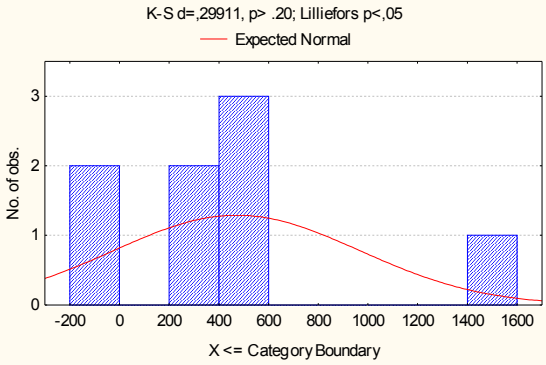

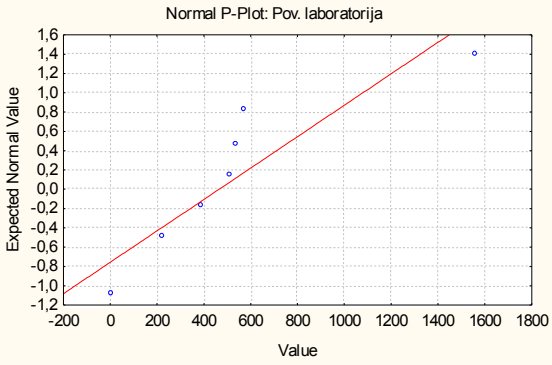

Summary Statistics: Pov. laboratorija

Valid N=8	Coef.Var.=104,904386
% Valid obs.=100,000000	Skewness= 1,669922
Mean=471,800000	Kurtosis= 3,702380
Geometric Mean=N/A	
Harmonic Mean=N/A	
Median=448,000000	
Mode= 1,000000	
Frequency of Mode= 2,000000	
Sum=3774,400000	
Minimum= 0,000000	
Maximum=1560,000000	
Lower Quartile=109,540000	
Upper Quartile=549,660000	
Range=1560,000000	

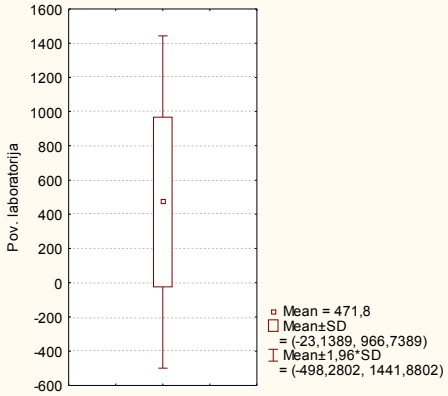

Summary: Ostale povrsine

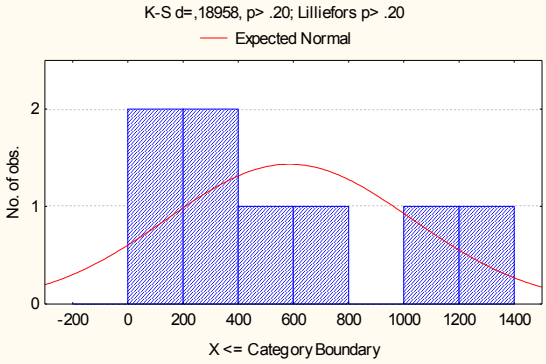

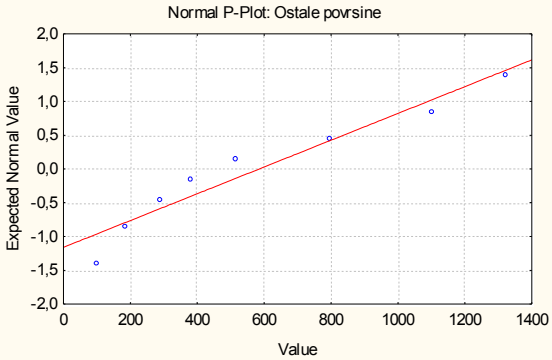

Summary Statistics: Ostale povrsine

Valid N=8	Coef.Var.= 75,984496
% Valid obs.=100,000000	Skewness= 0,718060
Mean=585,317500	Kurtosis= -0,880410
Geometric Mean=431,076668	
Harmonic Mean=302,672188	
Median=446,500000	
Mode= 1,000000	
Frequency of Mode= 1,000000	
Sum=4682,540000	
Minimum=100,000000	
Maximum=1322,720000	
Lower Quartile=236,125000	
Upper Quartile=947,285000	
Range=1222,720000	

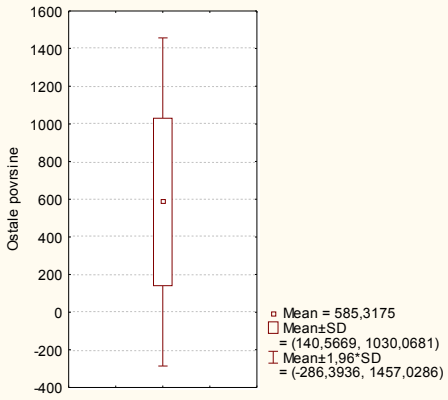

Summary: Ukupna povrsina

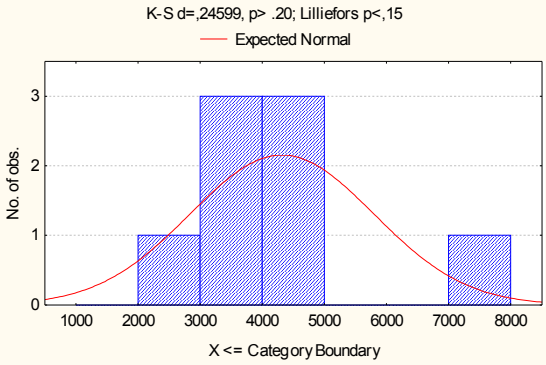

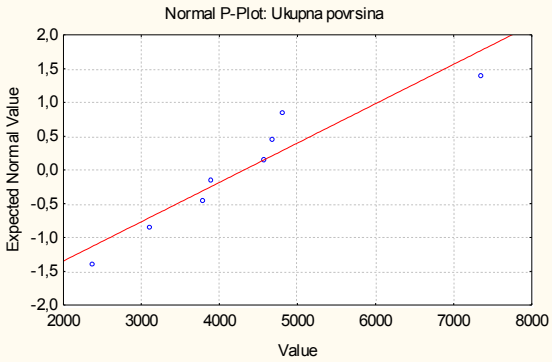

Summary Statistics: Ukupna povrsina

Valid N=8	Coef.Var.= 34,330745
% Valid obs.=100,000000	Skewness= 1,090219
Mean=4315,250000	Kurtosis= 2,281059
Geometric Mean=4108,461926	
Harmonic Mean=3914,002077	
Median=4227,000000	
Mode= 1,000000	
Frequency of Mode= 1,000000	
Sum=34522,000000	
Minimum=2375,000000	
Maximum=7345,000000	
Lower Quartile=3432,500000	
Upper Quartile=4741,500000	
Range=4970,000000	

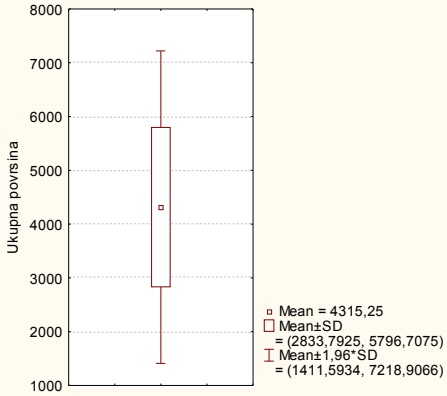

Summary: Djelatnici

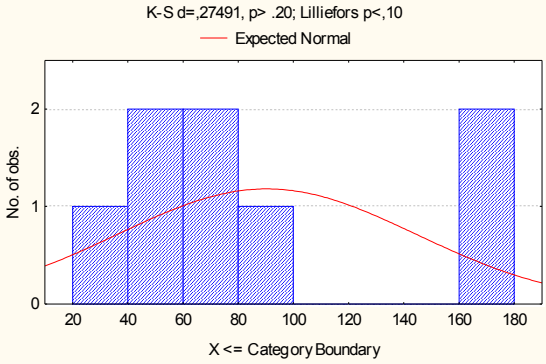

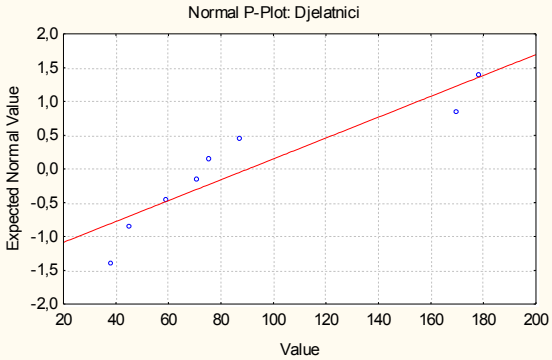

Summary Statistics: Djelatnici

Valid N=8	Coef.Var.= 59,774268
% Valid obs.=100,000000	Skewness= 1,085851
Mean= 90,375000	Kurtosis= -0,387731
Geometric Mean= 78,310408	
Harmonic Mean= 69,025267	
Median= 73,000000	
Mode= 1,000000	
Frequency of Mode= 1,000000	
Sum=723,000000	
Minimum= 38,000000	
Maximum=178,000000	
Lower Quartile= 52,000000	
Upper Quartile=128,500000	
Range=140,000000	

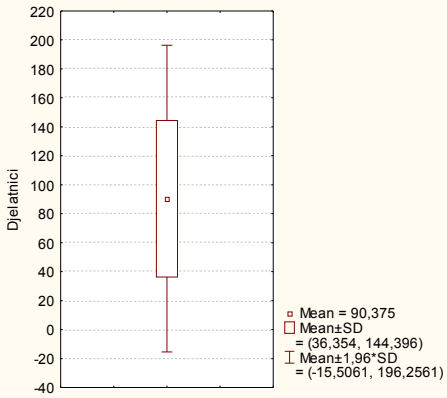

Summary: Studenti

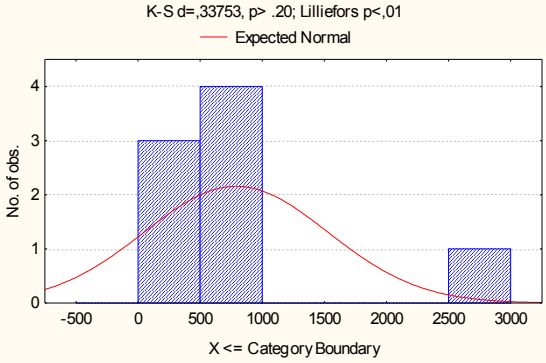

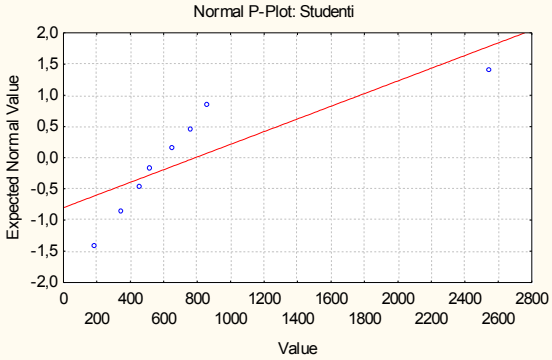

Summary Statistics:Studenti
Valid N=8
% Valid obs.=100,000000
Mean=788,375000
Geometric Mean=598,047751
Harmonic Mean=477,828878
Median=583,000000
Mode= 1,000000
Frequency of Mode= 1,000000
Sum=6307,000000
Minimum=189,000000
Maximum=2540,000000
Lower Quartile=398,500000
Upper Quartile=807,500000
Range=2351,000000

Coef.Var.= 93,885824
Skewness= 2,354494
Kurtosis= 6,065319

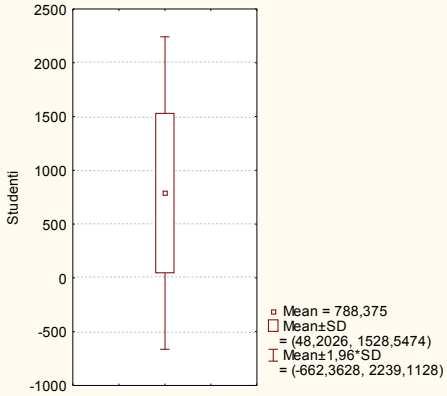

Summary: Smjene

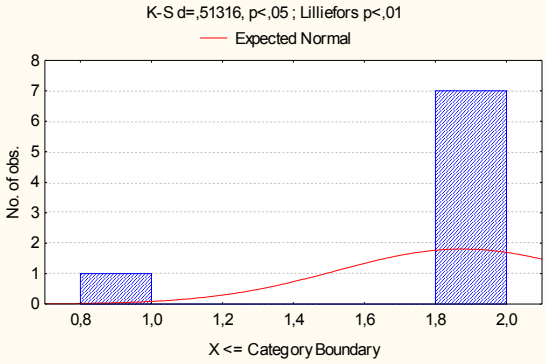

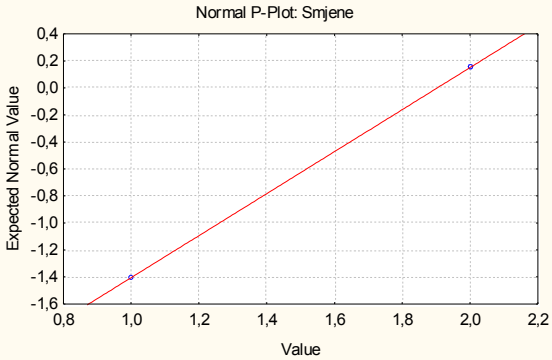

Summary Statistics:Smjene
Valid N=8
% Valid obs.=100,000000
Mean= 1,875000
Geometric Mean= 1,834008
Harmonic Mean= 1,777778
Median= 2,000000
Mode= 1,000000
Frequency of Mode= 7,000000
Sum= 15,000000
Minimum= 1,000000
Maximum= 2,000000
Lower Quartile= 2,000000
Upper Quartile= 2,000000
Range= 1,000000

Coef.Var.= 18,856181
Skewness= -2,828427
Kurtosis= 8,000000

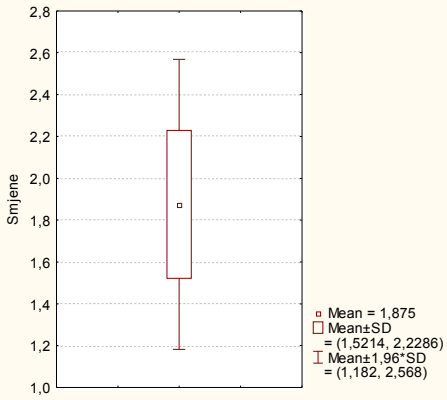

Summary: Troskovi uporabe

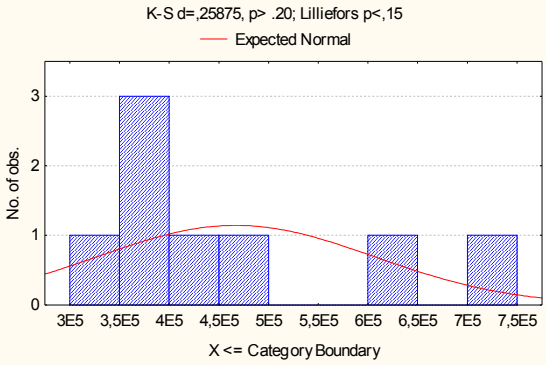

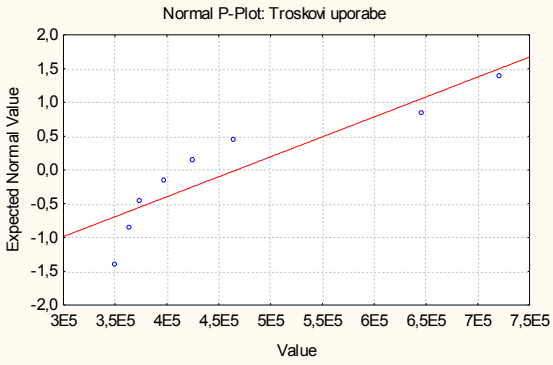

Summary Statistics: Troskovi uporabe

Valid N=8	Coef.Var.= 29,869344
% Valid obs.=100,000000	Skewness= 1,260173
Mean=466983,824583	Kurtosis= 0,124397
Geometric Mean=451181,299026	
Harmonic Mean=437916,380492	
Median=410088,368750	
Mode= 1,000000	
Frequency of Mode= 1,000000	
Sum=3735870,596667	
Minimum=349526,833333	
Maximum=720453,333333	
Lower Quartile=368298,968750	
Upper Quartile=554557,877500	
Range=370926,500000	

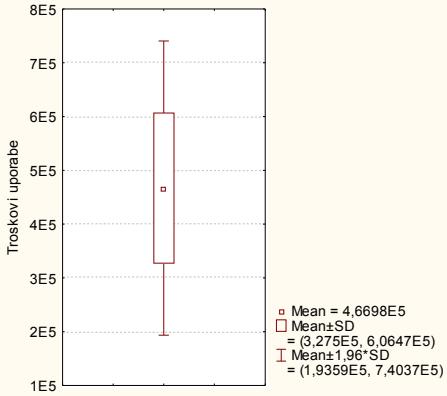

Summary: Troskovi odrzavanja i uporabe

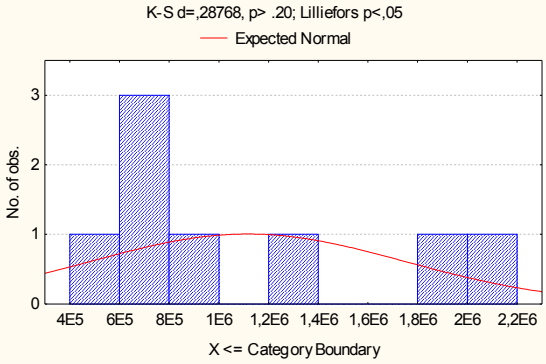

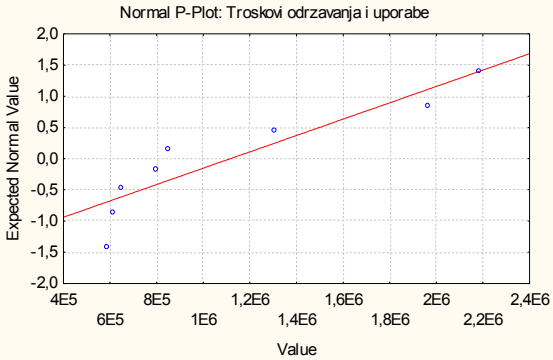

Summary Statistics: Troskovi odrzavanja i uporabe

Valid N=8	Coef.Var.= 56,888845
% Valid obs.=100,000000	Skewness= 1,030891
Mean=1115555,072917	Kurtosis= -0,653370
Geometric Mean=981478,039232	
Harmonic Mean=881308,560392	
Median=820671,175000	
Mode= 1,000000	
Frequency of Mode= 1,000000	
Sum=8924440,583333	
Minimum=586013,412500	
Maximum=2180682,582500	
Lower Quartile=626417,672917	
Upper Quartile=1631783,446250	
Range=1594669,170000	

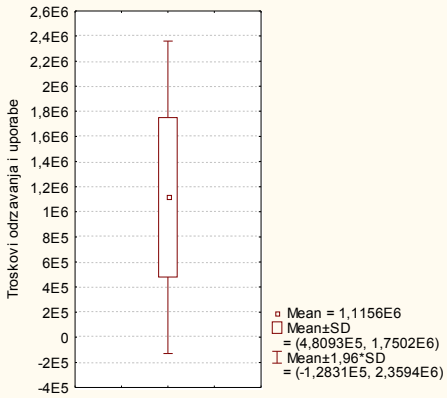

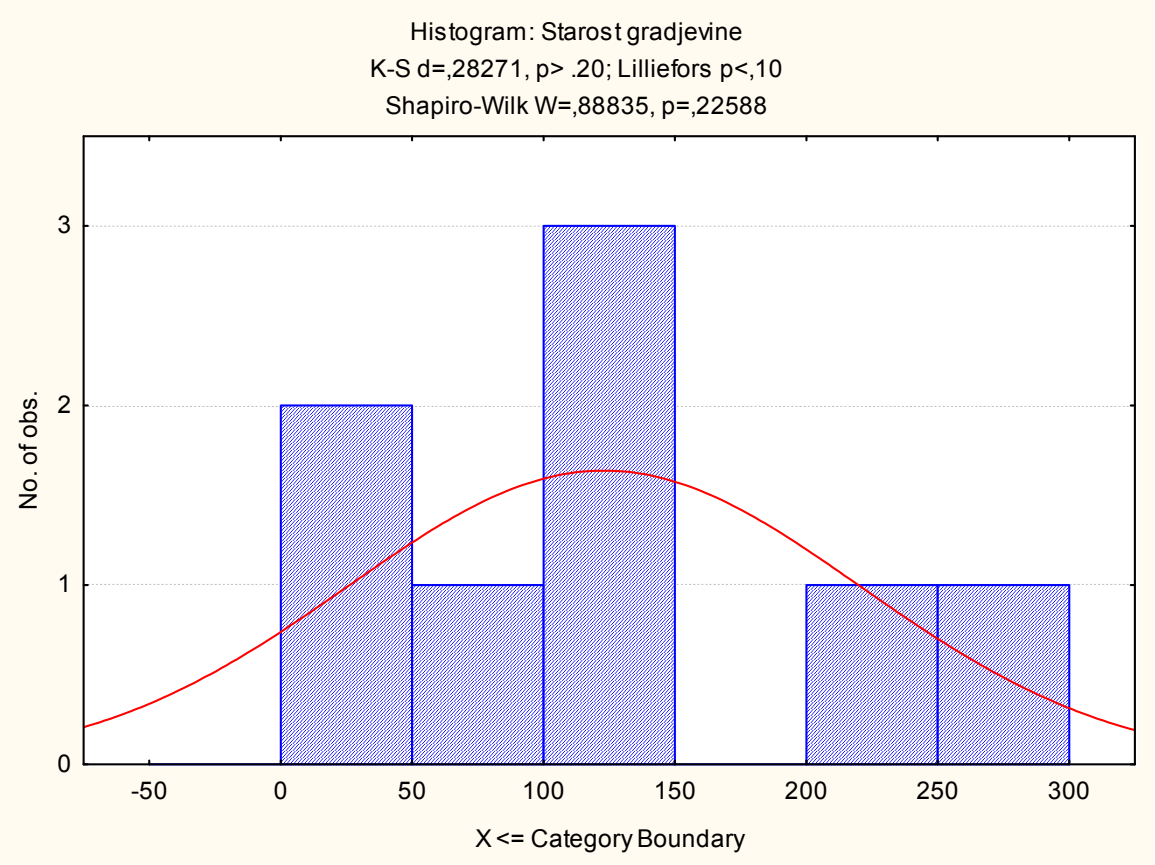
Histogram: Starost gradjevine
K-S d=,28271, p> .20; Lilliefors p<,10
Shapiro-Wilk W=,88835, p=,22588
No. of obs.
0
1
2
3
-50
0
50
100
150
200
250
300
X <= Category Boundary

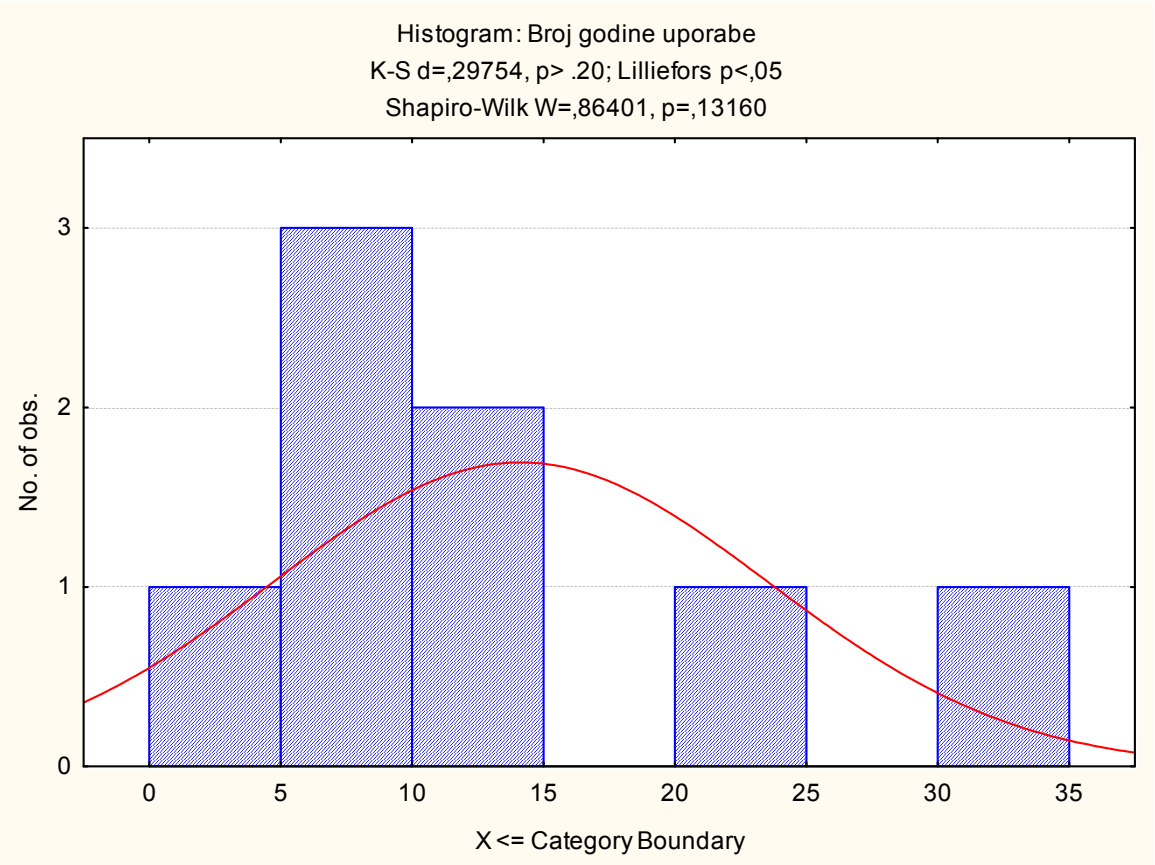
Histogram: Broj godine uporabe
K-S d=,29754, p> .20; Lilliefors p<,05
Shapiro-Wilk W=,86401, p=,13160
No. of obs.
0
1
2
3
0
5
10
15
20
25
30
35
X <= Category Boundary

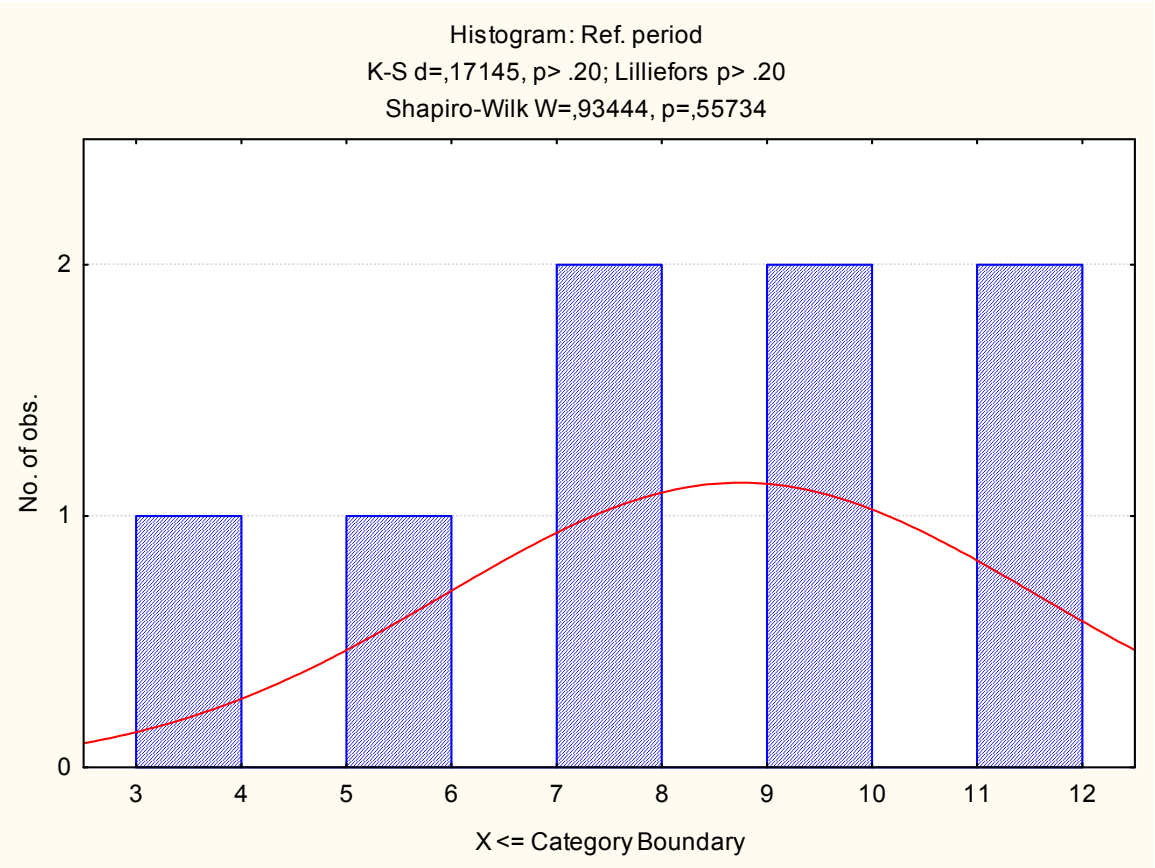
Histogram: Ref. period
K-S d=,17145, p> .20; Lilliefors p> .20
Shapiro-Wilk W=,93444, p=,55734
No. of obs.
0
1
2
3
4
5
6
7
8
9
10
11
12
X <= Category Boundary

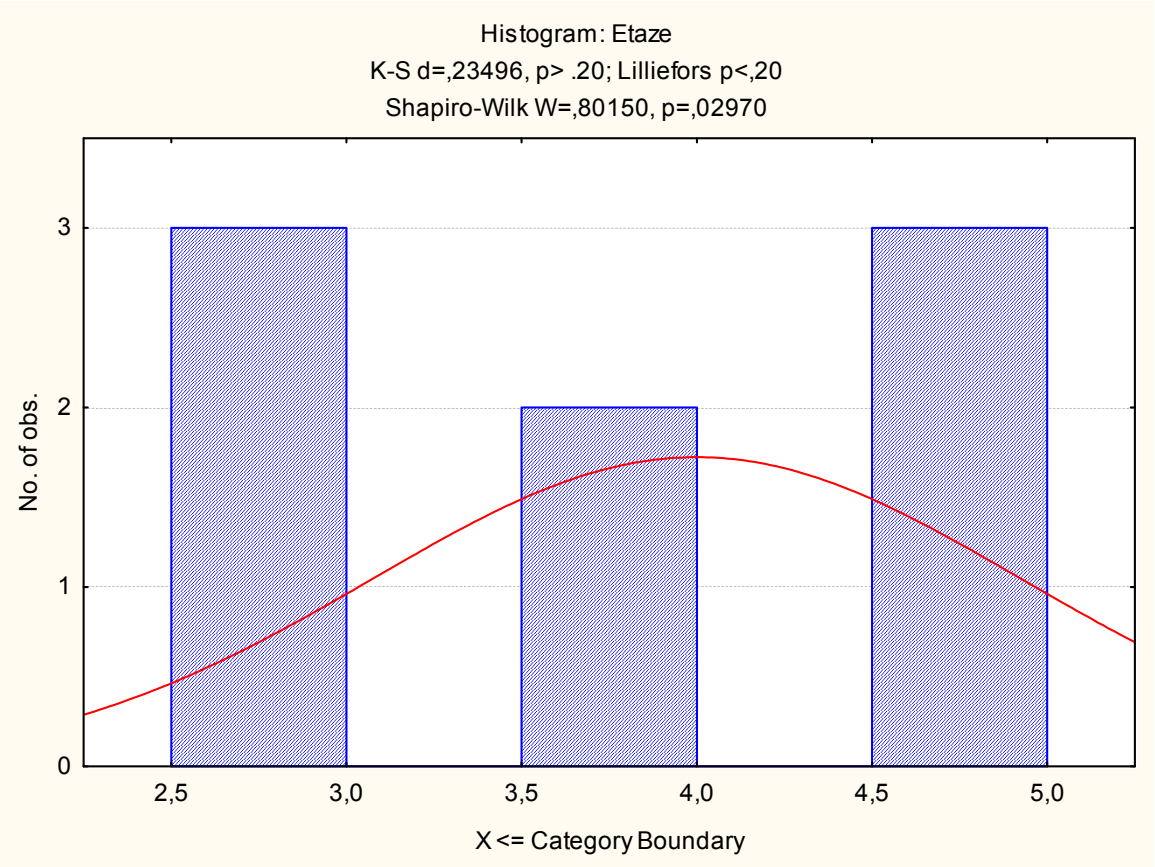
Histogram: Etaze
K-S d=,23496, p> .20; Lilliefors p<,20
Shapiro-Wilk W=,80150, p=,02970
No. of obs.
0
1
2
3
2,5
3,0
3,5
4,0
4,5
5,0
X <= Category Boundary

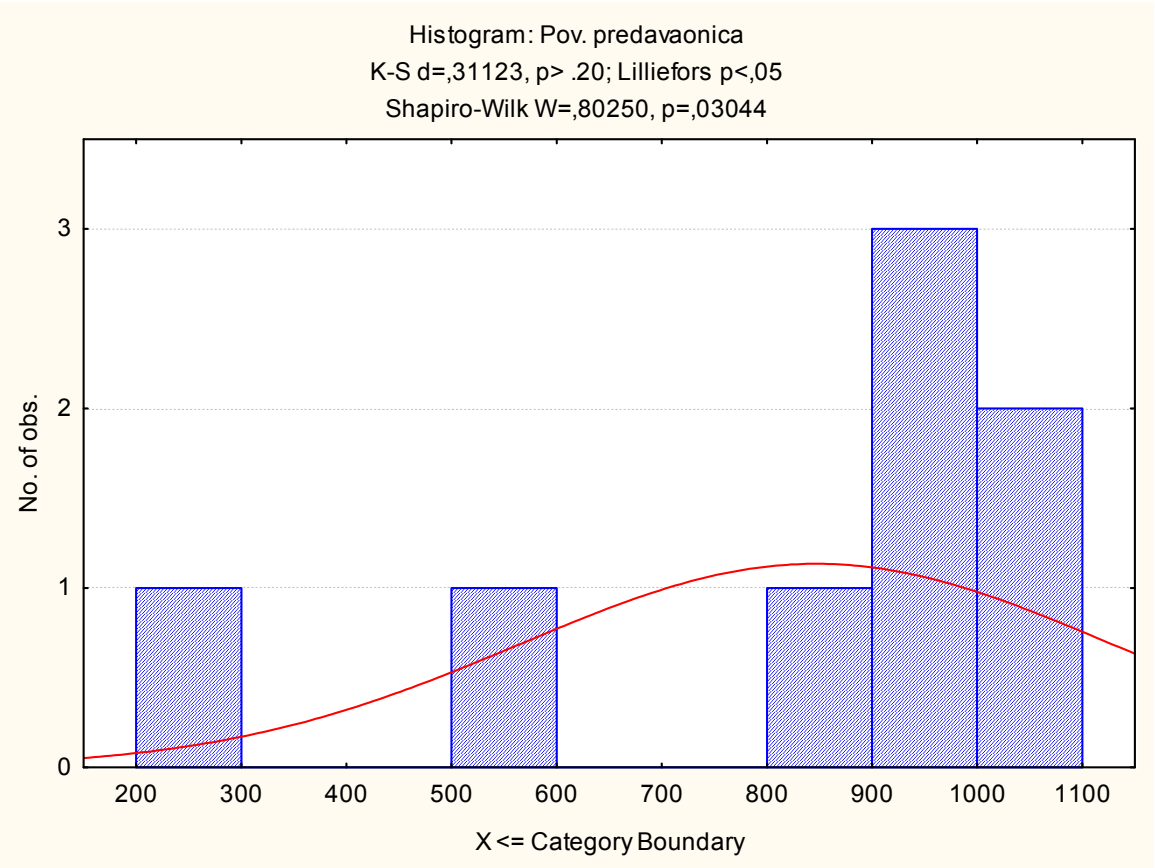
Histogram: Pov. predavaonica
K-S d=,31123, p> .20; Lilliefors p<,05
Shapiro-Wilk W=,80250, p=,03044
No. of obs.
0
1
2
3
200
300
400
500
600
700
800
900
1000
1100
X <= Category Boundary

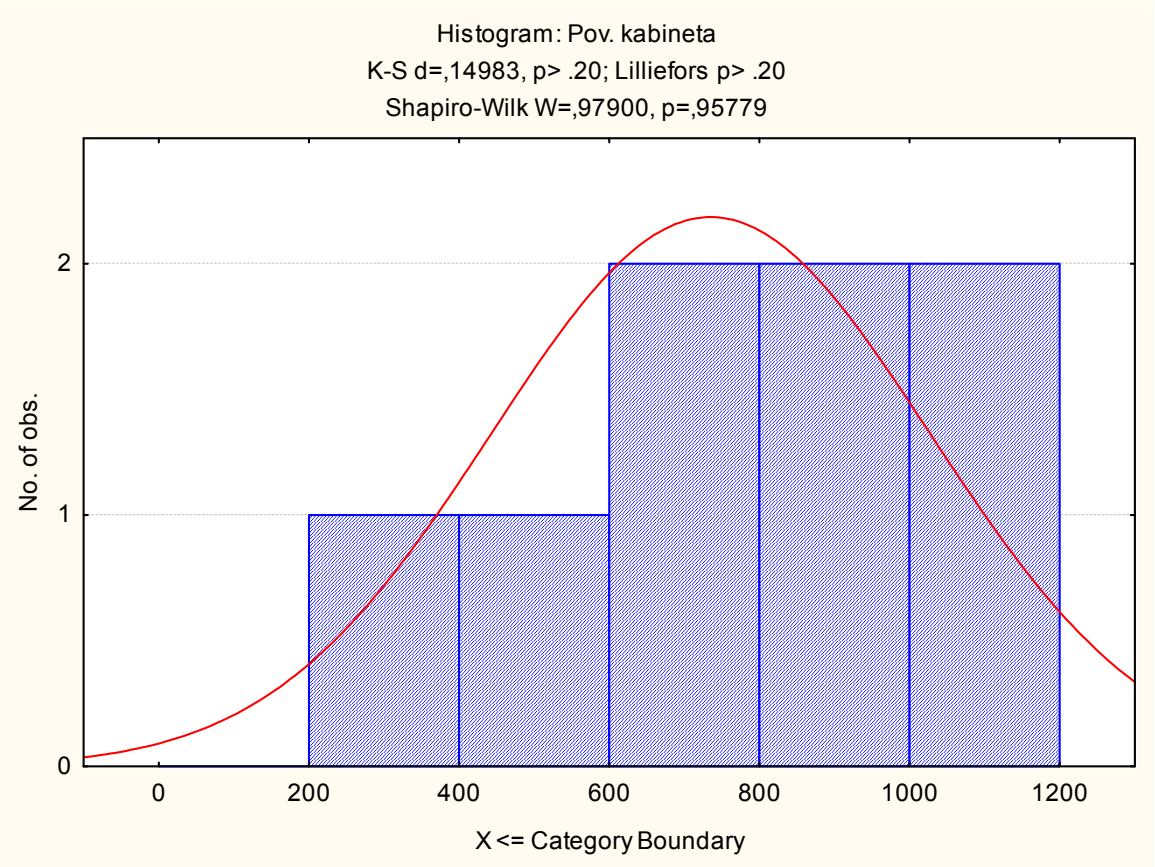
Histogram: Pov. kabineta
K-S d=,14983, p> .20; Lilliefors p> .20
Shapiro-Wilk W=,97900, p=,95779
No. of obs.
0
1
2
0
200
400
600
800
1000
1200
X <= Category Boundary

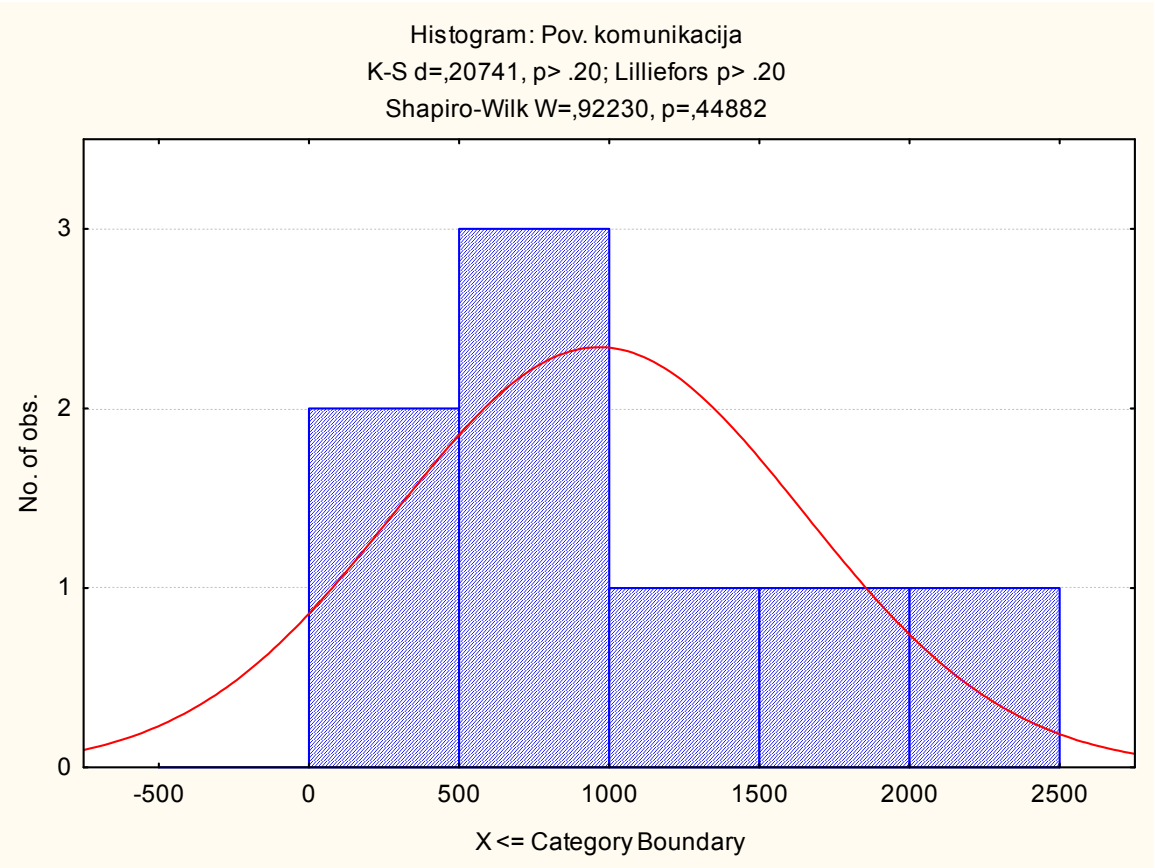
Histogram: Pov. komunikacija
K-S d=,20741, p> .20; Lilliefors p> .20
Shapiro-Wilk W=,92230, p=,44882
No. of obs.
0
1
2
3
-500
0
500
1000
1500
2000
2500
X <= Category Boundary

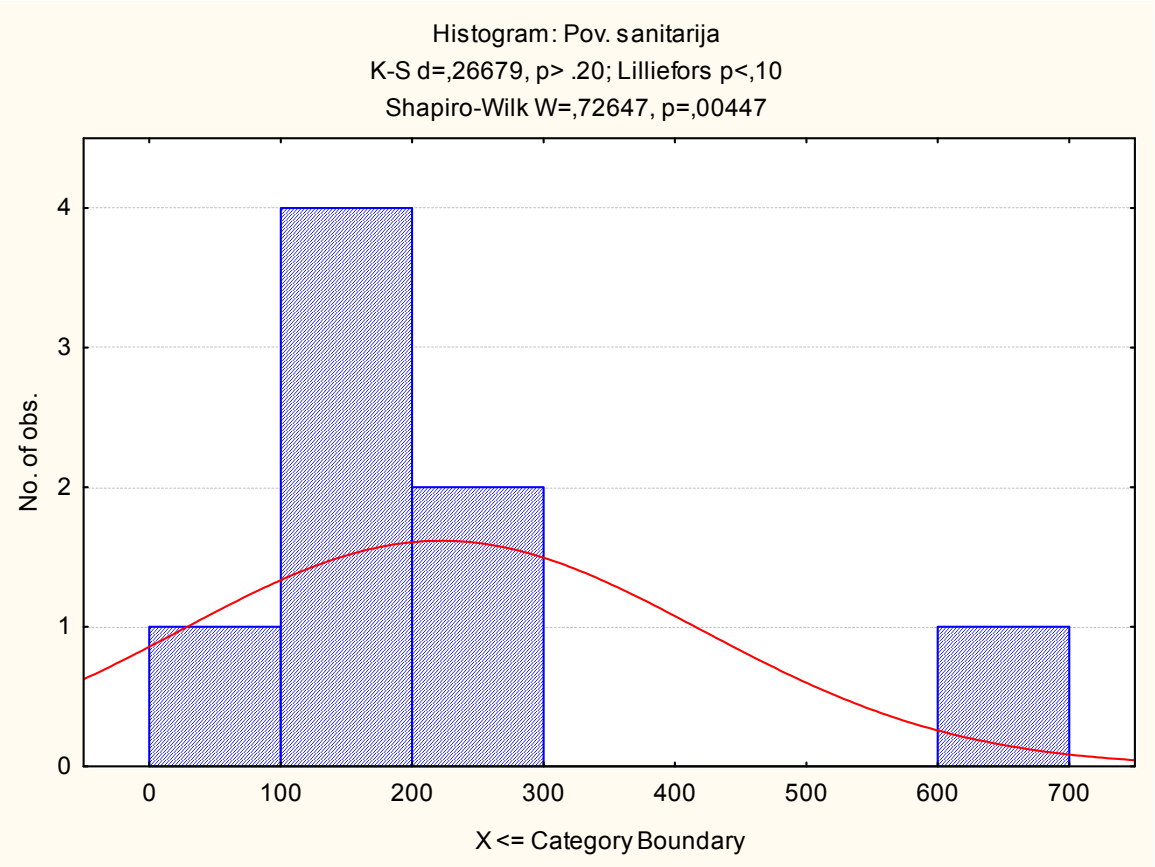
Histogram: Pov. sanitarija
K-S d=,26679, p> .20; Lilliefors p<,10
Shapiro-Wilk W=,72647, p=,00447
No. of obs.
0
1
2
3
4
0
100
200
300
400
500
600
700
X <= Category Boundary

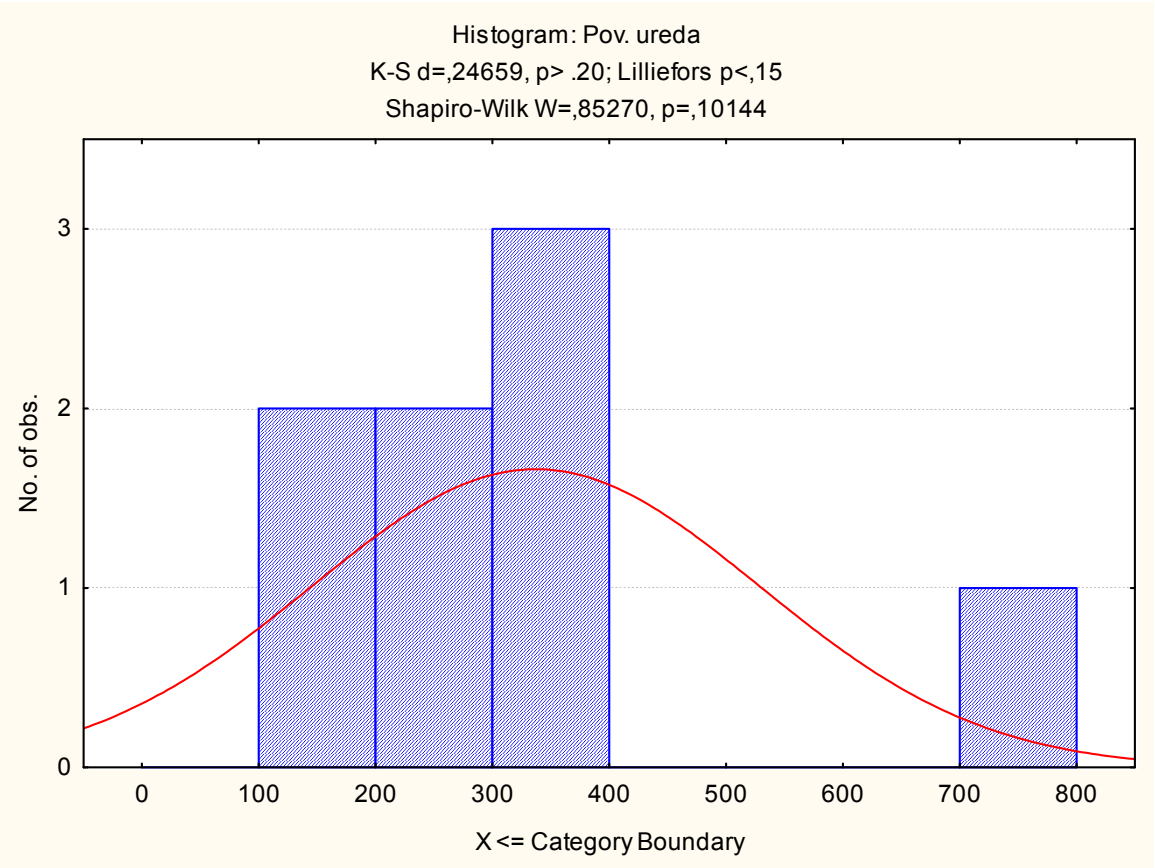
Histogram: Pov. ureda
K-S d=,24659, p> .20; Lilliefors p<,15
Shapiro-Wilk W=,85270, p=,10144
No. of obs.
0
1
2
3
0
100
200
300
400
500
600
700
800
X <= Category Boundary

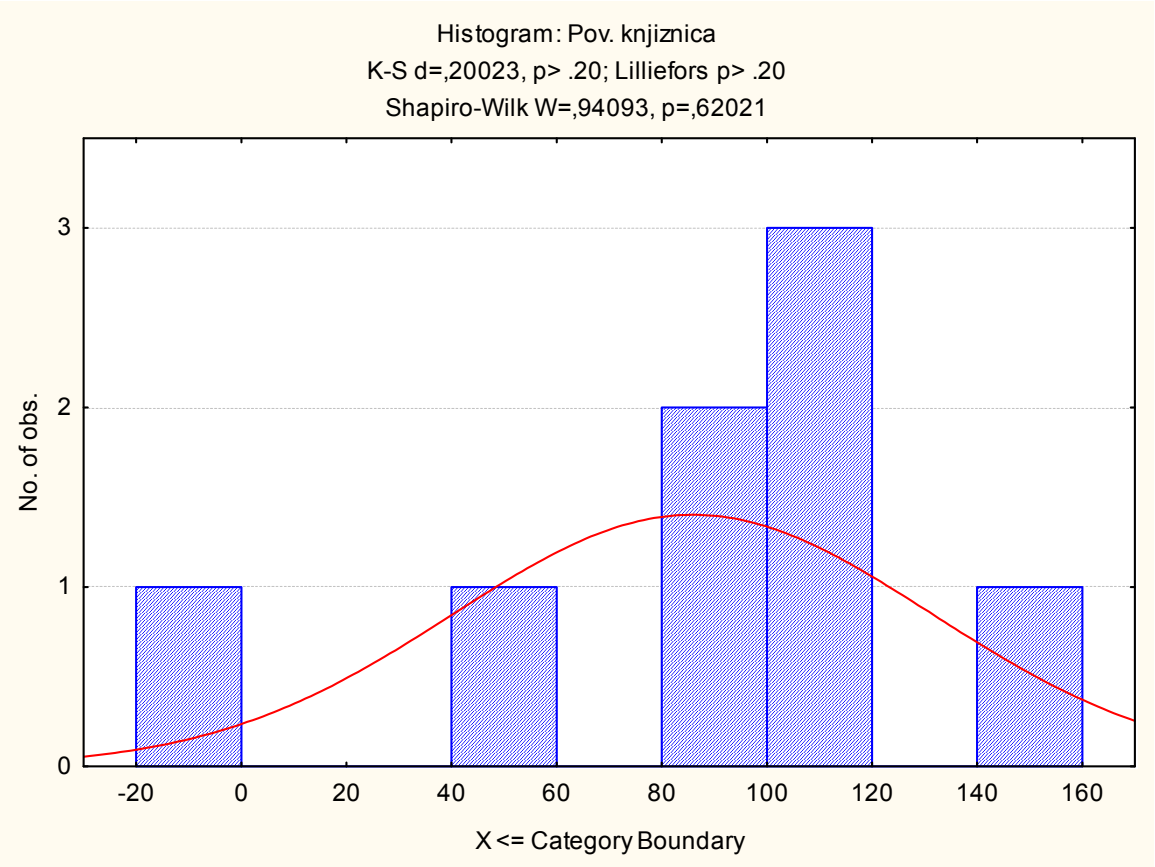
Histogram: Pov. knjiznica
K-S d=,20023, p> .20; Lilliefors p> .20
Shapiro-Wilk W=,94093, p=,62021
No. of obs.
0
1
2
3
-20
0
20
40
60
80
100
120
140
160
X <= Category Boundary

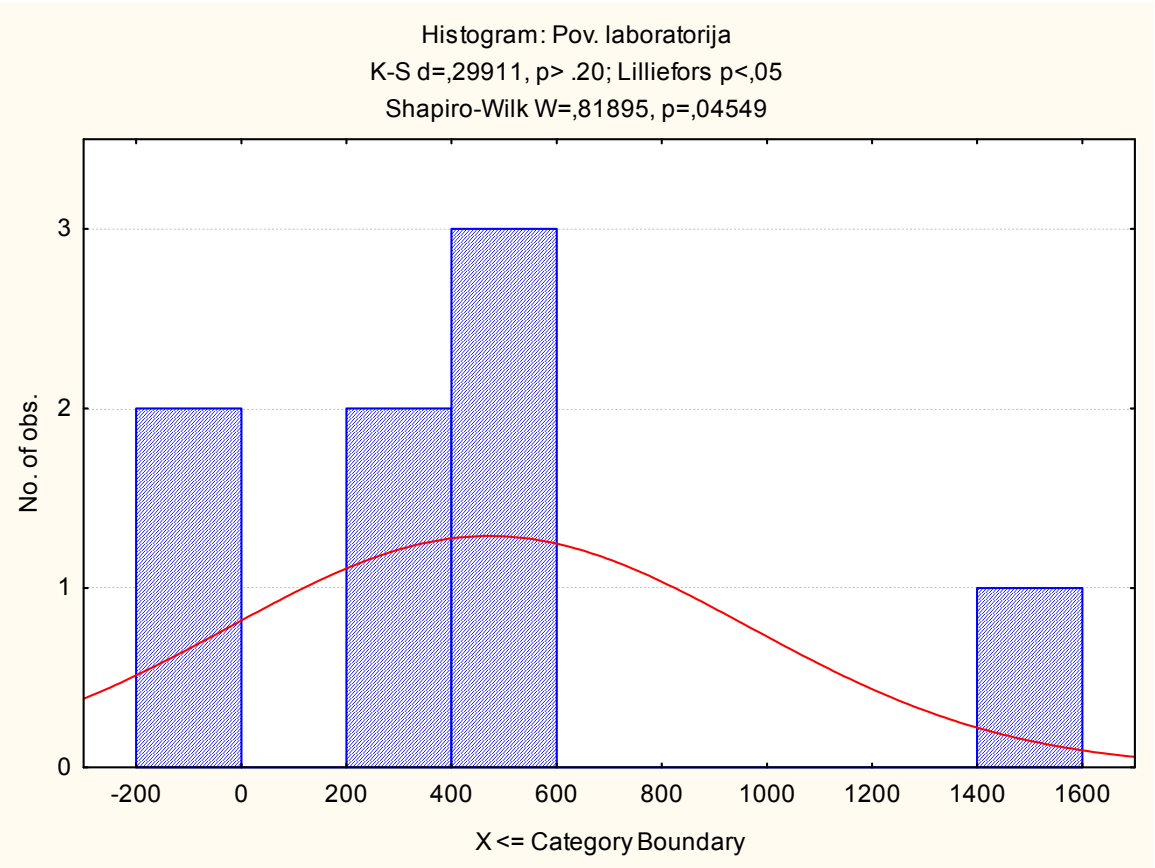
Histogram: Pov. laboratorija
K-S d=,29911, p> .20; Lilliefors p<,05
Shapiro-Wilk W=,81895, p=,04549
No. of obs.
0
1
2
3
-200
0
200
400
600
800
1000
1200
1400
1600
X <= Category Boundary

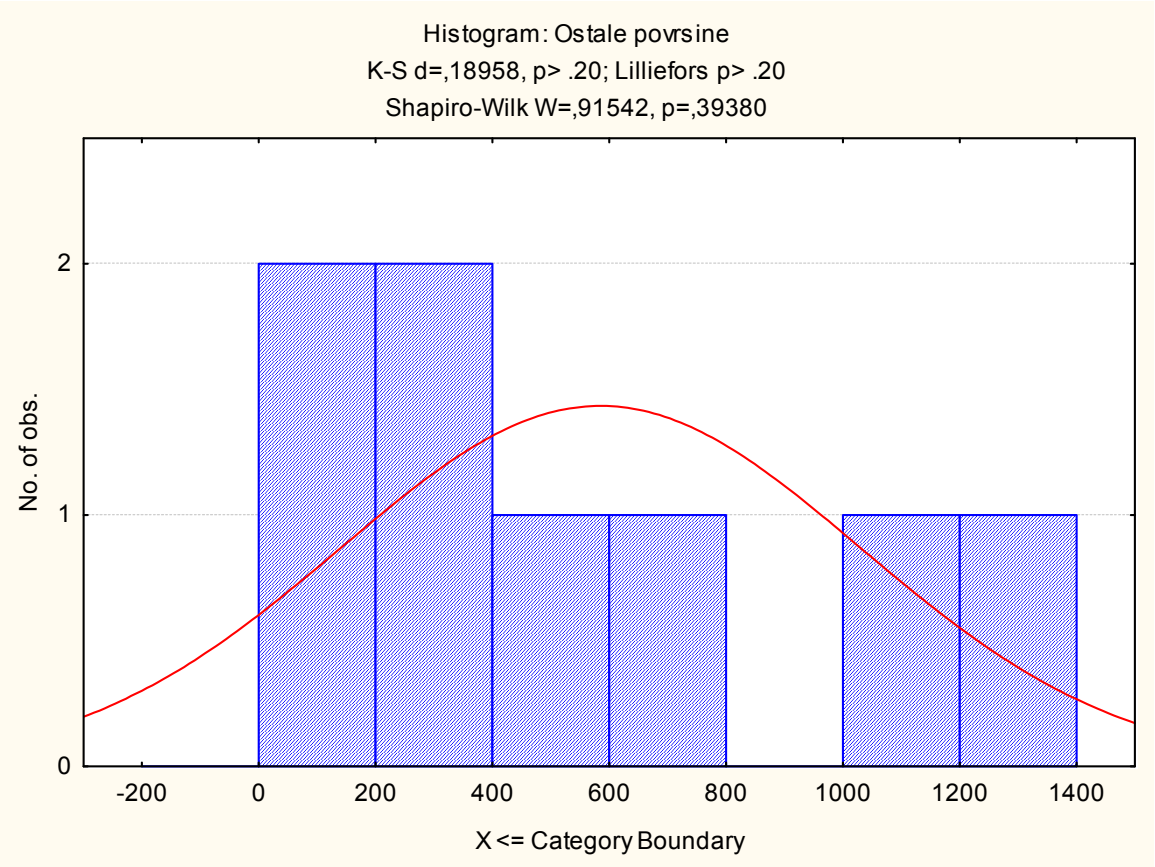
Histogram: Ostale povrsine
K-S d=,18958, p> .20; Lilliefors p> .20
Shapiro-Wilk W=,91542, p=,39380
No. of obs.
0
1
2
-200
0
200
400
600
800
1000
1200
1400
X <= Category Boundary

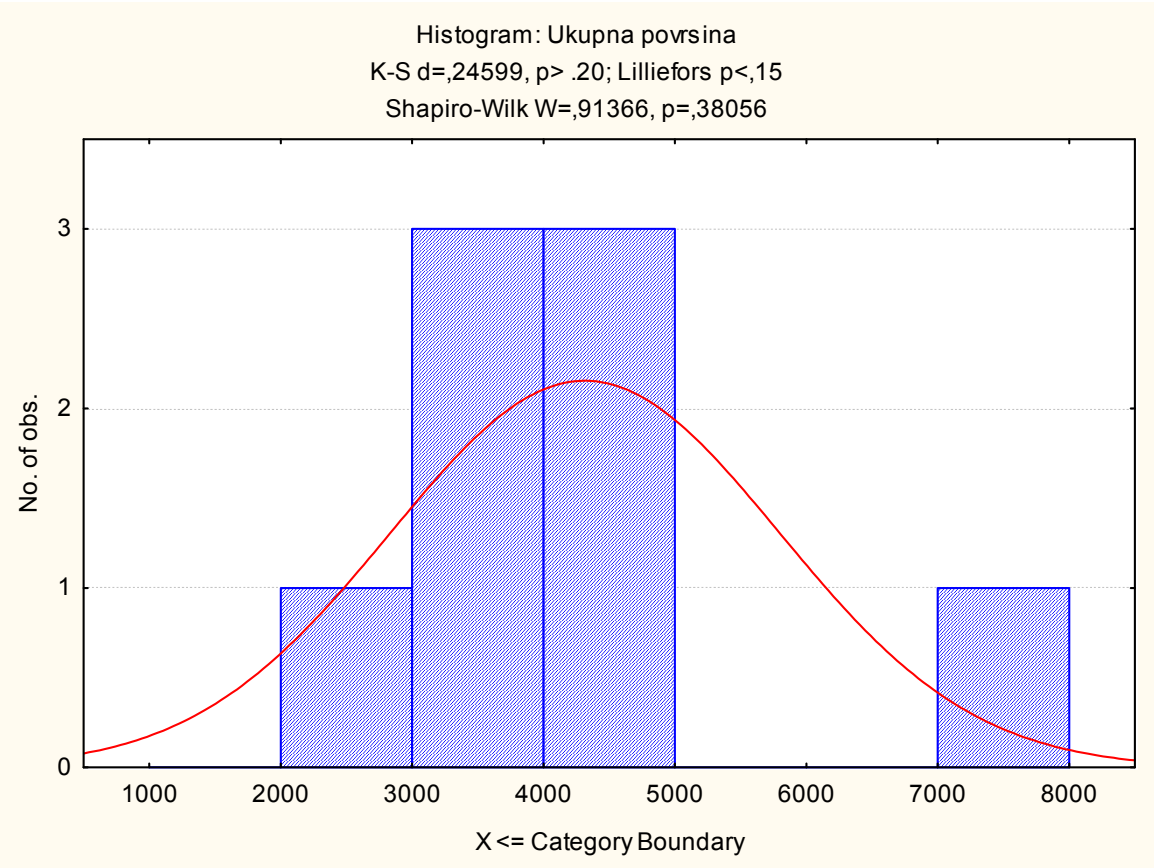
Histogram: Ukupna povrsina
K-S d=,24599, p> .20; Lilliefors p<,15
Shapiro-Wilk W=,91366, p=,38056
No. of obs.
0
1
2
3
1000
2000
3000
4000
5000
6000
7000
8000
X <= Category Boundary

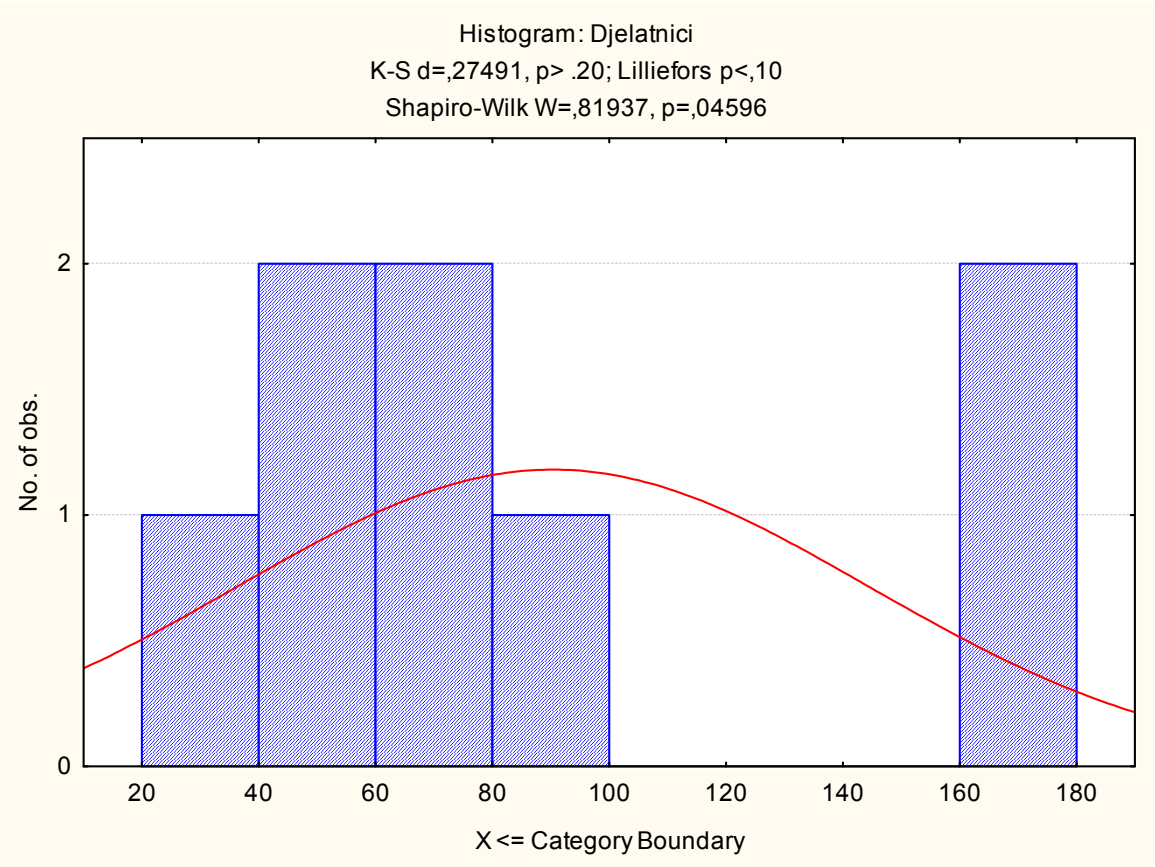
Histogram: Djelatnici
K-S d=,27491, p> .20; Lilliefors p<,10
Shapiro-Wilk W=,81937, p=,04596
No. of obs.
0
1
2
20
40
60
80
100
120
140
160
180
X <= Category Boundary

Histogram: Studenti
K-S d=,33753, p> .20; Lilliefors p<,01
Shapiro-Wilk W=,70557, p=,00260
No. of obs.
0
1
2
3
4
-500
0
500
1000
1500
2000
2500
3000
X <= Category Boundary

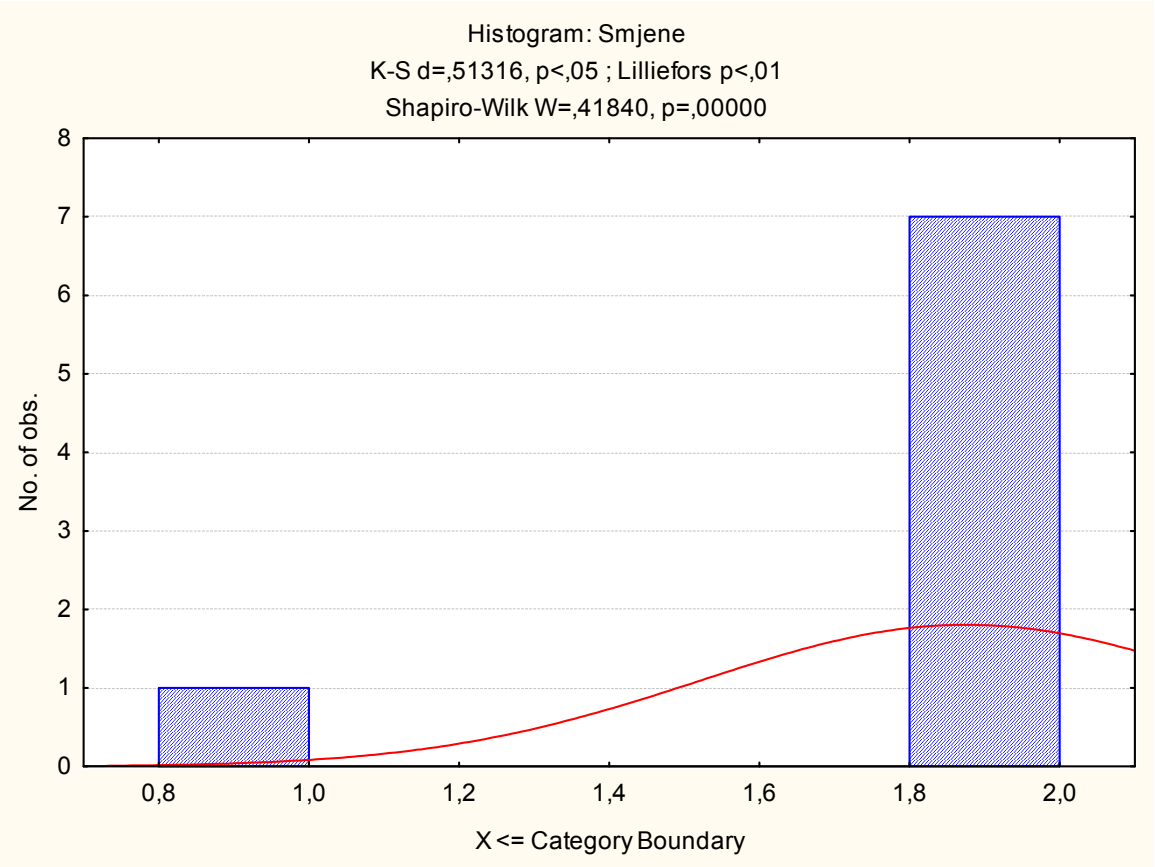
Histogram: Smjene
K-S d=,51316, p<,05 ; Lilliefors p<,01
Shapiro-Wilk W=,41840, p=,00000
No. of obs.
0
1
2
3
4
5
6
7
8
0,8
1,0
1,2
1,4
1,6
1,8
2,0
X <= Category Boundary

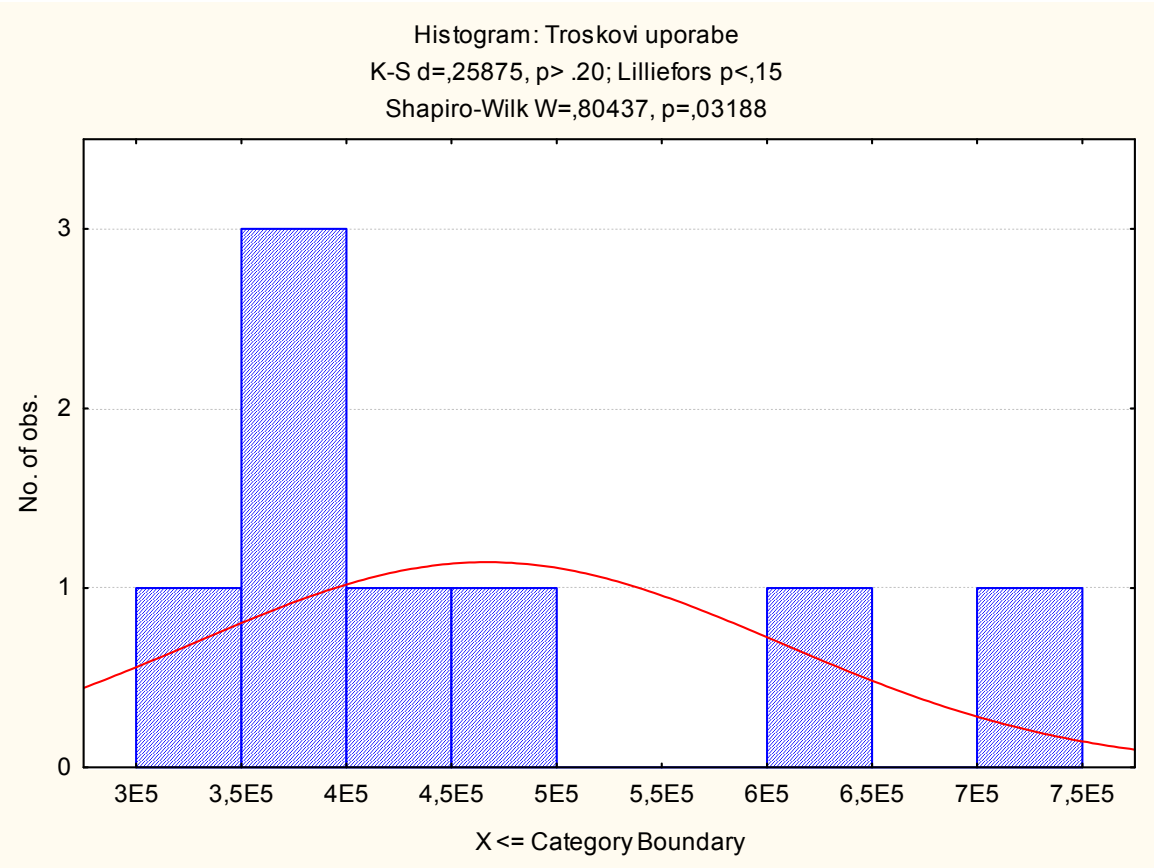
Histogram: Troskovi uporabe
K-S d=,25875, p> .20; Lilliefors p<,15
Shapiro-Wilk W=,80437, p=,03188
No. of obs.
0
1
2
3
3E5
3,5E5
4E5
4,5E5
5E5
5,5E5
6E5
6,5E5
7E5
7,5E5
X <= Category Boundary

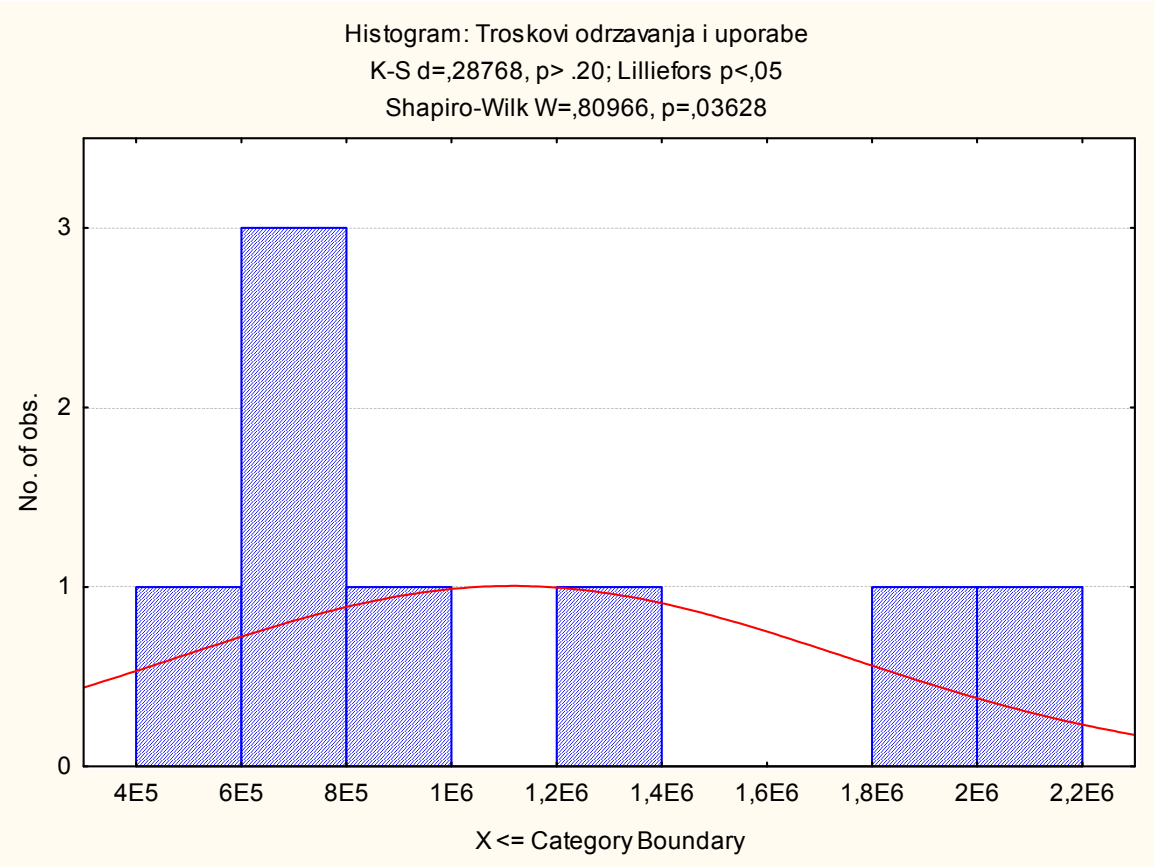
Histogram: Troskovi odrzavanja i uporabe
K-S d=,28768, p> .20; Lilliefors p<,05
Shapiro-Wilk W=,80966, p=,03628
No. of obs.
0
1
2
3
4E5
6E5
8E5
1E6
1,2E6
1,4E6
1,6E6
1,8E6
2E6
2,2E6
X <= Category Boundary

	Mean	Std.Dv.	r(X,Y)	r2	t	p	N	Constant dep: Y	Slope dep: Y	Constant dep: X	Slope dep: X
Troskovi uporabe	466983,8	139485,0									
Starost gradjevine	123,0	97,5	0,028066	0,000788	0,06878	0,947403	8	113,842	0,000020	462043	40
Troskovi uporabe	466983,8	139485,0									
Broj godine uporabe	14,1	9,4	-0,051673	0,002670	-0,12674	0,903285	8	15,754	-0,000003	477794	-765
Troskovi uporabe	466983,8	139485,0									
Ref. period	8,8	2,8	-0,158298	0,025058	-0,39270	0,708113	8	10,242	-0,000003	535598	-7842
Troskovi uporabe	466983,8	139485,0									
Etaze	4,0	0,9	0,266174	0,070849	0,67639	0,523995	8	3,175	0,000002	306576	40102
Troskovi uporabe	466983,8	139485,0									
Pov. predavaonica	846,7	281,2	-0,199966	0,039987	-0,49991	0,634938	8	1034,925	-0,000403	550965	-99
Troskovi uporabe	466983,8	139485,0									
Pov. kabineta	735,1	291,9	0,222712	0,049601	0,55959	0,596017	8	517,409	0,000466	388765	106
Troskovi uporabe	466983,8	139485,0									
Pov. komunikacija	966,3	681,5	0,353483	0,124951	0,92561	0,390359	8	159,807	0,001727	397072	72
Troskovi uporabe	466983,8	139485,0									
Pov. sanitarija	222,2	197,3	-0,178420	0,031834	-0,44416	0,672495	8	340,048	-0,000252	495001	-126
Troskovi uporabe	466983,8	139485,0									
Pov. ureda	337,1	192,0	0,650592	0,423269	2,09845	0,080651	8	-81,222	0,000896	307704	473
Troskovi uporabe	466983,8	139485,0									
Pov. knjiznica	85,9	45,5	-0,549411	0,301852	-1,61064	0,158384	8	169,598	-0,000179	611564	-1684
Troskovi uporabe	466983,8	139485,0									
Pov. laboratorija	471,8	494,9	-0,087622	0,007678	-0,21546	0,836548	8	616,990	-0,000311	478634	-25
Troskovi uporabe	466983,8	139485,0									
Ostale povrsine	585,3	444,8	0,276763	0,076598	0,70549	0,506959	8	173,221	0,000882	416178	87
Troskovi uporabe	466983,8	139485,0									
Ukupna povrsina	4315,3	1481,5	0,250506	0,062753	0,63382	0,549581	8	3072,792	0,002661	365204	24
Troskovi uporabe	**466983,8**	**139485,0**									
Djelatnici	**90,4**	**54,0**	**0,936251**	**0,876566**	**6,52756**	**0,000617**	**8**	**-78,953**	**0,000363**	**248507**	**2417**
Troskovi uporabe	466983,8	139485,0									
Studenti	788,4	740,2	0,219144	0,048024	0,55017	0,602070	8	245,328	0,001163	434426	41
Troskovi uporabe	**466983,8**	**139485,0**									
Smjene	**1,9**	**0,4**	**-0,734252**	**0,539126**	**-2,64929**	**0,038065**	**8**	**2,744**	**-0,000002**	**1010133**	**-289679**

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var1

Moments

N	8	Sum Weights	8
Mean	123	Sum Observations	984
Std Deviation	97.4620805	Variance	9498.85714
Skewness	0.92298795	Kurtosis	-0.1279583
Uncorrected SS	187524	Corrected SS	66492
Coeff Variation	79.2374639	Std Error Mean	34.458049

Basic Statistical Measures

Location		Variability	
Mean	123.0000	Std Deviation	97.46208
Median	109.0000	Variance	9499
Mode	.	Range	283.00000
		Interquartile Range	126.50000

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	3.569558	Pr > |t|	0.0091
Sign	M	4	Pr >= |M|	0.0078
Signed Rank	S	18	Pr >= |S|	0.0078

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.88835	Pr < W	0.2259
Kolmogorov-Smirnov	D	0.28271	Pr > D	0.0587
Cramer-von Mises	W-Sq	0.088323	Pr > W-Sq	0.1391
Anderson-Darling	A-Sq	0.477482	Pr > A-Sq	0.1741

Quantiles (Definition 5)

Quantile	Estimate
100% Max	293.0
99%	293.0
95%	293.0
90%	293.0
75% Q3	179.0
50% Median	109.0
25% Q1	52.5
10%	10.0
5%	10.0
1%	10.0
0% Min	10.0

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var1

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
10	8	108	6
49	1	110	4
56	3	115	5
108	6	243	7
110	4	293	2

```
Stem Leaf                     #             Boxplot                                 Normal Probability Plot
   2 9                        1                |                   275+                                        *++++
   2 4                        1                |                      |                                  +*++++
   1                                           +-----+                |                              +++++
   1 112                      3                *--+--*                |                        *+++*  *
   0 56                       2                +-----+                |                   ++*++
   0 1                        1                   |                    25+            * +++*+
     ----+----+----+----+                                                +----+----+----+----+----+----+----+----+----+----+
 Multiply Stem.Leaf by 10**+2                                               -2        -1         0        +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var2

Moments

N	8	Sum Weights	8
Mean	14.125	Sum Observations	113
Std Deviation	9.41787814	Variance	88.6964286
Skewness	1.35632531	Kurtosis	1.46413221
Uncorrected SS	2217	Corrected SS	620.875
Coeff Variation	66.6752434	Std Error Mean	3.32972275

Basic Statistical Measures

Location		Variability	
Mean	14.12500	Std Deviation	9.41788
Median	11.50000	Variance	88.69643
Mode	13.00000	Range	29.00000
		Interquartile Range	9.50000

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	4.242095	Pr > |t|	0.0038
Sign	M	4	Pr >= |M|	0.0078
Signed Rank	S	18	Pr >= |S|	0.0078

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.864008	Pr < W	0.1316
Kolmogorov-Smirnov	D	0.297542	Pr > D	0.0362
Cramer-von Mises	W-Sq	0.102481	Pr > W-Sq	0.0889
Anderson-Darling	A-Sq	0.5563	Pr > A-Sq	0.1021

Quantiles (Definition 5)

Quantile	Estimate
100% Max	33.0
99%	33.0
95%	33.0
90%	33.0
75% Q3	18.0
50% Median	11.5
25% Q1	8.5
10%	4.0
5%	4.0
1%	4.0
0% Min	4.0

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var2

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
4	4	10	8
8	5	13	2
9	1	13	7
10	8	23	3
13	7	33	6

```
Stem Leaf                     #             Boxplot                                 Normal Probability Plot
   3 3                        1                0                  32.5+                                     *  ++++++
   2                                                                  |                                  +++++
   2 3                        1                |                     |                              ++*++
   1                                        +-----+               17.5+                        ++++++
   1 033                      3             *--+--*                   |                     ++*++ *  *
   0 89                       2             +-----+                   |                *++++*
   0 4                        1                |                   2.5+           *++++
     ----+----+----+----+                                             +----+----+----+----+----+----+----+----+----+----+
 Multiply Stem.Leaf by 10**+1                                            -2        -1         0        +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var3

Moments

N	8	Sum Weights	8
Mean	8.75	Sum Observations	70
Std Deviation	2.81577191	Variance	7.92857143
Skewness	-0.4799222	Kurtosis	-0.5644996
Uncorrected SS	668	Corrected SS	55.5
Coeff Variation	32.1802504	Std Error Mean	0.9955257

Basic Statistical Measures

Location		Variability	
Mean	8.750000	Std Deviation	2.81577
Median	9.000000	Variance	7.92857
Mode	8.000000	Range	8.00000
		Interquartile Range	4.00000

Note: The mode displayed is the smallest of 3 modes with a count of 2.

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	8.789326	Pr > |t|	<.0001
Sign	M	4	Pr >= |M|	0.0078
Signed Rank	S	18	Pr >= |S|	0.0078

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.934441	Pr < W	0.5573
Kolmogorov-Smirnov	D	0.171453	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.039783	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.264342	Pr > A-Sq	>0.2500

Quantiles (Definition 5)

Quantile	Estimate
100% Max	12
99%	12
95%	12
90%	12
75% Q3	11
50% Median	9
25% Q1	7
10%	4
5%	4
1%	4
0% Min	4

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var3

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
4	4	8	5
6	8	10	2
8	5	10	7
8	1	12	3
10	7	12	6

```
Stem Leaf                     #             Boxplot                                 Normal Probability Plot
  12 00                       2                |                  12.5+                                  *  ++*+
  11                                           +-----+                 |                                 ++++
  10 00                       2                |     |                 |                            *  *++
   9                                           *-----*                 |                           ++++
   8 00                       2                |  +  |                8.5+                     *  *++
   7                                           +-----+                 |                   ++++
   6 0                        1                   |                    |                 *++
   5                                              |                    |            ++++
   4 0                        1                   |                   4.5+         ++*
     ----+----+----+----+                                                +----+----+----+----+----+----+----+----+----+----+
                                                                            -2        -1         0         +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var4

Moments

N	8	Sum Weights	8
Mean	4	Sum Observations	32
Std Deviation	0.9258201	Variance	0.85714286
Skewness	0	Kurtosis	-2.1
Uncorrected SS	134	Corrected SS	6
Coeff Variation	23.1455025	Std Error Mean	0.32732684

Basic Statistical Measures

Location		Variability	
Mean	4.000000	Std Deviation	0.92582
Median	4.000000	Variance	0.85714
Mode	3.000000	Range	2.00000
		Interquartile Range	2.00000

Note: The mode displayed is the smallest of 2 modes with a count of 3.

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	12.2202	Pr > |t|	<.0001
Sign	M	4	Pr >= |M|	0.0078
Signed Rank	S	18	Pr >= |S|	0.0078

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.801503	Pr < W	0.0297
Kolmogorov-Smirnov	D	0.234956	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.094242	Pr > W-Sq	0.1149
Anderson-Darling	A-Sq	0.66666	Pr > A-Sq	0.0499

Quantiles (Definition 5)

Quantile	Estimate
100% Max	5
99%	5
95%	5
90%	5
75% Q3	5
50% Median	4
25% Q1	3
10%	3
5%	3
1%	3
0% Min	3

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var4

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
3	5	4	6
3	4	4	7
3	2	5	1
4	7	5	3
4	6	5	8

```
Stem Leaf                     #           Boxplot                                  Normal Probability Plot
   5 000                      3           +-----+              5.25+                              *   * +++*++
   4                                      |     |                  |                               +++++
   4 00                       2           *--+--*              4.25+                       * ++*+++
   3                                      |     |                  |                     +++++
   3 000                      3           +-----+              3.25+           *   +*++++*
     ----+----+----+----+                                           +----+----+----+----+----+----+----+----+----+----+
                                                                        -2        -1         0        +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var5

Moments

N	8	Sum Weights	8
Mean	846.625	Sum Observations	6773
Std Deviation	281.325403	Variance	79143.9821
Skewness	-1.4955864	Kurtosis	1.35101985
Uncorrected SS	6288199	Corrected SS	554007.875
Coeff Variation	33.229045	Std Error Mean	99.4635499

Basic Statistical Measures

Location		Variability	
Mean	846.6250	Std Deviation	281.32540
Median	959.5000	Variance	79144
Mode	.	Range	816.00000
		Interquartile Range	295.00000

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	8.511912	Pr > |t|	<.0001
Sign	M	4	Pr >= |M|	0.0078
Signed Rank	S	18	Pr >= |S|	0.0078

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.802337	Pr < W	0.0303
Kolmogorov-Smirnov	D	0.311266	Pr > D	0.0220
Cramer-von Mises	W-Sq	0.148662	Pr > W-Sq	0.0200
Anderson-Darling	A-Sq	0.778126	Pr > A-Sq	0.0245

Quantiles (Definition 5)

Quantile	Estimate
100% Max	1100.0
99%	1100.0
95%	1100.0
90%	1100.0
75% Q3	1015.0
50% Median	959.5
25% Q1	720.0
10%	284.0
5%	284.0
1%	284.0
0% Min	284.0

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var5

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
284	1	954	7
550	8	965	5
890	2	991	6
954	7	1039	4
965	5	1100	3

```
Stem Leaf                     #             Boxplot                                Normal Probability Plot
  11 0                        1                |                 1150+                                  +++ *
  10 4                        1             +-----+                  |                            +++*
   9 569                      3             *-----*                  |                        *   *++*
   8 9                        1             |  +  |                850+                    *   +++
   7                                        +-----+                  |                    ++++
   6                                           |                     |                 +++
   5 5                        1                |                   550+             +++*
   4                                           |                     |          +++
   3                                           |                     |      ++++
   2 8                        1                |                   250+   +++     *
     ----+----+----+----+                                                +----+----+----+----+----+----+----+----+----+----+
 Multiply Stem.Leaf by 10**+2                                              -2        -1         0        +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var6

Moments

N	8	Sum Weights	8
Mean	735.125	Sum Observations	5881
Std Deviation	292.077503	Variance	85309.2679
Skewness	-0.3193885	Kurtosis	0.43155704
Uncorrected SS	4920435	Corrected SS	597164.875
Coeff Variation	39.7316787	Std Error Mean	103.264992

Basic Statistical Measures

Location		Variability	
Mean	735.1250	Std Deviation	292.07750
Median	747.0000	Variance	85309
Mode	.	Range	947.00000
		Interquartile Range	326.00000

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	7.118821	Pr > |t|	0.0002
Sign	M	4	Pr >= |M|	0.0078
Signed Rank	S	18	Pr >= |S|	0.0078

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.979041	Pr < W	0.9580
Kolmogorov-Smirnov	D	0.149831	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.028358	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.180411	Pr > A-Sq	>0.2500

Quantiles (Definition 5)

Quantile	Estimate
100% Max	1170.0
99%	1170.0
95%	1170.0
90%	1170.0
75% Q3	911.5
50% Median	747.0
25% Q1	585.5
10%	223.0
5%	223.0
1%	223.0
0% Min	223.0

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var6

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
223	1	690	4
510	8	804	5
661	2	810	3
690	4	1013	6
804	5	1170	7

```
Stem Leaf                     #             Boxplot                               Normal Probability Plot
  10 17                       2                |                  1100+                                  *+++++*+
   8 01                       2             +-----+                    |                          *+++*++++
   6 69                       2             *--+--*                 700+                    *++*++++
   4 1                        1             +-----+                    |               ++*++++
   2 2                        1                |                   300+       ++++*++
     ----+----+----+----+                                              +----+----+----+----+----+----+----+----+----+----+
 Multiply Stem.Leaf by 10**+2                                             -2        -1         0        +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var7

Moments

N	8	Sum Weights	8
Mean	966.25	Sum Observations	7730
Std Deviation	681.484042	Variance	464420.5
Skewness	0.89247335	Kurtosis	0.08225098
Uncorrected SS	10720056	Corrected SS	3250943.5
Coeff Variation	70.5287495	Std Error Mean	240.940994

Basic Statistical Measures

Location		Variability	
Mean	966.2500	Std Deviation	681.48404
Median	788.5000	Variance	464421
Mode	.	Range	2053
		Interquartile Range	841.00000

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	4.010318	Pr > |t|	0.0051
Sign	M	4	Pr >= |M|	0.0078
Signed Rank	S	18	Pr >= |S|	0.0078

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.92227	Pr < W	0.4486
Kolmogorov-Smirnov	D	0.207493	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.061435	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.35275	Pr > A-Sq	>0.2500

Quantiles (Definition 5)

Quantile	Estimate
100% Max	2193.0
99%	2193.0
95%	2193.0
90%	2193.0
75% Q3	1375.5
50% Median	788.5
25% Q1	534.5
10%	140.0
5%	140.0
1%	140.0
0% Min	140.0

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var7

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
140	3	620	8
467	1	957	2
602	4	1039	6
620	8	1712	5
957	2	2193	7

```
Stem Leaf                     #             Boxplot                                 Normal Probability Plot
   2 2                        1                |                  2250+                                     * +++++++
   1 7                        1                |                      |                              +*+++++++
   1 00                       2             +--+--+               1250+                       ++++*++
   0 566                      3             *-----*                  |                   +*++*++ *
   0 1                        1                |                   250+           *++++*++
     ----+----+----+----+                                             +----+----+----+----+----+----+----+----+----+----+
 Multiply Stem.Leaf by 10**+3                                            -2        -1         0        +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var8

Moments

N	8	Sum Weights	8
Mean	222.125	Sum Observations	1777
Std Deviation	197.375232	Variance	38956.9821
Skewness	2.19590123	Kurtosis	5.25050778
Uncorrected SS	667415	Corrected SS	272698.875
Coeff Variation	88.8577296	Std Error Mean	69.7826824

Basic Statistical Measures

Location		Variability	
Mean	222.1250	Std Deviation	197.37523
Median	160.0000	Variance	38957
Mode	.	Range	608.00000
		Interquartile Range	138.50000

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	3.183096	Pr > |t|	0.0154
Sign	M	4	Pr >= |M|	0.0078
Signed Rank	S	18	Pr >= |S|	0.0078

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.726776	Pr < W	0.0045
Kolmogorov-Smirnov	D	0.266418	Pr > D	0.0921
Cramer-von Mises	W-Sq	0.160334	Pr > W-Sq	0.0138
Anderson-Darling	A-Sq	0.945855	Pr > A-Sq	0.0087

Quantiles (Definition 5)

Quantile	Estimate
100% Max	680.0
99%	680.0
95%	680.0
90%	680.0
75% Q3	245.5
50% Median	160.0
25% Q1	107.0
10%	72.0
5%	72.0
1%	72.0
0% Min	72.0

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var8

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
72	1	120	8
105	5	200	2
109	4	214	6
120	8	277	7
200	2	680	3

```
Stem Leaf                     #             Boxplot                                 Normal Probability Plot
   6 8                        1                *                   650+                                        *     +++++
   5                                                                   |                                         +++++
   4                                                                   |                                   +++++
   3                                                                 350+                              ++++++
   2 018                      3             +--+--+                   |                         +++*+ *   *
   1 012                      3             *-----*                   |                 *  +*++*
   0 7                        1                |                     50+           *  +++++
     ----+----+----+----+                                                +----+----+----+----+----+----+----+----+----+----+
 Multiply Stem.Leaf by 10**+2                                              -2        -1         0        +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var9

Moments

N	8	Sum Weights	8
Mean	337.25	Sum Observations	2698
Std Deviation	191.970794	Variance	36852.7857
Skewness	1.60585675	Kurtosis	3.40137292
Uncorrected SS	1167870	Corrected SS	257969.5
Coeff Variation	56.9224	Std Error Mean	67.8719251

Basic Statistical Measures

Location		Variability	
Mean	337.2500	Std Deviation	191.97079
Median	321.0000	Variance	36853
Mode	.	Range	615.00000
		Interquartile Range	176.50000

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	4.968918	Pr > |t|	0.0016
Sign	M	4	Pr >= |M|	0.0078
Signed Rank	S	18	Pr >= |S|	0.0078

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.852659	Pr < W	0.1014
Kolmogorov-Smirnov	D	0.246882	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.079194	Pr > W-Sq	0.1903
Anderson-Darling	A-Sq	0.518518	Pr > A-Sq	0.1326

Quantiles (Definition 5)

Quantile	Estimate
100% Max	755.0
99%	755.0
95%	755.0
90%	755.0
75% Q3	378.5
50% Median	321.0
25% Q1	202.0
10%	140.0
5%	140.0
1%	140.0
0% Min	140.0

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var9

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
140	6	298	4
170	3	344	2
234	1	357	5
298	4	400	8
344	2	755	7

```
Stem Leaf                     #             Boxplot                                 Normal Probability Plot
   7 6                        1                0                  750+                                       *    ++++++
   6                                                                  |                                       +++++
   5                                                                  |                                 +++++
   4 0                        1                |                  450+                            +++++*
   3 046                      3             +--+--+                  |                        +++*+ *
   2 3                        1             +-----+                  |                  ++*++*
   1 47                       2                |                  150+           * +++*+
     ----+----+----+----+                                             +----+----+----+----+----+----+----+----+----+----+
 Multiply Stem.Leaf by 10**+2                                            -2        -1         0        +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var10

Moments

N	8	Sum Weights	8
Mean	85.875	Sum Observations	687
Std Deviation	45.6428292	Variance	2083.26786
Skewness	-0.9220831	Kurtosis	0.69789348
Uncorrected SS	73579	Corrected SS	14582.875
Coeff Variation	53.1503106	Std Error Mean	16.137177

Basic Statistical Measures

Location		Variability	
Mean	85.87500	Std Deviation	45.64283
Median	96.00000	Variance	2083
Mode	.	Range	144.00000
		Interquartile Range	52.50000

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	5.321563	Pr > |t|	0.0011
Sign	M	3.5	Pr >= |M|	0.0156
Signed Rank	S	14	Pr >= |S|	0.0156

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.941561	Pr < W	0.6265
Kolmogorov-Smirnov	D	0.198791	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.048419	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.288431	Pr > A-Sq	>0.2500

Quantiles (Definition 5)

Quantile	Estimate
100% Max	144.0
99%	144.0
95%	144.0
90%	144.0
75% Q3	114.0
50% Median	96.0
25% Q1	61.5
10%	0.0
5%	0.0
1%	0.0
0% Min	0.0

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var10

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
0	8	89	6
43	4	103	2
80	1	108	7
89	6	120	3
103	2	144	5

```
Stem Leaf                     #             Boxplot                                 Normal Probability Plot
  14 4                        1                |                   150+                                     ++*++
  12 0                        1                |                      |                                +*++
  10 38                       2             +-----+                   |                           * +*++
   8 09                       2             *--+--*                   |                     *  *+++++
   6                                        +-----+                   |                     ++++
   4 3                        1                |                      |                +*+++
   2                                           |                      |            ++++
   0 0                        1                |                    10+       ++++*
     ----+----+----+----+                                                +----+----+----+----+----+----+----+----+----+----+
 Multiply Stem.Leaf by 10**+1                                              -2        -1         0        +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var11

Moments

N	8	Sum Weights	8
Mean	471.875	Sum Observations	3775
Std Deviation	494.961308	Variance	244986.696
Skewness	1.66908836	Kurtosis	3.69904061
Uncorrected SS	3496235	Corrected SS	1714906.88
Coeff Variation	104.892463	Std Error Mean	174.995249

Basic Statistical Measures

Location		Variability	
Mean	471.8750	Std Deviation	494.96131
Median	448.0000	Variance	244987
Mode	0.0000	Range	1560
		Interquartile Range	440.50000

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	2.696502	Pr > |t|	0.0308
Sign	M	3	Pr >= |M|	0.0313
Signed Rank	S	10.5	Pr >= |S|	0.0313

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.819148	Pr < W	0.0457
Kolmogorov-Smirnov	D	0.298798	Pr > D	0.0346
Cramer-von Mises	W-Sq	0.100764	Pr > W-Sq	0.0930
Anderson-Darling	A-Sq	0.626494	Pr > A-Sq	0.0685

Quantiles (Definition 5)

Quantile	Estimate
100% Max	1560.0
99%	1560.0
95%	1560.0
90%	1560.0
75% Q3	550.0
50% Median	448.0
25% Q1	109.5
10%	0.0
5%	0.0
1%	0.0
0% Min	0.0

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var11

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
0	6	386	2
0	4	510	8
219	1	533	5
386	2	567	7
510	8	1560	3

```
Stem Leaf                     #             Boxplot                                 Normal Probability Plot
  14 6                        1                0                 1500+                                        *    ++++
  12                                                                 |                                        ++++
  10                                                                 |                                    ++++
   8                                                                 |                                ++++
   6                                                                 |                            ++++
   4 137                      3             +--+--+                  |                       +++*  *   *
   2 29                       2             |     |                  |                    *+++
   0 00                       2             +-----+                100+           *    *+++
     ----+----+----+----+                                              +----+----+----+----+----+----+----+----+----+----+
 Multiply Stem.Leaf by 10**+2                                              -2        -1         0        +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var12

Moments

N	8	Sum Weights	8
Mean	585.375	Sum Observations	4683
Std Deviation	444.651047	Variance	197714.554
Skewness	0.71875089	Kurtosis	-0.8769028
Uncorrected SS	4125313	Corrected SS	1384001.88
Coeff Variation	75.9600336	Std Error Mean	157.207885

Basic Statistical Measures

Location		Variability	
Mean	585.3750	Std Deviation	444.65105
Median	446.5000	Variance	197715
Mode	.	Range	1223
		Interquartile Range	710.50000

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	3.723573	Pr > |t|	0.0074
Sign	M	4	Pr >= |M|	0.0078
Signed Rank	S	18	Pr >= |S|	0.0078

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.91555	Pr < W	0.3948
Kolmogorov-Smirnov	D	0.189649	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.053325	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.326591	Pr > A-Sq	>0.2500

Quantiles (Definition 5)

Quantile	Estimate
100% Max	1323.0
99%	1323.0
95%	1323.0
90%	1323.0
75% Q3	947.0
50% Median	446.5
25% Q1	236.5
10%	100.0
5%	100.0
1%	100.0
0% Min	100.0

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var12

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
100	3	380	8
183	5	513	2
290	6	795	1
380	8	1099	4
513	2	1323	7

```
Stem Leaf                     #             Boxplot                                 Normal Probability Plot
  12 2                        1                |                  1300+                                        *++++
  10 0                        1                |                      |                                    *++++
   8 0                        1             +-----+                   |                                +++++
   6                                        |     |                700+                           ++++*
   4 1                        1             *--+--*                   |                       +++++ *
   2 98                       2             +-----+                   |                  +++*  *
   0 08                       2                |                   100+            *+++++*
     ----+----+----+----+                                                +----+----+----+----+----+----+----+----+----+----+
 Multiply Stem.Leaf by 10**+2                                              -2        -1         0        +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var13

Moments

N	8	Sum Weights	8
Mean	4315.25	Sum Observations	34522
Std Deviation	1481.45746	Variance	2194716.21
Skewness	1.09021938	Kurtosis	2.28105949
Uncorrected SS	164334074	Corrected SS	15363013.5
Coeff Variation	34.3307448	Std Error Mean	523.774309

Basic Statistical Measures

Location		Variability	
Mean	4315.250	Std Deviation	1481
Median	4227.000	Variance	2194716
Mode	.	Range	4970
		Interquartile Range	1309

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	8.238758	Pr > |t|	<.0001
Sign	M	4	Pr >= |M|	0.0078
Signed Rank	S	18	Pr >= |S|	0.0078

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.91366	Pr < W	0.3806
Kolmogorov-Smirnov	D	0.245988	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.060214	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.380063	Pr > A-Sq	>0.2500

Quantiles (Definition 5)

Quantile	Estimate
100% Max	7345.0
99%	7345.0
95%	7345.0
90%	7345.0
75% Q3	4741.5
50% Median	4227.0
25% Q1	3432.5
10%	2375.0
5%	2375.0
1%	2375.0
0% Min	2375.0

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var13

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
2375	1	3881	4
3090	8	4573	2
3775	6	4680	3
3881	4	4803	5
4573	2	7345	7

```
Stem Leaf                     #             Boxplot                                 Normal Probability Plot
   7 3                        1                0                  7500+                                        *    ++++++
   6                                                                  |                                   +++++++
   5                                                                  |                              +++++++
   4 678                      3             +--+--+                  |                       ++++*++*   *
   3 189                      3             +-----+                  |                 *+++*++*
   2 4                        1                |                  2500+          +*+++++
     ----+----+----+----+                                             +----+----+----+----+----+----+----+----+----+----+
 Multiply Stem.Leaf by 10**+3                                            -2        -1         0        +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var14

Moments

N	8	Sum Weights	8
Mean	90.375	Sum Observations	723
Std Deviation	54.0209946	Variance	2918.26786
Skewness	1.08585099	Kurtosis	-0.3877307
Uncorrected SS	85769	Corrected SS	20427.875
Coeff Variation	59.7742679	Std Error Mean	19.0993058

Basic Statistical Measures

Location		Variability	
Mean	90.37500	Std Deviation	54.02099
Median	73.00000	Variance	2918
Mode	.	Range	140.00000
		Interquartile Range	76.50000

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	4.731847	Pr > |t|	0.0021
Sign	M	4	Pr >= |M|	0.0078
Signed Rank	S	18	Pr >= |S|	0.0078

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.81937	Pr < W	0.0460
Kolmogorov-Smirnov	D	0.274908	Pr > D	0.0747
Cramer-von Mises	W-Sq	0.117784	Pr > W-Sq	0.0519
Anderson-Darling	A-Sq	0.679145	Pr > A-Sq	0.0470

Quantiles (Definition 5)

Quantile	Estimate
100% Max	178.0
99%	178.0
95%	178.0
90%	178.0
75% Q3	128.5
50% Median	73.0
25% Q1	52.0
10%	38.0
5%	38.0
1%	38.0
0% Min	38.0

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var14

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
38	1	71	6
45	4	75	3
59	5	87	2
71	6	170	8
75	3	178	7

```
Stem Leaf                     #             Boxplot                                 Normal Probability Plot
  16 08                       2                |                   170+                                  *   +*++
  14                                           |                      |                                   +++
  12                                           +-----+                |                              ++++
  10                                           |     |                |                           ++++
   8 7                        1                |  +  |                |                        +++   *
   6 15                       2                *-----*                |                    +++*   *
   4 59                       2                +-----+                |                *++++*
   2 8                        1                   |                    30+           *++++
     ----+----+----+----+                                                +----+----+----+----+----+----+----+----+----+----+
 Multiply Stem.Leaf by 10**+1                                                -2        -1         0         +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var15

Moments

N	8	Sum Weights	8
Mean	788.375	Sum Observations	6307
Std Deviation	740.172362	Variance	547855.125
Skewness	2.35449393	Kurtosis	6.06531906
Uncorrected SS	8807267	Corrected SS	3834985.88
Coeff Variation	93.8858236	Std Error Mean	261.690448

Basic Statistical Measures

Location		Variability	
Mean	788.3750	Std Deviation	740.17236
Median	583.0000	Variance	547855
Mode	.	Range	2351
		Interquartile Range	409.00000

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	3.012624	Pr > |t|	0.0196
Sign	M	4	Pr >= |M|	0.0078
Signed Rank	S	18	Pr >= |S|	0.0078

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.705571	Pr < W	0.0026
Kolmogorov-Smirnov	D	0.337528	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.185555	Pr > W-Sq	0.0058
Anderson-Darling	A-Sq	1.047666	Pr > A-Sq	<0.0050

Quantiles (Definition 5)

Quantile	Estimate
100% Max	2540.0
99%	2540.0
95%	2540.0
90%	2540.0
75% Q3	807.5
50% Median	583.0
25% Q1	398.5
10%	189.0
5%	189.0
1%	189.0
0% Min	189.0

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var15

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
189	4	518	5
349	1	648	2
448	3	757	8
518	5	858	7
648	2	2540	6

```
Stem Leaf                     #             Boxplot                                 Normal Probability Plot
   2 5                        1                *                 2750+                                        *         ++
   2                                                                 |                                        +++++++
   1                                                                 |                                 +++++++
   1                                                                 |                            +++++++
   0 5689                     4             +--+--+                  |                       +*++++*  *   *
   0 234                      3             +-----+                250+            *   +*++++*+
     ----+----+----+----+                                            +----+----+----+----+----+----+----+----+----+----+
 Multiply Stem.Leaf by 10**+3                                           -2        -1         0        +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var17

Moments

N	8	Sum Weights	8
Mean	466983.75	Sum Observations	3735870
Std Deviation	139484.97	Variance	1.94561E10
Skewness	1.26017026	Kurtosis	0.12438973
Uncorrected SS	1.88078E12	Corrected SS	1.36192E11
Coeff Variation	29.8693413	Std Error Mean	49315.3841

Basic Statistical Measures

Location		Variability	
Mean	466983.8	Std Deviation	139485
Median	410088.5	Variance	1.94561E10
Mode	.	Range	370926
		Interquartile Range	186260

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	9.469332	Pr > |t|	<.0001
Sign	M	4	Pr >= |M|	0.0078
Signed Rank	S	18	Pr >= |S|	0.0078

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.804373	Pr < W	0.0319
Kolmogorov-Smirnov	D	0.258751	Pr > D	0.1136
Cramer-von Mises	W-Sq	0.132793	Pr > W-Sq	0.0328
Anderson-Darling	A-Sq	0.732218	Pr > A-Sq	0.0346

Quantiles (Definition 5)

Quantile	Estimate
100% Max	720453
99%	720453
95%	720453
90%	720453
75% Q3	554558
50% Median	410089
25% Q1	368299
10%	349527
5%	349527
1%	349527
0% Min	349527

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var17

Extreme Observations

-----Lowest-----		-----Highest----	
Value	Obs	Value	Obs
349527	3	396157	4
363703	1	424020	2
372894	5	463924	6
396157	4	645192	7
424020	2	720453	8

```
Stem Leaf                     #             Boxplot                                 Normal Probability Plot
   7 2                        1                |               725000+                                      *  ++++
   6 5                        1                |                     |                                      +++
   6                                           |                     |                                *++++
   5                                     +-----+                     |                              ++++
   5                                     |     |               525000+                           +++
   4 6                        1          |  +  |                     |                       ++++  *
   4 02                       2          *-----*                     |                    +++   *
   3 567                      3          +-----+                     |                *++++*  *
   3                                                           325000+           *  +++
     ----+----+----+----+                                              +----+----+----+----+----+----+----+----+----+----+
 Multiply Stem.Leaf by 10**+5                                              -2        -1         0        +1        +2
```

Deskriptivna statistika

The FREQ Procedure

var16	Frequency	Percent	Cumulative Frequency	Cumulative Percent
1	1	12.50	1	12.50
2	7	87.50	8	100.00

multivarijatna regresija-dijagnostika model

The CORR Procedure

16 Variables: var1 var2 var3 var4 var5 var6 var7 var8 var9 var10 var11 var12 var13 var14 var15 var17

Simple Statistics

Variable	N	Mean	Std Dev	Sum	Minimum	Maximum
var1	8	123.00000	97.46208	984.00000	10.00000	293.00000
var2	8	14.12500	9.41788	113.00000	4.00000	33.00000
var3	8	8.75000	2.81577	70.00000	4.00000	12.00000
var4	8	4.00000	0.92582	32.00000	3.00000	5.00000
var5	8	846.62500	281.32540	6773	284.00000	1100
var6	8	735.12500	292.07750	5881	223.00000	1170
var7	8	966.25000	681.48404	7730	140.00000	2193
var8	8	222.12500	197.37523	1777	72.00000	680.00000
var9	8	337.25000	191.97079	2698	140.00000	755.00000
var10	8	85.87500	45.64283	687.00000	0	144.00000
var11	8	471.87500	494.96131	3775	0	1560
var12	8	585.37500	444.65105	4683	100.00000	1323
var13	8	4315	1481	34522	2375	7345
var14	8	90.37500	54.02099	723.00000	38.00000	178.00000
var15	8	788.37500	740.17236	6307	189.00000	2540
var17	8	466984	139485	3735870	349527	720453

Pearson Correlation Coefficients, N = 8
Prob > |r| under H0: Rho=0

	var1	var2	var3	var4	var5	var6	var7	var8
var1	1.00000	-0.02770	0.27590	-0.63804	0.37942	0.47058	0.59094	-0.01987
		0.9481	0.5083	0.0887	0.3539	0.2393	0.1229	0.9628
var2	-0.02770	1.00000	0.83634	0.27853	0.33637	0.47218	-0.09398	0.53235
	0.9481		0.0097	0.5041	0.4153	0.2375	0.8248	0.1744
var3	0.27590	0.83634	1.00000	0.21920	0.30951	0.47998	0.11692	0.64808
	0.5083	0.0097		0.6020	0.4557	0.2287	0.7828	0.0822

	var9	var10	var11	var12	var13	var14	var15	var17
var1	0.50656	0.43238	-0.14499	0.38700	0.66768	0.18942	0.05354	0.02807
	0.2002	0.2847	0.7319	0.3436	0.0704	0.6532	0.8998	0.9474
var2	-0.40600	0.25926	0.19252	-0.46376	0.05886	-0.00151	0.82438	-0.05167
	0.3183	0.5352	0.6478	0.2471	0.8899	0.9972	0.0118	0.9033
var3	-0.15262	0.63442	0.44022	-0.39208	0.34454	0.04860	0.54587	-0.15830
	0.7182	0.0911	0.2750	0.3367	0.4033	0.9090	0.1616	0.7081

	var1	var2	var3	var4	var5	var6	var7	var8
var4	-0.63804	0.27853	0.21920	1.00000	-0.52655	-0.32332	-0.46281	0.35805
	0.0887	0.5041	0.6020		0.1800	0.4347	0.2482	0.3838
var5	0.37942	0.33637	0.30951	-0.52655	1.00000	0.79445	0.24908	0.51173
	0.3539	0.4153	0.4557	0.1800		0.0185	0.5519	0.1949
var6	0.47058	0.47218	0.47998	-0.32332	0.79445	1.00000	0.64159	0.38271
	0.2393	0.2375	0.2287	0.4347	0.0185		0.0864	0.3494
var7	0.59094	-0.09398	0.11692	-0.46281	0.24908	0.64159	1.00000	-0.26256
	0.1229	0.8248	0.7828	0.2482	0.5519	0.0864		0.5299
var8	-0.01987	0.53235	0.64808	0.35805	0.51173	0.38271	-0.26256	1.00000
	0.9628	0.1744	0.0822	0.3838	0.1949	0.3494	0.5299	
var9	0.50656	-0.40600	-0.15262	-0.15674	0.02264	0.39674	0.75903	-0.15452
	0.2002	0.3183	0.7182	0.7109	0.9576	0.3305	0.0290	0.7149
var10	0.43238	0.25926	0.63442	-0.30426	0.44087	0.42923	0.41632	0.38263
	0.2847	0.5352	0.0911	0.4637	0.2742	0.2886	0.3049	0.3495
var11	-0.14499	0.19252	0.44022	0.42710	0.26827	0.14280	-0.20557	0.86199
	0.7319	0.6478	0.2750	0.2913	0.5206	0.7359	0.6253	0.0059
var12	0.38700	-0.46376	-0.39208	-0.18045	-0.10896	0.10528	0.36037	-0.32431
	0.3436	0.2471	0.3367	0.6689	0.7973	0.8041	0.3805	0.4332
var13	0.66768	0.05886	0.34454	-0.32413	0.61020	0.82483	0.74833	0.36171
	0.0704	0.8899	0.4033	0.4335	0.1082	0.0117	0.0327	0.3786
var14	0.18942	-0.00151	0.04860	0.26279	-0.03783	0.36763	0.42890	0.08762
	0.6532	0.9972	0.9090	0.5295	0.9291	0.3703	0.2890	0.8366
var15	0.05354	0.82438	0.54587	0.04149	0.19020	0.49060	0.21023	0.00536
	0.8998	0.0118	0.1616	0.9223	0.6519	0.2171	0.6173	0.9899
var17	0.02807	-0.05167	-0.15830	0.26617	-0.19940	0.22296	0.35358	-0.17837
	0.9474	0.9033	0.7081	0.5240	0.6359	0.5956	0.3902	0.6726

	var9	var10	var11	var12	var13	var14	var15	var17
var4	-0.15674	-0.30426	0.42710	-0.18045	-0.32413	0.26279	0.04149	0.26617
	0.7109	0.4637	0.2913	0.6689	0.4335	0.5295	0.9223	0.5240
var5	0.02264	0.44087	0.26827	-0.10896	0.61020	-0.03783	0.19020	-0.19940

	0.9576	0.2742	0.5206	0.7973	0.1082	0.9291	0.6519	0.6359
var6	0.39674	0.42923	0.14280	0.10528	0.82483	0.36763	0.49060	0.22296
	0.3305	0.2886	0.7359	0.8041	0.0117	0.3703	0.2171	0.5956

	var9	var10	var11	var12	var13	var14	var15	var17
var7	0.75903	0.41632	-0.20557	0.36037	0.74833	0.42890	0.21023	0.35358
	0.0290	0.3049	0.6253	0.3805	0.0327	0.2890	0.6173	0.3902
var8	-0.15452	0.38263	0.86199	-0.32431	0.36171	0.08762	0.00536	-0.17837
	0.7149	0.3495	0.0059	0.4332	0.3786	0.8366	0.9899	0.6726
var9	1.00000	0.01766	-0.00229	0.64342	0.73494	0.75133	-0.19993	0.65032
		0.9669	0.9957	0.0852	0.0378	0.0316	0.6350	0.0808
var10	0.01766	1.00000	0.36858	-0.22110	0.51929	-0.29622	0.03490	-0.54757
	0.9669		0.3689	0.5988	0.1872	0.4762	0.9346	0.1601
var11	-0.00229	0.36858	1.00000	-0.41555	0.31105	0.19668	-0.31274	-0.08747
	0.9957	0.3689		0.3059	0.4533	0.6406	0.4507	0.8368
var12	0.64342	-0.22110	-0.41555	1.00000	0.35226	0.23819	-0.24975	0.27697
	0.0852	0.5988	0.3059		0.3921	0.5700	0.5508	0.5066
var13	0.73494	0.51929	0.31105	0.35226	1.00000	0.49612	0.01611	0.25051
	0.0378	0.1872	0.4533	0.3921		0.2111	0.9698	0.5496
var14	0.75133	-0.29622	0.19668	0.23819	0.49612	1.00000	0.12170	0.93625
	0.0316	0.4762	0.6406	0.5700	0.2111		0.7741	0.0006
var15	-0.19993	0.03490	-0.31274	-0.24975	0.01611	0.12170	1.00000	0.21915
	0.6350	0.9346	0.4507	0.5508	0.9698	0.7741		0.6021
var17	0.65032	-0.54757	-0.08747	0.27697	0.25051	0.93625	0.21915	1.00000
	0.0808	0.1601	0.8368	0.5066	0.5496	0.0006	0.6021	

multivarijatna regresija-dijagnostika model

The REG Procedure
Model: MODEL1
Dependent Variable: var17

R-Square Selection Method

Number of Observations Read 8
Number of Observations Used 8

Number in Model	R-Square	Adjusted R-Square	C(p)	Root MSE	Variables in Model
1	0.8766	0.8560	.	52932	var14
1	0.5391	0.4623	.	102280	var16
1	0.4229	0.3267	.	114451	var9
1	0.2998	0.1831	.	126067	var10
1	0.1250	-.0208	.	140929	var7
1	0.0767	-.0772	.	144767	var12
1	0.0708	-.0840	.	145226	var4
1	0.0628	-.0935	.	145857	var13
1	0.0497	-.1087	.	146869	var6
1	0.0480	-.1106	.	146999	var15
1	0.0398	-.1203	.	147636	var5
1	0.0318	-.1296	.	148245	var8
1	0.0251	-.1374	.	148761	var3
1	0.0077	-.1577	.	150084	var11
1	0.0027	-.1636	.	150460	var2
1	0.0008	-.1657	.	150602	var1
2	0.9566	0.9393	.	34375	var10 var14
2	0.9533	0.9346	.	35664	var11 var14
2	0.9449	0.9229	.	38741	var8 var14
2	0.9373	0.9122	.	41323	var13 var14
2	0.9249	0.8949	.	45222	var14 var16
2	0.9182	0.8855	.	47203	var3 var14
2	0.9035	0.8649	.	51271	var5 var14
2	0.8997	0.8596	.	52274	var1 var14
2	0.8936	0.8510	.	53844	var6 var14
2	0.8878	0.8429	.	55283	var14 var15
2	0.8830	0.8363	.	56442	var9 var14
2	0.8797	0.8315	.	57254	var12 var14
2	0.8794	0.8311	.	57318	var7 var14
2	0.8791	0.8307	.	57388	var2 var14
2	0.8770	0.8278	.	57882	var4 var14
2	0.8507	0.7910	.	63760	var9 var16
3	0.9967	0.9942	.	10656	var1 var11 var14
3	0.9897	0.9820	.	18722	var11 var14 var16
3	0.9867	0.9768	.	21253	var11 var13 var14
3	0.9852	0.9741	.	22432	var3 var14 var15
3	0.9843	0.9725	.	23130	var10 var11 var14
3	0.9825	0.9695	.	24378	var7 var10 var14
3	0.9806	0.9661	.	25689	var8 var10 var14
3	0.9767	0.9593	.	28146	var8 var9 var14
3	0.9765	0.9588	.	28311	var7 var11 var14
3	0.9754	0.9570	.	28917	var9 var11 var14
3	0.9736	0.9538	.	29974	var4 var11 var14
3	0.9733	0.9533	.	30131	var9 var15 var16
3	0.9729	0.9525	.	30386	var10 var14 var15
3	0.9711	0.9494	.	31366	var1 var8 var14
3	0.9710	0.9493	.	31413	var8 var13 var14
3	0.9670	0.9423	.	33497	var7 var8 var14
4	0.9988	0.9972	.	7370.23342	var1 var11 var14 var16
4	0.9986	0.9968	.	7835.12257	var1 var7 var11 var14
4	0.9986	0.9967	.	8068.20685	var1 var10 var11 var14
4	0.9985	0.9965	.	8302.07700	var1 var9 var11 var14
4	0.9983	0.9961	.	8752.72865	var6 var9 var13 var14
4	0.9983	0.9960	.	8768.56444	var3 var5 var14 var15
4	0.9982	0.9959	.	8981.38281	var7 var9 var15 var16
4	0.9981	0.9957	.	9187.89008	var3 var6 var14 var15
4	0.9981	0.9957	.	9199.65720	var1 var11 var13 var14
4	0.9974	0.9939	.	10879	var1 var11 var12 var14
4	0.9969	0.9927	.	11915	var1 var6 var11 var14
4	0.9968	0.9925	.	12063	var1 var4 var11 var14
4	0.9968	0.9925	.	12106	var1 var5 var11 var14
4	0.9968	0.9925	.	12106	var1 var8 var11 var14
4	0.9967	0.9924	.	12174	var1 var3 var11 var14
4	0.9967	0.9923	.	12231	var1 var2 var11 var14
5	1.0000	1.0000	.	567.32506	var1 var3 var9 var11 var14
5	1.0000	0.9999	.	1103.25872	var7 var12 var14 var15 var16
5	1.0000	0.9998	.	1806.08498	var1 var8 var11 var14 var16
5	0.9999	0.9997	.	2462.12641	var1 var10 var11 var12 var14
5	0.9999	0.9997	.	2509.70206	var9 var12 var14 var15 var16
5	0.9999	0.9997	.	2534.02739	var2 var3 var5 var14 var15
5	0.9999	0.9996	.	2704.75002	var2 var8 var9 var10 var16
5	0.9999	0.9996	.	2940.80425	var1 var5 var11 var13 var14
5	0.9999	0.9995	.	3011.78802	var2 var9 var10 var11 var16
5	0.9999	0.9995	.	3165.13893	var8 var10 var11 var12 var16
5	0.9998	0.9994	.	3281.12279	var3 var5 var8 var14 var15
5	0.9998	0.9994	.	3344.16625	var3 var5 var7 var14 var15
5	0.9998	0.9994	.	3396.41567	var3 var5 var10 var14 var15
5	0.9998	0.9994	.	3483.42250	var7 var9 var12 var14 var16
5	0.9998	0.9993	.	3674.03879	var6 var9 var10 var13 var14
5	0.9998	0.9993	.	3811.88325	var2 var9 var10 var15 var16
6	1.0000	1.0000	.	1.17692	var1 var3 var6 var9 var11 var14
6	1.0000	1.0000	.	6.21999	var1 var3 var5 var9 var11 var14
6	1.0000	1.0000	.	16.68932	var6 var7 var8 var9 var13 var14
6	1.0000	1.0000	.	22.90418	var1 var4 var6 var7 var8 var14
6	1.0000	1.0000	.	26.20191	var4 var5 var7 var12 var13 var14
6	1.0000	1.0000	.	28.18184	var5 var8 var10 var11 var12 var16
6	1.0000	1.0000	.	33.37122	var1 var6 var12 var13 var15 var16
6	1.0000	1.0000	.	45.99396	var1 var3 var9 var11 var13 var14
6	1.0000	1.0000	.	47.41353	var2 var4 var7 var8 var13 var16
6	1.0000	1.0000	.	51.79702	var1 var2 var7 var8 var10 var14
6	1.0000	1.0000	.	69.98733	var3 var4 var6 var11 var14 var16
6	1.0000	1.0000	.	75.43225	var7 var8 var10 var11 var13 var14

6	1.0000	1.0000	.	84.63494	var1 var3 var5 var6 var12 var16
6	1.0000	1.0000	.	98.45202	var1 var6 var7 var11 var14 var16
6	1.0000	1.0000	.	107.86820	var2 var9 var10 var13 var15 var16
6	1.0000	1.0000	.	110.70295	var3 var6 var7 var13 var14 var16
7	1.0000	.	.	.	var4 var6 var8 var9 var10 var13 var16
7	1.0000	.	.	.	var1 var5 var7 var8 var9 var13 var16
7	1.0000	.	.	.	var4 var6 var7 var9 var10 var13 var16
7	1.0000	.	.	.	var4 var7 var8 var9 var10 var13 var16
7	1.0000	.	.	.	var1 var2 var6 var9 var11 var13 var16
7	1.0000	.	.	.	var4 var6 var8 var9 var12 var13 var16
7	1.0000	.	.	.	var5 var8 var9 var12 var13 var15 var16
7	1.0000	.	.	.	var4 var6 var7 var8 var10 var13 var16
7	1.0000	.	.	.	var2 var3 var6 var7 var9 var13 var16
7	1.0000	.	.	.	var4 var6 var7 var8 var9 var10 var16
7	1.0000	.	.	.	var2 var4 var5 var8 var14 var15 var16
7	1.0000	.	.	.	var1 var4 var5 var9 var10 var13 var16
7	1.0000	.	.	.	var1 var2 var4 var9 var13 var15 var16
7	1.0000	.	.	.	var3 var5 var7 var8 var9 var13 var16
7	1.0000	.	.	.	var3 var6 var9 var11 var13 var15 var16
7	1.0000	.	.	.	var1 var3 var5 var6 var13 var15 var16

NOTE: Models of not full rank are not included.

The REG Procedure
Model: MODEL1
Dependent Variable: var17

R-Square Selection Method

Number of Observations Read 8
Number of Observations Used 8

Number in Model	R-Square	Adjusted R-Square	C(p)	Root MSE	Variables in Model
1	0.8766	0.8560	.	52932	var14
1	0.5391	0.4623	.	102280	var16
1	0.4229	0.3267	.	114451	var9
1	0.2998	0.1831	.	126067	var10
1	0.1250	-.0208	.	140929	var7
1	0.0767	-.0772	.	144767	var12
1	0.0708	-.0840	.	145226	var4
1	0.0628	-.0935	.	145857	var13
1	0.0497	-.1087	.	146869	var6
1	0.0480	-.1106	.	146999	var15
1	0.0398	-.1203	.	147636	var5
1	0.0318	-.1296	.	148245	var8
1	0.0251	-.1374	.	148761	var3
1	0.0077	-.1577	.	150084	var11
1	0.0027	-.1636	.	150460	var2
1	0.0008	-.1657	.	150602	var1
2	0.9566	0.9393	.	34375	var10 var14
2	0.9533	0.9346	.	35664	var11 var14
2	0.9449	0.9229	.	38741	var8 var14
2	0.9373	0.9122	.	41323	var13 var14
2	0.9249	0.8949	.	45222	var14 var16
2	0.9182	0.8855	.	47203	var3 var14
2	0.9035	0.8649	.	51271	var5 var14
2	0.8997	0.8596	.	52274	var1 var14
2	0.8936	0.8510	.	53844	var6 var14
2	0.8878	0.8429	.	55283	var14 var15
2	0.8830	0.8363	.	56442	var9 var14
2	0.8797	0.8315	.	57254	var12 var14
2	0.8794	0.8311	.	57318	var7 var14
2	0.8791	0.8307	.	57388	var2 var14
2	0.8770	0.8278	.	57882	var4 var14
2	0.8507	0.7910	.	63760	var9 var16
3	0.9967	0.9942	.	10656	var1 var11 var14
3	0.9897	0.9820	.	18722	var11 var14 var16
3	0.9867	0.9768	.	21253	var11 var13 var14
3	0.9852	0.9741	.	22432	var3 var14 var15
3	0.9843	0.9725	.	23130	var10 var11 var14
3	0.9825	0.9695	.	24378	var7 var10 var14
3	0.9806	0.9661	.	25689	var8 var10 var14
3	0.9767	0.9593	.	28146	var8 var9 var14
3	0.9765	0.9588	.	28311	var7 var11 var14
3	0.9754	0.9570	.	28917	var9 var11 var14
3	0.9736	0.9538	.	29974	var4 var11 var14
3	0.9733	0.9533	.	30131	var9 var15 var16
3	0.9729	0.9525	.	30386	var10 var14 var15
3	0.9711	0.9494	.	31366	var1 var8 var14
3	0.9710	0.9493	.	31413	var8 var13 var14
3	0.9670	0.9423	.	33497	var7 var8 var14
4	0.9988	0.9972	.	7370.23342	var1 var11 var14 var16
4	0.9986	0.9968	.	7835.12257	var1 var7 var11 var14
4	0.9986	0.9967	.	8068.20685	var1 var10 var11 var14
4	0.9985	0.9965	.	8302.07700	var1 var9 var11 var14
4	0.9983	0.9961	.	8752.72865	var6 var9 var13 var14
4	0.9983	0.9960	.	8768.56444	var3 var5 var14 var15
4	0.9982	0.9959	.	8981.38281	var7 var9 var15 var16
4	0.9981	0.9957	.	9187.89008	var3 var6 var14 var15
4	0.9981	0.9957	.	9199.65720	var1 var11 var13 var14
4	0.9974	0.9939	.	10879	var1 var11 var12 var14
4	0.9969	0.9927	.	11915	var1 var6 var11 var14
4	0.9968	0.9925	.	12063	var1 var4 var11 var14
4	0.9968	0.9925	.	12106	var1 var5 var11 var14
4	0.9968	0.9925	.	12106	var1 var8 var11 var14
4	0.9967	0.9924	.	12174	var1 var3 var11 var14
4	0.9967	0.9923	.	12231	var1 var2 var11 var14
5	1.0000	1.0000	.	567.32506	var1 var3 var9 var11 var14
5	1.0000	0.9999	.	1103.25872	var7 var12 var14 var15 var16
5	1.0000	0.9998	.	1806.08498	var1 var8 var11 var14 var16
5	0.9999	0.9997	.	2462.12641	var1 var10 var11 var12 var14
5	0.9999	0.9997	.	2509.70206	var9 var12 var14 var15 var16
5	0.9999	0.9997	.	2534.02739	var2 var3 var5 var14 var15
5	0.9999	0.9996	.	2704.75002	var2 var8 var9 var10 var16
5	0.9999	0.9996	.	2940.80425	var1 var5 var11 var13 var14
5	0.9999	0.9995	.	3011.78802	var2 var9 var10 var11 var16
5	0.9999	0.9995	.	3165.13893	var8 var10 var11 var12 var16
5	0.9998	0.9994	.	3281.12279	var3 var5 var8 var14 var15
5	0.9998	0.9994	.	3344.16625	var3 var5 var7 var14 var15
5	0.9998	0.9994	.	3396.41567	var3 var5 var10 var14 var15
5	0.9998	0.9994	.	3483.42250	var7 var9 var12 var14 var16
5	0.9998	0.9993	.	3674.03879	var6 var9 var10 var13 var14
5	0.9998	0.9993	.	3811.88325	var2 var9 var10 var15 var16
6	1.0000	1.0000	.	1.17692	var1 var3 var6 var9 var11 var14
6	1.0000	1.0000	.	6.21999	var1 var3 var5 var9 var11 var14
6	1.0000	1.0000	.	16.68932	var6 var7 var8 var9 var13 var14
6	1.0000	1.0000	.	22.90418	var1 var4 var6 var7 var8 var14
6	1.0000	1.0000	.	26.20191	var4 var5 var7 var12 var13 var14
6	1.0000	1.0000	.	28.18184	var5 var8 var10 var11 var12 var16
6	1.0000	1.0000	.	33.37122	var1 var6 var12 var13 var15 var16
6	1.0000	1.0000	.	45.99396	var1 var3 var9 var11 var13 var14
6	1.0000	1.0000	.	47.41353	var2 var4 var7 var8 var13 var16
6	1.0000	1.0000	.	51.79702	var1 var2 var7 var8 var10 var14
6	1.0000	1.0000	.	69.98733	var3 var4 var6 var11 var14 var16
6	1.0000	1.0000	.	75.43225	var7 var8 var10 var11 var13 var14
6	1.0000	1.0000	.	84.63494	var1 var3 var5 var6 var12 var16

6	1.0000	1.0000	.	98.45202	var1 var6 var7 var11 var14 var16
6	1.0000	1.0000	.	107.86820	var2 var9 var10 var13 var15 var16
6	1.0000	1.0000	.	110.70295	var3 var6 var7 var13 var14 var16
7	1.0000	.	.	.	var4 var6 var8 var9 var10 var13 var16
7	1.0000	.	.	.	var1 var5 var7 var8 var9 var13 var16
7	1.0000	.	.	.	var4 var6 var7 var9 var10 var13 var16
7	1.0000	.	.	.	var4 var7 var8 var9 var10 var13 var16
7	1.0000	.	.	.	var1 var2 var6 var9 var11 var13 var16
7	1.0000	.	.	.	var4 var6 var8 var9 var12 var13 var16
7	1.0000	.	.	.	var5 var8 var9 var12 var13 var15 var16
7	1.0000	.	.	.	var4 var6 var7 var8 var10 var13 var16
7	1.0000	.	.	.	var2 var3 var6 var7 var9 var13 var16
7	1.0000	.	.	.	var4 var6 var7 var8 var9 var10 var16
7	1.0000	.	.	.	var2 var4 var5 var8 var14 var15 var16
7	1.0000	.	.	.	var1 var4 var5 var9 var10 var13 var16
7	1.0000	.	.	.	var1 var2 var4 var9 var13 var15 var16
7	1.0000	.	.	.	var3 var5 var7 var8 var9 var13 var16
7	1.0000	.	.	.	var3 var6 var9 var11 var13 var15 var16
7	1.0000	.	.	.	var1 var3 var5 var6 var13 var15 var16

NOTE: Models of not full rank are not included.

multivarijatna regresija-stepwise

The REG Procedure
Model: MODEL1
Dependent Variable: var17

Number of Observations Read	8
Number of Observations Used	8

Stepwise Selection: Step 1

Variable var14 Entered: R-Square = 0.8766 and C(p) = .

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	1	1.193816E11	1.193816E11	42.61	0.0006
Error	6	16810760935	2801793489		
Corrected Total	7	1.361924E11			

Variable	Parameter Estimate	Standard Error	Type II SS	F Value	Pr > F
Intercept	248507	38347	1.176683E11	42.00	0.0006
var14	2417.44816	370.34498	1.193816E11	42.61	0.0006

Bounds on condition number: 1, 1

Stepwise Selection: Step 2

Variable var10 Entered: R-Square = 0.9566 and C(p) = .

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	2	1.302843E11	65142165039	55.13	0.0004
Error	5	5908067882	1181613576		
Corrected Total	7	1.361924E11			

Variable	Parameter Estimate	Standard Error	Type II SS	F Value	Pr > F
Intercept	346725	40812	85283055919	72.18	0.0004
var10	-905.28880	298.02863	10902693053	9.23	0.0288
var14	2190.87529	251.80710	89448866162	75.70	0.0003

Bounds on condition number: 1.0962, 4.3847

Stepwise Selection: Step 3

Variable var11 Entered: R-Square = 0.9843 and C(p) = .

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	3	1.340525E11	44684159559	83.52	0.0005
Error	4	2139919284	534979821		
Corrected Total	7	1.361924E11			

Variable	Parameter Estimate	Standard Error	Type II SS	F Value	Pr > F
Intercept	333754	27893	76595721520	143.17	0.0003
var10	-632.74867	225.29899	4219698103	7.89	0.0484
var11	-53.71311	20.23881	3768148598	7.04	0.0567
var14	2355.87772	180.47999	91155899184	170.39	0.0002

Bounds on condition number: 1.3836, 11.821

Stepwise Selection: Step 4

Variable var1 Entered: R-Square = 0.9986 and C(p) = .

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	4	1.359971E11	33999277519	522.29	0.0001
Error	3	195287885	65095962		
Corrected Total	7	1.361924E11			

Variable	Parameter Estimate	Standard Error	Type II SS	F Value	Pr > F
Intercept	319554	10071	65543043263	1006.87	<.0001
var1	-246.59346	45.11697	1944631398	29.87	0.0120
var10	-217.89555	109.25885	258903253	3.98	0.1401
var11	-79.90444	8.53254	5708732512	87.70	0.0026
var14	2591.17367	76.26770	75139064416	1154.28	<.0001

Bounds on condition number: 2.6743, 33.987

Stepwise Selection: Step 5

Variable var12 Entered: R-Square = 0.9999 and C(p) = .

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	5	1.361803E11	27236054765	4492.87	0.0002
Error	2	12124133	6062066		
Corrected Total	7	1.361924E11			

Variable	Parameter Estimate	Standard Error	Type II SS	F Value	Pr > F
Intercept	328091	3443.38156	55035170451	9078.62	0.0001
var1	-217.43627	14.75454	1316537111	217.18	0.0046
var10	-256.19695	34.06219	342944230	56.57	0.0172
var11	-83.54031	2.68652	5861804270	966.96	0.0010
var12	-14.56245	2.64926	183163753	30.21	0.0315
var14	2606.72660	23.44552	74936266696	12361.5	<.0001

Bounds on condition number: 2.791, 53.377

Stepwise Selection: Step 6

Variable var5 Entered: R-Square = 1.0000 and C(p) = .

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	6	1.361924E11	22698725767	523495	0.0011
Error	1	43360	43360		
Corrected Total	7	1.361924E11			

Variable	Parameter Estimate	Standard Error	Type II SS	F Value	Pr > F
Intercept	324312	368.90490	33510802716	772851	0.0007
var1	-224.90646	1.32567	1248021000	28782.8	0.0038
var5	5.58589	0.33465	12080773	278.62	0.0381
var10	-258.58759	2.88432	348512847	8037.66	0.0071
var11	-84.44351	0.23356	5667782523	130715	0.0018
var12	-14.12654	0.22557	170052026	3921.87	0.0102
var14	2610.55464	1.99609	74164419371	1710435	0.0005

Bounds on condition number: 2.7979, 75.496

All variables left in the model are significant at the 0.1500 level.

No other variable met the 0.1500 significance level for entry into the model.

Summary of Stepwise Selection

Step	Variable Entered	Variable Removed	Number Vars In	Partial R-Square	Model R-Square	C(p)	F Value	Pr > F
1	var14		1	0.8766	0.8766	.	42.61	0.0006
2	var10		2	0.0801	0.9566	.	9.23	0.0288
3	var11		3	0.0277	0.9843	.	7.04	0.0567
4	var1		4	0.0143	0.9986	.	29.87	0.0120
5	var12		5	0.0013	0.9999	.	30.21	0.0315
6	var5		6	0.0001	1.0000	.	278.62	0.0381

modeli s jednom varijablom

The REG Procedure
Model: MODEL1
Dependent Variable: var17

Number of Observations Read	8
Number of Observations Used	8

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	1	1.193816E11	1.193816E11	42.61	0.0006
Error	6	16810760935	2801793489		
Corrected Total	7	1.361924E11			

Root MSE	52932	R-Square	0.8766
Dependent Mean	466984	Adj R-Sq	0.8560
Coeff Var	11.33486		

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
Intercept	1	248507	38347	6.48	0.0006
var14	1	2417.44816	370.34498	6.53	0.0006

Output Statistics

Obs	Dependent Variable	Predicted Value	Std Error Mean Predict	Residual	Std Error Residual	Student Residual	-2-1 0 1 2	Cook's D
1	363703	340370	26953	23333	45556	0.512	| |* |	0.046
2	424020	458825	18756	-34805	49498	-0.703	| *| |	0.035
3	349527	429815	19561	-80288	49185	-1.632	| ***| |	0.211
4	396157	357292	25152	38865	46574	0.834	| |* |	0.102
5	372894	391136	22028	-18242	48131	-0.379	| | |	0.015
6	463924	420146	20043	43778	48991	0.894	| |* |	0.067
7	645192	678813	37461	-33621	37396	-0.899	| *| |	0.406
8	720453	659473	34926	60980	39774	1.533	| |*** |	0.906

Sum of Residuals	0
Sum of Squared Residuals	16810760935
Predicted Residual SS (PRESS)	33042797067

modeli s jednom varijablom

The REG Procedure
Model: MODEL1
Dependent Variable: var17

Number of Observations Read	8
Number of Observations Used	8

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	1	73424755081	73424755081	7.02	0.0381
Error	6	62767642879	10461273813		
Corrected Total	7	1.361924E11			

Root MSE	102280	R-Square	0.5391
Dependent Mean	466984	Adj R-Sq	0.4623
Coeff Var	21.90234		

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
Intercept	1	1010132	208182	4.85	0.0028
var16	1	-289679	109342	-2.65	0.0381

Output Statistics

Obs	Dependent Variable	Predicted Value	Std Error Mean Predict	Residual	Std Error Residual	Student Residual	-2-1 0 1 2	Cook's D
1	363703	430774	38658	-67071	94693	-0.708	| *| |	0.042
2	424020	430774	38658	-6754	94693	-0.0713	| | |	0.000
3	349527	430774	38658	-81247	94693	-0.858	| *| |	0.061
4	396157	430774	38658	-34617	94693	-0.366	| | |	0.011
5	372894	430774	38658	-57880	94693	-0.611	| *| |	0.031
6	463924	430774	38658	33150	94693	0.350	| | |	0.010
7	645192	430774	38658	214418	94693	2.264	| |**** |	0.427
8	720453	720453	102280	0	.	.		.

Sum of Residuals	0
Sum of Squared Residuals	62767642879
Predicted Residual SS (PRESS)	85433736141

The REG Procedure
Model: MODEL1
Dependent Variable: var17

Number of Observations Read	8
Number of Observations Used	8

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	2	1.302843E11	65142165039	55.13	0.0004
Error	5	5908067882	1181613576		
Corrected Total	7	1.361924E11			

Root MSE	34375	R-Square	0.9566
Dependent Mean	466984	Adj R-Sq	0.9393
Coeff Var	7.36099		

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
Intercept	1	346725	40812	8.50	0.0004
var10	1	-905.28880	298.02863	-3.04	0.0288
var14	1	2190.87529	251.80710	8.70	0.0003

Output Statistics

Obs	Dependent Variable	Predicted Value	Std Error Mean Predict	Residual	Std Error Residual	Student Residual	-2-1 0 1 2	Cook's D
1	363703	357555	18395	6148	29038	0.212	| | |	0.006
2	424020	444086	13111	-20066	31776	-0.631	| *| |	0.023
3	349527	402406	15582	-52879	30640	-1.726	| ***| |	0.257
4	396157	406387	22979	-10230	25565	-0.400	| | |	0.043
5	372894	345625	20715	27269	27432	0.994	| |* |	0.188
6	463924	421707	13026	42217	31811	1.327	| |** |	0.098
7	645192	638930	27645	6262	20430	0.307	| | |	0.057
8	720453	719174	30012	1279	16760	0.0763	| | |	0.006

Sum of Residuals	0
Sum of Squared Residuals	5908067882
Predicted Residual SS (PRESS)	10004121243

The REG Procedure
Model: MODEL1
Dependent Variable: var17

Number of Observations Read	8
Number of Observations Used	8

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	2	1.276543E11	63827126940	37.38	0.0010
Error	5	8538144080	1707628816		
Corrected Total	7	1.361924E11			

Root MSE	41323	R-Square	0.9373
Dependent Mean	466984	Adj R-Sq	0.9122
Coeff Var	8.84902		

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
Intercept	1	330975	47959	6.90	0.0010
var14	1	2781.07255	332.99610	8.35	0.0004
var13	1	-26.72620	12.14262	-2.20	0.0790

Output Statistics

Obs	Dependent Variable	Predicted Value	Std Error Mean Predict	Residual	Std Error Residual	Student Residual	-2-1 0 1 2	Cook's D
1	363703	373181	25787	-9478	32290	-0.294	| | |	0.018
2	424020	450709	15100	-26689	38466	-0.694	| *| |	0.025
3	349527	414476	16786	-64949	37760	-1.720	| ***| |	0.195
4	396157	352398	19761	43759	36292	1.206	| |** |	0.144
5	372894	366692	20472	6202	35896	0.173	| | |	0.003
6	463924	427539	16004	36385	38099	0.955	| |* |	0.054
7	645192	629702	36785	15490	18827	0.823	| |* |	0.861
8	720453	721173	39106	-719.9319	13356	-0.0539	| | |	0.008

Sum of Residuals	0
Sum of Squared Residuals	8538144080
Predicted Residual SS (PRESS)	17974711793

The REG Procedure
Model: MODEL1
Dependent Variable: var17

Number of Observations Read	8
Number of Observations Used	8

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	2	1.28688E11	64343983410	42.87	0.0007
Error	5	7504431140	1500886228		
Corrected Total	7	1.361924E11			

Root MSE	38741	R-Square	0.9449
Dependent Mean	466984	Adj R-Sq	0.9229
Coeff Var	8.29606		

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
Intercept	1	284334	31539	9.02	0.0003
var8	1	-185.44753	74.47418	-2.49	0.0552
var14	1	2476.81592	272.10454	9.10	0.0003

Output Statistics

Obs	Dependent Variable	Predicted Value	Std Error Mean Predict	Residual	Std Error Residual	Student Residual	-2-1 0 1 2	Cook's D
1	363703	365101	22086	-1398	31829	-0.0439	| | |	0.000
2	424020	462728	13817	-38708	36194	-1.069	| **| |	0.056
3	349527	343991	37322	5536	10391	0.533	| |* |	1.221
4	396157	375577	19819	20580	33288	0.618	| |* |	0.045
5	372894	410994	17987	-38100	34313	-1.110	| **| |	0.113
6	463924	420502	14670	43422	35856	1.211	| |** |	0.082
7	645192	673838	27491	-28646	27297	-1.049	| **| |	0.372
8	720453	683139	27272	37314	27516	1.356	| |** |	0.602

Sum of Residuals	0
Sum of Squared Residuals	7504431140
Predicted Residual SS (PRESS)	22399437549

The REG Procedure
Model: MODEL1
Dependent Variable: var17

Number of Observations Read	8
Number of Observations Used	8

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	2	1.259674E11	62983713108	30.80	0.0015
Error	5	10224971743	2044994349		
Corrected Total	7	1.361924E11			

Root MSE	45222	R-Square	0.9249
Dependent Mean	466984	Adj R-Sq	0.8949
Coeff Var	9.68377		

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
Intercept	1	489050	137986	3.54	0.0165
var16	1	-107999	60181	-1.79	0.1327
var14	1	1996.48210	393.87227	5.07	0.0039

Output Statistics

Obs	Dependent Variable	Predicted Value	Std Error Mean Predict	Residual	Std Error Residual	Student Residual	-2-1 0 1 2	Cook's D
1	363703	348918	23514	14785	38627	0.383	| | |	0.018
2	424020	446746	17380	-22726	41748	-0.544	| *| |	0.017
3	349527	422788	17165	-73261	41837	-1.751	| ***| |	0.172
4	396157	362893	21714	33264	39668	0.839	| |* |	0.070
5	372894	390844	18820	-17950	41119	-0.437	| | |	0.013
6	463924	414802	17380	49122	41748	1.177	| |** |	0.080
7	645192	628426	42575	16766	15244	1.100	| |** |	3.146
8	720453	720453	45222	0	.	.		.

Sum of Residuals	0
Sum of Squared Residuals	10224971743
Predicted Residual SS (PRESS)	35881910195

The REG Procedure
Model: MODEL1
Dependent Variable: var17

Number of Observations Read	8
Number of Observations Used	8

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	2	1.230487E11	61524368269	23.40	0.0029
Error	5	13143661422	2628732284		
Corrected Total	7	1.361924E11			

Root MSE	51271	R-Square	0.9035
Dependent Mean	466984	Adj R-Sq	0.8649
Coeff Var	10.97922		

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
Intercept	1	318886	70216	4.54	0.0062
var5	1	-81.41688	68.93285	-1.18	0.2907
var14	1	2401.40671	358.98197	6.69	0.0011

Output Statistics

Obs	Dependent Variable	Predicted Value	Std Error Mean Predict	Residual	Std Error Residual	Student Residual	-2-1 0 1 2	Cook's D
1	363703	387017	47344	-23314	19680	-1.185	| **| |	2.707
2	424020	455348	18404	-31328	47854	-0.655	| *| |	0.021
3	349527	409433	25628	-59906	44406	-1.349	| **| |	0.202
4	396157	342357	27449	53800	43305	1.242	| |** |	0.207
5	372894	382002	22695	-9108	45974	-0.198	| | |	0.003
6	463924	408702	21697	55222	46454	1.189	| |** |	0.103
7	645192	668665	37289	-23473	35189	-0.667	| *| |	0.167
8	720453	682346	38981	38107	33305	1.144	| |** |	0.598

Sum of Residuals	0
Sum of Squared Residuals	13143661422
Predicted Residual SS (PRESS)	53688920977

The REG Procedure
Model: MODEL1
Dependent Variable: var17

Number of Observations Read	8
Number of Observations Used	8

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	2	1.216964E11	60848185745	20.99	0.0037
Error	5	14496026469	2899205294		
Corrected Total	7	1.361924E11			

Root MSE	53844	R-Square	0.8936
Dependent Mean	466984	Adj R-Sq	0.8510
Coeff Var	11.53022		

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
Intercept	1	285695	57042	5.01	0.0041
var6	1	-66.94751	74.92441	-0.89	0.4125
var14	1	2550.52018	405.09685	6.30	0.0015

Output Statistics

Obs	Dependent Variable	Predicted Value	Std Error Mean Predict	Residual	Std Error Residual	Student Residual	-2-1 0 1 2	Cook's D
1	363703	367686	41064	-3983	34827	-0.114	| | |	0.006
2	424020	463338	19737	-39318	50097	-0.785	| *| |	0.032
3	349527	422757	21409	-73230	49405	-1.482	| **| |	0.138
4	396157	354275	25807	41882	47257	0.886	| |* |	0.078
5	372894	382350	24470	-9456	47963	-0.197	| | |	0.003
6	463924	398964	31267	64960	43836	1.482	| |** |	0.372
7	645192	661359	42821	-16167	32643	-0.495	| | |	0.141
8	720453	685140	45688	35313	28492	1.239	| |** |	1.316

Sum of Residuals	0
Sum of Squared Residuals	14496026469
Predicted Residual SS (PRESS)	40262003456

modeli s dvije varijable

The REG Procedure
Model: MODEL1
Dependent Variable: var17

Number of Observations Read	8
Number of Observations Used	8

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	2	1.209116E11	60455782818	19.78	0.0042
Error	5	15280832323	3056166465		
Corrected Total	7	1.361924E11			

Root MSE	55283	R-Square	0.8878
Dependent Mean	466984	Adj R-Sq	0.8429
Coeff Var	11.83823		

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
Intercept	1	235675	43965	5.36	0.0030
var15	1	20.12306	28.44114	0.71	0.5108
var14	1	2383.89256	389.68820	6.12	0.0017

Output Statistics

Obs	Dependent Variable	Predicted Value	Std Error Mean Predict	Residual	Std Error Residual	Student Residual	-2-1 0 1 2	Cook's D
1	363703	333286	29877	30417	46513	0.654	| |* |	0.059
2	424020	456113	19960	-32093	51553	-0.623	| *| |	0.019
3	349527	423482	22305	-73955	50583	-1.462	| **| |	0.139
4	396157	346753	30198	49404	46306	1.067	| |** |	0.161
5	372894	386748	23828	-13854	49884	-0.278	| | |	0.006
6	463924	456044	54886	7880	6613.0	1.192	| |** |	32.603
7	645192	677273	39185	-32081	38996	-0.823	| *| |	0.228
8	720453	656170	36774	64283	41277	1.557	| |*** |	0.642

Sum of Residuals	0
Sum of Squared Residuals	15280832323
Predicted Residual SS (PRESS)	3.369736E11

modeli s tri varijable

The REG Procedure
Model: MODEL1
Dependent Variable: var17

Number of Observations Read	8
Number of Observations Used	8

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	3	1.347903E11	44930111254	128.18	0.0002
Error	4	1402064199	350516050		
Corrected Total	7	1.361924E11			

Root MSE	18722	R-Square	0.9897
Dependent Mean	466984	Adj R-Sq	0.9820
Coeff Var	4.00915		

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
Intercept	1	481206	57149	8.42	0.0011
var11	1	-73.59648	14.66916	-5.02	0.0074
var14	1	2182.63397	167.23391	13.05	0.0002
var16	1	-94266	25065	-3.76	0.0198

Output Statistics

Obs	Dependent Variable	Predicted Value	Std Error Mean Predict	Residual	Std Error Residual	Student Residual	-2-1 0 1 2	Cook's D
1	363703	359496	9961	4207	15852	0.265	| | |	0.007
2	424020	454154	7345	-30134	17221	-1.750	| ***| |	0.139
3	349527	341560	17681	7967	6155.9	1.294	| |** |	3.454
4	396157	390892	10581	5265	15445	0.341	| | |	0.014
5	372894	382222	7979	-9328	16937	-0.551	| *| |	0.017
6	463924	447640	9727	16284	15997	1.018	| |** |	0.096
7	645192	639453	17763	5739	5915.9	0.970	| |* |	2.121
8	720453	720453	18722	0	.	.		.

Sum of Residuals	0
Sum of Squared Residuals	1402064199
Predicted Residual SS (PRESS)	10724255970

The REG Procedure
Model: MODEL1
Dependent Variable: var17

Number of Observations Read	8
Number of Observations Used	8

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	3	1.343856E11	44795192888	99.17	0.0003
Error	4	1806819296	451704824		
Corrected Total	7	1.361924E11			

Root MSE	21253	R-Square	0.9867
Dependent Mean	466984	Adj R-Sq	0.9768
Coeff Var	4.55120		

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
Intercept	1	332103	24668	13.46	0.0002
var11	1	-66.00833	17.09920	-3.86	0.0181
var13	1	-20.48130	6.45128	-3.17	0.0337
var14	1	2815.05538	171.49155	16.42	<.0001

Output Statistics

Obs	Dependent Variable	Predicted Value	Std Error Mean Predict	Residual	Std Error Residual	Student Residual	-2-1 0 1 2	Cook's D
1	363703	375976	13283	-12273	16592	-0.740	| *| |	0.088
2	424020	457872	7985	-33852	19696	-1.719	| ***| |	0.121
3	349527	344406	20100	5121	6906.2	0.741	| |* |	1.164
4	396157	379292	12322	16865	17317	0.974	| |* |	0.120
5	372894	364637	10542	8257	18454	0.447	| | |	0.016
6	463924	454655	10821	9269	18293	0.507	| |* |	0.022
7	645192	645321	19347	-128.7234	8797.4	-0.0146	| | |	0.000
8	720453	713711	20205	6742	6591.4	1.023	| |** |	2.458

Sum of Residuals	0
Sum of Squared Residuals	1806819296
Predicted Residual SS (PRESS)	10147237430

The REG Procedure
Model: MODEL1
Dependent Variable: var17

Number of Observations Read	8
Number of Observations Used	8

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	3	1.338152E11	44605054281	75.05	0.0006
Error	4	2377235116	594308779		
Corrected Total	7	1.361924E11			

Root MSE	24378	R-Square	0.9825
Dependent Mean	466984	Adj R-Sq	0.9695
Coeff Var	5.22041		

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
Intercept	1	369625	30431	12.15	0.0003
var7	1	46.96478	19.26814	2.44	0.0714
var10	1	-1322.95502	272.09616	-4.86	0.0083
var14	1	1832.23503	231.38948	7.92	0.0014

Output Statistics

Obs	Dependent Variable	Predicted Value	Std Error Mean Predict	Residual	Std Error Residual	Student Residual	-2-1 0 1 2	Cook's D
1	363703	355346	13077	8357	20574	0.406	| | |	0.017
2	424020	437710	9659	-13690	22383	-0.612	| *| |	0.017
3	349527	354863	22418	-5336	9577.3	-0.557	| *| |	0.425
4	396157	423461	17738	-27304	16723	-1.633	| ***| |	0.750
5	372894	367625	17242	5269	17234	0.306	| | |	0.023
6	463924	430767	9958	33157	22252	1.490	| |** |	0.111
7	645192	655877	20802	-10685	12712	-0.841	| *| |	0.473
8	720453	710223	21599	10230	11305	0.905	| |* |	0.747

Sum of Residuals	0
Sum of Squared Residuals	2377235116
Predicted Residual SS (PRESS)	10466019636

The REG Procedure
Model: MODEL1
Dependent Variable: var17

Number of Observations Read	8
Number of Observations Used	8

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	3	1.335527E11	44517555602	67.46	0.0007
Error	4	2639731153	659932788		
Corrected Total	7	1.361924E11			

Root MSE	25689	R-Square	0.9806
Dependent Mean	466984	Adj R-Sq	0.9661
Coeff Var	5.50108		

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
Intercept	1	344664	30514	11.30	0.0004
var8	1	-121.69149	54.68229	-2.23	0.0901
var10	1	-669.59668	246.62387	-2.72	0.0533
var14	1	2288.82098	193.26111	11.84	0.0003

Output Statistics

Obs	Dependent Variable	Predicted Value	Std Error Mean Predict	Residual	Std Error Residual	Student Residual	-2-1 0 1 2	Cook's D
1	363703	369310	14727	-5607	21049	-0.266	| | |	0.009
2	424020	450485	10211	-26465	23572	-1.123	| **| |	0.059
3	349527	353224	24980	-3697	5992.6	-0.617	| *| |	1.653
4	396157	405604	17176	-9447	19103	-0.495	| | |	0.049
5	372894	370505	19096	2389	17184	0.139	| | |	0.006
6	463924	421534	9735	42390	23773	1.783	| |*** |	0.133
7	645192	646049	20906	-857.0408	14929	-0.0574	| | |	0.002
8	720453	719160	22429	1293	12525	0.103	| | |	0.009

Sum of Residuals	0
Sum of Squared Residuals	2639731153
Predicted Residual SS (PRESS)	8478953368

The REG Procedure
Model: MODEL1
Dependent Variable: var17

Number of Observations Read	8
Number of Observations Used	8

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	3	1.330236E11	44341206452	55.97	0.0010
Error	4	3168778602	792194651		
Corrected Total	7	1.361924E11			

Root MSE	28146	R-Square	0.9767
Dependent Mean	466984	Adj R-Sq	0.9593
Coeff Var	6.02718		

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
Intercept	1	313041	25992	12.04	0.0003
var8	1	-230.48001	57.42844	-4.01	0.0160
var9	1	-208.50899	89.12786	-2.34	0.0794
var14	1	3047.93927	314.13193	9.70	0.0006

Output Statistics

Obs	Dependent Variable	Predicted Value	Std Error Mean Predict	Residual	Std Error Residual	Student Residual	-2-1 0 1 2	Cook's D
1	363703	363477	16061	225.7042	23114	0.00976	| | |	0.000
2	424020	460389	10088	-36369	26276	-1.384	| **| |	0.071
3	349527	349464	27215	63.2246	7177.5	0.00881	| | |	0.000
4	396157	362941	15379	33216	23573	1.409	| |** |	0.211
5	372894	394232	14903	-21338	23877	-0.894	| *| |	0.078
6	463924	450931	16816	12993	22570	0.576	| |* |	0.046
7	645192	634307	26161	10885	10381	1.048	| |** |	1.745
8	720453	720130	25349	323.2530	12232	0.0264	| | |	0.001

Sum of Residuals	0
Sum of Squared Residuals	3168778602
Predicted Residual SS (PRESS)	11676661640

modeli s tri varijable

The REG Procedure
Model: MODEL1
Dependent Variable: var17

Number of Observations Read	8
Number of Observations Used	8

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	3	1.324991E11	44166351823	47.83	0.0014
Error	4	3693342491	923335623		
Corrected Total	7	1.361924E11			

Root MSE	30386	R-Square	0.9729
Dependent Mean	466984	Adj R-Sq	0.9525
Coeff Var	6.50696		

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
Intercept	1	334565	36922	9.06	0.0008
var10	1	-935.91118	264.19205	-3.54	0.0240
var14	1	2142.72484	224.75296	9.53	0.0007
var15	1	24.27941	15.67682	1.55	0.1964

Output Statistics

Obs	Dependent Variable	Predicted Value	Std Error Mean Predict	Residual	Std Error Residual	Student Residual	-2-1 0 1 2	Cook's D
1	363703	349589	17055	14114	25149	0.561	| |* |	0.036
2	424020	440316	11843	-16296	27984	-0.582	| *| |	0.015
3	349527	393837	14844	-44310	26514	-1.671	| ***| |	0.219
4	396157	395332	21530	824.6681	21443	0.0385	| | |	0.000
5	372894	338791	18836	34103	23844	1.430	| |** |	0.319
6	463924	465072	30276	-1148	2591.8	-0.443	| | |	6.695
7	645192	635723	24525	9469	17941	0.528	| |* |	0.130
8	720453	717208	26560	3245	14761	0.220	| | |	0.039

Sum of Residuals	0
Sum of Squared Residuals	3693342491
Predicted Residual SS (PRESS)	33084270628

	Mean	Std.Dv.	r(X,Y)	r2	t	p	N	Constant dep: Y	Slope dep: Y	Constant dep: X	Slope dep: X
Troskovi odrzavanja i uporabe	1115555	634626,4									
Starost gradjevine	123	97,5	0,332877	0,110807	0,86469	0,420430	8	65,972	0,000051	848949	2168
Troskovi odrzavanja i uporabe	1115555	634626,4									
Broj godine uporabe	14	9,4	-0,452262	0,204541	-1,24210	0,260546	8	21,612	-0,000007	1546026	-30476
Troskovi odrzavanja i uporabe	1115555	634626,4									
Ref. period	9	2,8	-0,246536	0,060780	-0,62312	0,556133	8	9,970	-0,000001	1601749	-55565
Troskovi odrzavanja i uporabe	1115555	634626,4									
Etaze	4	0,9	-0,534467	0,285654	-1,54897	0,172362	8	4,870	-0,000001	2581009	-366363
Troskovi odrzavanja i uporabe	1115555	634626,4									
Pov. predavaonica	847	281,2	0,338337	0,114472	0,88069	0,412368	8	679,429	0,000150	469062	764
Troskovi odrzavanja i uporabe	1115555	634626,4									
Pov. kabineta	735	291,9	0,471739	0,222538	1,31050	0,237953	8	493,000	0,000217	361753	1025
Troskovi odrzavanja i uporabe	**1115555**	**634626,4**									
Pov. komunikacija	**966**	**681,5**	**0,818448**	**0,669857**	**3,48911**	**0,012997**	**8**	**-14,137**	**0,000879**	**379068**	**762**
Troskovi odrzavanja i uporabe	1115555	634626,4									
Pov. sanitarija	222	197,3	-0,226372	0,051244	-0,56927	0,589830	8	300,694	-0,000070	1277285	-728
Troskovi odrzavanja i uporabe	1115555	634626,4									
Pov. ureda	337	192,0	0,681456	0,464382	2,28079	0,062731	8	107,032	0,000206	356485	2252
Troskovi odrzavanja i uporabe	1115555	634626,4									
Pov. knjiznica	86	45,5	0,371205	0,137793	0,97923	0,365285	8	56,173	0,000027	671114	5176
Troskovi odrzavanja i uporabe	1115555	634626,4									
Pov. laboratorija	472	494,9	-0,031309	0,000980	-0,07673	0,941335	8	499,039	-0,000024	1134495	-40
Troskovi odrzavanja i uporabe	1115555	634626,4									
Ostale povrsine	585	444,8	0,322329	0,103896	0,83406	0,436190	8	333,325	0,000226	846345	460
Troskovi odrzavanja i uporabe	1115555	634626,4									
Ukupna povrsina	4315	1481,5	0,664086	0,441011	2,17570	0,072490	8	2585,885	0,001550	-112052	284
Troskovi odrzavanja i uporabe	1115555	634626,4									
Djelatnici	90	54,0	0,236921	0,056131	0,59734	0,572117	8	67,877	0,000020	864015	2783
Troskovi odrzavanja i uporabe	1115555	634626,4									
Studenti	788	740,2	-0,236554	0,055958	-0,59636	0,572730	8	1096,152	-0,000276	1275455	-203
Troskovi odrzavanja i uporabe	1115555	634626,4									
Smjene	2	0,4	0,169625	0,028773	0,42161	0,688001	8	1,770	0,000000	544662	304477

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var1

Moments

N	8	Sum Weights	8
Mean	123	Sum Observations	984
Std Deviation	97.4620805	Variance	9498.85714
Skewness	0.92298795	Kurtosis	-0.1279583
Uncorrected SS	187524	Corrected SS	66492
Coeff Variation	79.2374639	Std Error Mean	34.458049

Basic Statistical Measures

Location		Variability	
Mean	123.0000	Std Deviation	97.46208
Median	109.0000	Variance	9499
Mode	.	Range	283.00000
		Interquartile Range	126.50000

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	3.569558	Pr > |t|	0.0091
Sign	M	4	Pr >= |M|	0.0078
Signed Rank	S	18	Pr >= |S|	0.0078

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.88835	Pr < W	0.2259
Kolmogorov-Smirnov	D	0.28271	Pr > D	0.0587
Cramer-von Mises	W-Sq	0.088323	Pr > W-Sq	0.1391
Anderson-Darling	A-Sq	0.477482	Pr > A-Sq	0.1741

Quantiles (Definition 5)

Quantile	Estimate
100% Max	293.0
99%	293.0
95%	293.0
90%	293.0
75% Q3	179.0
50% Median	109.0
25% Q1	52.5
10%	10.0
5%	10.0
1%	10.0
0% Min	10.0

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var1

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
10	8	108	6
49	1	110	4
56	3	115	5
108	6	243	7
110	4	293	2

```
Stem Leaf                     #             Boxplot                                 Normal Probability Plot
   2 9                        1                |                  275+                                      *++++
   2 4                        1                |                     |                                +*++++
   1                                           +-----+               |                             +++++
   1 112                      3                *--+--*               |                       *+++*  *
   0 56                       2                +-----+               |                  ++*++
   0 1                        1                   |                   25+           * +++*+
     ----+----+----+----+                                                +----+----+----+----+----+----+----+----+----+----+
 Multiply Stem.Leaf by 10**+2                                              -2        -1         0        +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var2

Moments

N	8	Sum Weights	8
Mean	14.125	Sum Observations	113
Std Deviation	9.41787814	Variance	88.6964286
Skewness	1.35632531	Kurtosis	1.46413221
Uncorrected SS	2217	Corrected SS	620.875
Coeff Variation	66.6752434	Std Error Mean	3.32972275

Basic Statistical Measures

Location		Variability	
Mean	14.12500	Std Deviation	9.41788
Median	11.50000	Variance	88.69643
Mode	13.00000	Range	29.00000
		Interquartile Range	9.50000

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	4.242095	Pr > |t|	0.0038
Sign	M	4	Pr >= |M|	0.0078
Signed Rank	S	18	Pr >= |S|	0.0078

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.864008	Pr < W	0.1316
Kolmogorov-Smirnov	D	0.297542	Pr > D	0.0362
Cramer-von Mises	W-Sq	0.102481	Pr > W-Sq	0.0889
Anderson-Darling	A-Sq	0.5563	Pr > A-Sq	0.1021

Quantiles (Definition 5)

Quantile	Estimate
100% Max	33.0
99%	33.0
95%	33.0
90%	33.0
75% Q3	18.0
50% Median	11.5
25% Q1	8.5
10%	4.0
5%	4.0
1%	4.0
0% Min	4.0

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var2

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
4	4	10	8
8	5	13	2
9	1	13	7
10	8	23	3
13	7	33	6

```
Stem Leaf                     #             Boxplot                               Normal Probability Plot
  3 3                         1                0                  32.5+                                     *  ++++++
  2                                                                    |                                  +++++
  2 3                         1                |                     |                              ++*++
  1                                         +-----+               17.5+                         ++++++
  1 033                       3             *--+--*                   |                     ++*++ *  *
  0 89                        2             +-----+                   |                *+++*
  0 4                         1                |                   2.5+           *++++
    ----+----+----+----+                                             +----+----+----+----+----+----+----+----+----+----+
Multiply Stem.Leaf by 10**+1                                            -2        -1         0        +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var3

Moments

N	8	Sum Weights	8
Mean	8.75	Sum Observations	70
Std Deviation	2.81577191	Variance	7.92857143
Skewness	-0.4799222	Kurtosis	-0.5644996
Uncorrected SS	668	Corrected SS	55.5
Coeff Variation	32.1802504	Std Error Mean	0.9955257

Basic Statistical Measures

Location		Variability	
Mean	8.750000	Std Deviation	2.81577
Median	9.000000	Variance	7.92857
Mode	8.000000	Range	8.00000
		Interquartile Range	4.00000

Note: The mode displayed is the smallest of 3 modes with a count of 2.

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	8.789326	Pr > |t|	<.0001
Sign	M	4	Pr >= |M|	0.0078
Signed Rank	S	18	Pr >= |S|	0.0078

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.934441	Pr < W	0.5573
Kolmogorov-Smirnov	D	0.171453	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.039783	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.264342	Pr > A-Sq	>0.2500

Quantiles (Definition 5)

Quantile	Estimate
100% Max	12
99%	12
95%	12
90%	12
75% Q3	11
50% Median	9
25% Q1	7
10%	4
5%	4
1%	4
0% Min	4

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var3

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
4	4	8	5
6	8	10	2
8	5	10	7
8	1	12	3
10	7	12	6

```
Stem Leaf                     #             Boxplot                                 Normal Probability Plot
  12 00                       2                |                  12.5+                                  *  ++*+
  11                                       +-----+                     |                                 ++++
  10 00                       2            |     |                     |                            *  *++
   9                                       *-----*                     |                           ++++
   8 00                       2            |  +  |                8.5+                     *  *++
   7                                       +-----+                     |                   ++++
   6 0                        1                |                       |                *++
   5                                           |                       |            ++++
   4 0                        1                |                   4.5+         ++*
     ----+----+----+----+                                                +----+----+----+----+----+----+----+----+----+----+
                                                                            -2        -1         0        +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var4

Moments

N	8	Sum Weights	8
Mean	4	Sum Observations	32
Std Deviation	0.9258201	Variance	0.85714286
Skewness	0	Kurtosis	-2.1
Uncorrected SS	134	Corrected SS	6
Coeff Variation	23.1455025	Std Error Mean	0.32732684

Basic Statistical Measures

Location		Variability	
Mean	4.000000	Std Deviation	0.92582
Median	4.000000	Variance	0.85714
Mode	3.000000	Range	2.00000
		Interquartile Range	2.00000

Note: The mode displayed is the smallest of 2 modes with a count of 3.

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	12.2202	Pr > |t|	<.0001
Sign	M	4	Pr >= |M|	0.0078
Signed Rank	S	18	Pr >= |S|	0.0078

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.801503	Pr < W	0.0297
Kolmogorov-Smirnov	D	0.234956	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.094242	Pr > W-Sq	0.1149
Anderson-Darling	A-Sq	0.66666	Pr > A-Sq	0.0499

Quantiles (Definition 5)

Quantile	Estimate
100% Max	5
99%	5
95%	5
90%	5
75% Q3	5
50% Median	4
25% Q1	3
10%	3
5%	3
1%	3
0% Min	3

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var4

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
3	5	4	6
3	4	4	7
3	2	5	1
4	7	5	3
4	6	5	8

```
Stem Leaf                     #           Boxplot                                 Normal Probability Plot
   5 000                      3           +-----+              5.25+                              *   * +++*++
   4                                      |     |                  |                               +++++
   4 00                       2           *--+--*              4.25+                       * ++*+++
   3                                      |     |                  |                     +++++
   3 000                      3           +-----+              3.25+           *   +*+++*
     ----+----+----+----+                                           +----+----+----+----+----+----+----+----+----+----+
                                                                        -2        -1         0        +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var5

Moments

N	8	Sum Weights	8
Mean	846.625	Sum Observations	6773
Std Deviation	281.325403	Variance	79143.9821
Skewness	-1.4955864	Kurtosis	1.35101985
Uncorrected SS	6288199	Corrected SS	554007.875
Coeff Variation	33.229045	Std Error Mean	99.4635499

Basic Statistical Measures

Location		Variability	
Mean	846.6250	Std Deviation	281.32540
Median	959.5000	Variance	79144
Mode	.	Range	816.00000
		Interquartile Range	295.00000

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	8.511912	Pr > |t|	<.0001
Sign	M	4	Pr >= |M|	0.0078
Signed Rank	S	18	Pr >= |S|	0.0078

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.802337	Pr < W	0.0303
Kolmogorov-Smirnov	D	0.311266	Pr > D	0.0220
Cramer-von Mises	W-Sq	0.148662	Pr > W-Sq	0.0200
Anderson-Darling	A-Sq	0.778126	Pr > A-Sq	0.0245

Quantiles (Definition 5)

Quantile	Estimate
100% Max	1100.0
99%	1100.0
95%	1100.0
90%	1100.0
75% Q3	1015.0
50% Median	959.5
25% Q1	720.0
10%	284.0
5%	284.0
1%	284.0
0% Min	284.0

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var5

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
284	1	954	7
550	8	965	5
890	2	991	6
954	7	1039	4
965	5	1100	3

```
Stem Leaf                     #             Boxplot                               Normal Probability Plot
  11 0                        1                |                 1150+                                  +++ *
  10 4                        1           +-----+                    |                            +++*
   9 569                      3           *-----*                    |                        *   *++*
   8 9                        1           |  +  |                850+                    *   +++
   7                                      +-----+                    |                    ++++
   6                                         |                       |                +++
   5 5                        1              |                   550+             +++*
   4                                         |                       |          +++
   3                                         |                       |      ++++
   2 8                        1              |                   250+   +++     *
     ----+----+----+----+                                            +----+----+----+----+----+----+----+----+----+----+
Multiply Stem.Leaf by 10**+2                                            -2        -1         0        +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var6

Moments

N	8	Sum Weights	8
Mean	735.125	Sum Observations	5881
Std Deviation	292.077503	Variance	85309.2679
Skewness	-0.3193885	Kurtosis	0.43155704
Uncorrected SS	4920435	Corrected SS	597164.875
Coeff Variation	39.7316787	Std Error Mean	103.264992

Basic Statistical Measures

Location		Variability	
Mean	735.1250	Std Deviation	292.07750
Median	747.0000	Variance	85309
Mode	.	Range	947.00000
		Interquartile Range	326.00000

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	7.118821	Pr > |t|	0.0002
Sign	M	4	Pr >= |M|	0.0078
Signed Rank	S	18	Pr >= |S|	0.0078

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.979041	Pr < W	0.9580
Kolmogorov-Smirnov	D	0.149831	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.028358	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.180411	Pr > A-Sq	>0.2500

Quantiles (Definition 5)

Quantile	Estimate
100% Max	1170.0
99%	1170.0
95%	1170.0
90%	1170.0
75% Q3	911.5
50% Median	747.0
25% Q1	585.5
10%	223.0
5%	223.0
1%	223.0
0% Min	223.0

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var6

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
223	1	690	4
510	8	804	5
661	2	810	3
690	4	1013	6
804	5	1170	7

```
Stem Leaf                     #             Boxplot                               Normal Probability Plot
 10 17                        2                |                 1100+                                  *++++*+
  8 01                        2             +-----+                  |                          *++*++++
  6 69                        2             *--+--*                700+                    *++*++++
  4 1                         1             +-----+                  |              ++*++++
  2 2                         1                |                   300+       ++++*++
    ----+----+----+----+                                              +----+----+----+----+----+----+----+----+----+----+
Multiply Stem.Leaf by 10**+2                                              -2        -1         0        +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var7

Moments

N	8	Sum Weights	8
Mean	966.25	Sum Observations	7730
Std Deviation	681.484042	Variance	464420.5
Skewness	0.89247335	Kurtosis	0.08225098
Uncorrected SS	10720056	Corrected SS	3250943.5
Coeff Variation	70.5287495	Std Error Mean	240.940994

Basic Statistical Measures

Location		Variability	
Mean	966.2500	Std Deviation	681.48404
Median	788.5000	Variance	464421
Mode	.	Range	2053
		Interquartile Range	841.00000

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	4.010318	Pr > |t|	0.0051
Sign	M	4	Pr >= |M|	0.0078
Signed Rank	S	18	Pr >= |S|	0.0078

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.92227	Pr < W	0.4486
Kolmogorov-Smirnov	D	0.207493	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.061435	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.35275	Pr > A-Sq	>0.2500

Quantiles (Definition 5)

Quantile	Estimate
100% Max	2193.0
99%	2193.0
95%	2193.0
90%	2193.0
75% Q3	1375.5
50% Median	788.5
25% Q1	534.5
10%	140.0
5%	140.0
1%	140.0
0% Min	140.0

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var7

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
140	3	620	8
467	1	957	2
602	4	1039	6
620	8	1712	5
957	2	2193	7

```
Stem Leaf                     #             Boxplot                                Normal Probability Plot
  2 2                         1                |                  2250+                                     * +++++++
  1 7                         1                |                      |                              +*++++++
  1 00                        2             +--+--+               1250+                        ++++*++
  0 566                       3             *-----*                  |                   +*++*++ *
  0 1                         1                |                   250+           *++++*++
    ----+----+----+----+                                                +----+----+----+----+----+----+----+----+----+----+
Multiply Stem.Leaf by 10**+3                                              -2        -1         0        +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var8

Moments

N	8	Sum Weights	8
Mean	222.125	Sum Observations	1777
Std Deviation	197.375232	Variance	38956.9821
Skewness	2.19590123	Kurtosis	5.25050778
Uncorrected SS	667415	Corrected SS	272698.875
Coeff Variation	88.8577296	Std Error Mean	69.7826824

Basic Statistical Measures

Location		Variability	
Mean	222.1250	Std Deviation	197.37523
Median	160.0000	Variance	38957
Mode	.	Range	608.00000
		Interquartile Range	138.50000

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	3.183096	Pr > |t|	0.0154
Sign	M	4	Pr >= |M|	0.0078
Signed Rank	S	18	Pr >= |S|	0.0078

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.726776	Pr < W	0.0045
Kolmogorov-Smirnov	D	0.266418	Pr > D	0.0921
Cramer-von Mises	W-Sq	0.160334	Pr > W-Sq	0.0138
Anderson-Darling	A-Sq	0.945855	Pr > A-Sq	0.0087

Quantiles (Definition 5)

Quantile	Estimate
100% Max	680.0
99%	680.0
95%	680.0
90%	680.0
75% Q3	245.5
50% Median	160.0
25% Q1	107.0
10%	72.0
5%	72.0
1%	72.0
0% Min	72.0

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var8

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
72	1	120	8
105	5	200	2
109	4	214	6
120	8	277	7
200	2	680	3

```
Stem Leaf                     #             Boxplot                                Normal Probability Plot
  6 8                         1                *                    650+                                      *     +++++
  5                                                                     |                                       +++++
  4                                                                     |                                 +++++
  3                                                                 350+                              ++++++
  2 018                       3             +--+--+                    |                         +++*+ *   *
  1 012                       3             *-----*                    |                 *  +*++*
  0 7                         1                |                   50+            *  +++++
    ----+----+----+----+                                                +----+----+----+----+----+----+----+----+----+----+
Multiply Stem.Leaf by 10**+2                                             -2        -1         0        +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var9

Moments

N	8	Sum Weights	8
Mean	337.25	Sum Observations	2698
Std Deviation	191.970794	Variance	36852.7857
Skewness	1.60585675	Kurtosis	3.40137292
Uncorrected SS	1167870	Corrected SS	257969.5
Coeff Variation	56.9224	Std Error Mean	67.8719251

Basic Statistical Measures

Location		Variability	
Mean	337.2500	Std Deviation	191.97079
Median	321.0000	Variance	36853
Mode	.	Range	615.00000
		Interquartile Range	176.50000

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	4.968918	Pr > |t|	0.0016
Sign	M	4	Pr >= |M|	0.0078
Signed Rank	S	18	Pr >= |S|	0.0078

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.852659	Pr < W	0.1014
Kolmogorov-Smirnov	D	0.246882	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.079194	Pr > W-Sq	0.1903
Anderson-Darling	A-Sq	0.518518	Pr > A-Sq	0.1326

Quantiles (Definition 5)

Quantile	Estimate
100% Max	755.0
99%	755.0
95%	755.0
90%	755.0
75% Q3	378.5
50% Median	321.0
25% Q1	202.0
10%	140.0
5%	140.0
1%	140.0
0% Min	140.0

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var9

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
140	6	298	4
170	3	344	2
234	1	357	5
298	4	400	8
344	2	755	7

```
Stem Leaf                     #             Boxplot                                Normal Probability Plot
  7 6                         1                0                  750+                                     *    ++++++
  6                                                                  |                                     +++++
  5                                                                  |                                +++++
  4 0                         1                |                  450+                            +++++*
  3 046                       3             +--+--+                 |                        +++*+ *
  2 3                         1             +-----+                 |                  ++*++*
  1 47                        2                |                  150+           * +++*+
    ----+----+----+----+                                             +----+----+----+----+----+----+----+----+----+----+
Multiply Stem.Leaf by 10**+2                                            -2        -1         0        +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var10

Moments

N	8	Sum Weights	8
Mean	85.875	Sum Observations	687
Std Deviation	45.6428292	Variance	2083.26786
Skewness	-0.9220831	Kurtosis	0.69789348
Uncorrected SS	73579	Corrected SS	14582.875
Coeff Variation	53.1503106	Std Error Mean	16.137177

Basic Statistical Measures

Location		Variability	
Mean	85.87500	Std Deviation	45.64283
Median	96.00000	Variance	2083
Mode	.	Range	144.00000
		Interquartile Range	52.50000

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	5.321563	Pr > |t|	0.0011
Sign	M	3.5	Pr >= |M|	0.0156
Signed Rank	S	14	Pr >= |S|	0.0156

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.941561	Pr < W	0.6265
Kolmogorov-Smirnov	D	0.198791	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.048419	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.288431	Pr > A-Sq	>0.2500

Quantiles (Definition 5)

Quantile	Estimate
100% Max	144.0
99%	144.0
95%	144.0
90%	144.0
75% Q3	114.0
50% Median	96.0
25% Q1	61.5
10%	0.0
5%	0.0
1%	0.0
0% Min	0.0

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var10

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
0	8	89	6
43	4	103	2
80	1	108	7
89	6	120	3
103	2	144	5

```
Stem Leaf                     #             Boxplot                                Normal Probability Plot
 14 4                         1                |                  150+                                     ++*++
 12 0                         1                |                     |                              +*++
 10 38                        2           +-----+                   |                          * +*++
  8 09                        2           *--+--*                   |                    *  *+++++
  6                                       +-----+                   |                    ++++
  4 3                         1                |                     |               +*+++
  2                                            |                     |           ++++
  0 0                         1                |                  10+       ++++*
    ----+----+----+----+                                              +----+----+----+----+----+----+----+----+----+----+
Multiply Stem.Leaf by 10**+1                                              -2        -1         0        +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var11

Moments

N	8	Sum Weights	8
Mean	471.875	Sum Observations	3775
Std Deviation	494.961308	Variance	244986.696
Skewness	1.66908836	Kurtosis	3.69904061
Uncorrected SS	3496235	Corrected SS	1714906.88
Coeff Variation	104.892463	Std Error Mean	174.995249

Basic Statistical Measures

Location		Variability	
Mean	471.8750	Std Deviation	494.96131
Median	448.0000	Variance	244987
Mode	0.0000	Range	1560
		Interquartile Range	440.50000

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	2.696502	Pr > |t|	0.0308
Sign	M	3	Pr >= |M|	0.0313
Signed Rank	S	10.5	Pr >= |S|	0.0313

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.819148	Pr < W	0.0457
Kolmogorov-Smirnov	D	0.298798	Pr > D	0.0346
Cramer-von Mises	W-Sq	0.100764	Pr > W-Sq	0.0930
Anderson-Darling	A-Sq	0.626494	Pr > A-Sq	0.0685

Quantiles (Definition 5)

Quantile	Estimate
100% Max	1560.0
99%	1560.0
95%	1560.0
90%	1560.0
75% Q3	550.0
50% Median	448.0
25% Q1	109.5
10%	0.0
5%	0.0
1%	0.0
0% Min	0.0

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var11

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
0	6	386	2
0	4	510	8
219	1	533	5
386	2	567	7
510	8	1560	3

```
Stem Leaf                     #             Boxplot                                Normal Probability Plot
 14 6                         1                0                  1500+                                     *    ++++
 12                                                                     |                                      ++++
 10                                                                     |                                  ++++
  8                                                                     |                              ++++
  6                                                                     |                          ++++
  4 137                       3             +--+--+                    |                      +++*  *   *
  2 29                        2             |     |                     |                  *++*
  0 00                        2             +-----+                  100+           *    *+++
    ----+----+----+----+                                                  +----+----+----+----+----+----+----+----+----+----+
Multiply Stem.Leaf by 10**+2                                                -2        -1         0        +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var12

Moments

N	8	Sum Weights	8
Mean	585.375	Sum Observations	4683
Std Deviation	444.651047	Variance	197714.554
Skewness	0.71875089	Kurtosis	-0.8769028
Uncorrected SS	4125313	Corrected SS	1384001.88
Coeff Variation	75.9600336	Std Error Mean	157.207885

Basic Statistical Measures

Location		Variability	
Mean	585.3750	Std Deviation	444.65105
Median	446.5000	Variance	197715
Mode	.	Range	1223
		Interquartile Range	710.50000

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	3.723573	Pr > |t|	0.0074
Sign	M	4	Pr >= |M|	0.0078
Signed Rank	S	18	Pr >= |S|	0.0078

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.91555	Pr < W	0.3948
Kolmogorov-Smirnov	D	0.189649	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.053325	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.326591	Pr > A-Sq	>0.2500

Quantiles (Definition 5)

Quantile	Estimate
100% Max	1323.0
99%	1323.0
95%	1323.0
90%	1323.0
75% Q3	947.0
50% Median	446.5
25% Q1	236.5
10%	100.0
5%	100.0
1%	100.0
0% Min	100.0

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var12

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
100	3	380	8
183	5	513	2
290	6	795	1
380	8	1099	4
513	2	1323	7

```
Stem Leaf                     #             Boxplot                                Normal Probability Plot
 12 2                         1                |                  1300+                                     *++++
 10 0                         1                |                      |                                 *++++
  8 0                         1             +-----+                   |                              +++++
  6                                         |     |                700+                         ++++*
  4 1                         1             *--+--*                   |                     +++++ *
  2 98                        2             +-----+                   |                 +++*  *
  0 08                        2                |                   100+           *++++*
    ----+----+----+----+                                                +----+----+----+----+----+----+----+----+----+----+
Multiply Stem.Leaf by 10**+2                                              -2        -1         0        +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var13

Moments

N	8	Sum Weights	8
Mean	4315.25	Sum Observations	34522
Std Deviation	1481.45746	Variance	2194716.21
Skewness	1.09021938	Kurtosis	2.28105949
Uncorrected SS	164334074	Corrected SS	15363013.5
Coeff Variation	34.3307448	Std Error Mean	523.774309

Basic Statistical Measures

Location		Variability	
Mean	4315.250	Std Deviation	1481
Median	4227.000	Variance	2194716
Mode	.	Range	4970
		Interquartile Range	1309

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	8.238758	Pr > |t|	<.0001
Sign	M	4	Pr >= |M|	0.0078
Signed Rank	S	18	Pr >= |S|	0.0078

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.91366	Pr < W	0.3806
Kolmogorov-Smirnov	D	0.245988	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.060214	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.380063	Pr > A-Sq	>0.2500

Quantiles (Definition 5)

Quantile	Estimate
100% Max	7345.0
99%	7345.0
95%	7345.0
90%	7345.0
75% Q3	4741.5
50% Median	4227.0
25% Q1	3432.5
10%	2375.0
5%	2375.0
1%	2375.0
0% Min	2375.0

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var13

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
2375	1	3881	4
3090	8	4573	2
3775	6	4680	3
3881	4	4803	5
4573	2	7345	7

```
Stem Leaf                     #             Boxplot                                Normal Probability Plot
  7 3                         1                0                  7500+                                     *    ++++++
  6                                                                    |                                 +++++++
  5                                                                    |                            +++++++
  4 678                       3             +--+--+                   |                       ++++*++*   *
  3 189                       3             +-----+                   |                  *+++*++*
  2 4                         1                |                  2500+           +*+++++
    ----+----+----+----+                                             +----+----+----+----+----+----+----+----+----+----+
Multiply Stem.Leaf by 10**+3                                             -2        -1         0        +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var14

Moments

N	8	Sum Weights	8
Mean	90.375	Sum Observations	723
Std Deviation	54.0209946	Variance	2918.26786
Skewness	1.08585099	Kurtosis	-0.3877307
Uncorrected SS	85769	Corrected SS	20427.875
Coeff Variation	59.7742679	Std Error Mean	19.0993058

Basic Statistical Measures

Location		Variability	
Mean	90.37500	Std Deviation	54.02099
Median	73.00000	Variance	2918
Mode	.	Range	140.00000
		Interquartile Range	76.50000

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	4.731847	Pr > |t|	0.0021
Sign	M	4	Pr >= |M|	0.0078
Signed Rank	S	18	Pr >= |S|	0.0078

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.81937	Pr < W	0.0460
Kolmogorov-Smirnov	D	0.274908	Pr > D	0.0747
Cramer-von Mises	W-Sq	0.117784	Pr > W-Sq	0.0519
Anderson-Darling	A-Sq	0.679145	Pr > A-Sq	0.0470

Quantiles (Definition 5)

Quantile	Estimate
100% Max	178.0
99%	178.0
95%	178.0
90%	178.0
75% Q3	128.5
50% Median	73.0
25% Q1	52.0
10%	38.0
5%	38.0
1%	38.0
0% Min	38.0

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var14

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
38	1	71	6
45	4	75	3
59	5	87	2
71	6	170	8
75	3	178	7

```
Stem Leaf                     #             Boxplot                                Normal Probability Plot
 16 08                        2                |                  170+                                  *   +*++
 14                                            |                     |                                 +++
 12                                       +-----+                    |                              ++++
 10                                       |     |                    |                          ++++
  8 7                         1           |  +  |                    |                       +++   *
  6 15                        2           *-----*                    |                   +++*   *
  4 59                        2           +-----+                    |                *+++*
  2 8                         1              |                   30+           *++++
    ----+----+----+----+                                              +----+----+----+----+----+----+----+----+----+----+
Multiply Stem.Leaf by 10**+1                                              -2        -1         0        +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var15

Moments

N	8	Sum Weights	8
Mean	788.375	Sum Observations	6307
Std Deviation	740.172362	Variance	547855.125
Skewness	2.35449393	Kurtosis	6.06531906
Uncorrected SS	8807267	Corrected SS	3834985.88
Coeff Variation	93.8858236	Std Error Mean	261.690448

Basic Statistical Measures

Location		Variability	
Mean	788.3750	Std Deviation	740.17236
Median	583.0000	Variance	547855
Mode	.	Range	2351
		Interquartile Range	409.00000

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	3.012624	Pr > |t|	0.0196
Sign	M	4	Pr >= |M|	0.0078
Signed Rank	S	18	Pr >= |S|	0.0078

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.705571	Pr < W	0.0026
Kolmogorov-Smirnov	D	0.337528	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.185555	Pr > W-Sq	0.0058
Anderson-Darling	A-Sq	1.047666	Pr > A-Sq	<0.0050

Quantiles (Definition 5)

Quantile	Estimate
100% Max	2540.0
99%	2540.0
95%	2540.0
90%	2540.0
75% Q3	807.5
50% Median	583.0
25% Q1	398.5
10%	189.0
5%	189.0
1%	189.0
0% Min	189.0

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var15

Extreme Observations

----Lowest----		----Highest---	
Value	Obs	Value	Obs
189	4	518	5
349	1	648	2
448	3	757	8
518	5	858	7
648	2	2540	6

```
Stem Leaf                     #             Boxplot                               Normal Probability Plot
  2 5                         1                *                  2750+                                     *         ++
  2                                                                    |                                        +++++++
  1                                                                    |                                 +++++++
  1                                                                    |                            +++++++
  0 5689                      4             +--+--+                   |                       +*+++*  *   *
  0 234                       3             +-----+                250+            *   +*+++*+
    ----+----+----+----+                                                +----+----+----+----+----+----+----+----+----+----+
Multiply Stem.Leaf by 10**+3                                              -2        -1         0        +1        +2
```

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var17

Moments

N	8	Sum Weights	8
Mean	1115555.13	Sum Observations	8924441
Std Deviation	634626.486	Variance	4.02751E11
Skewness	1.03089138	Kurtosis	-0.6533696
Uncorrected SS	1.2775E13	Corrected SS	2.81926E12
Coeff Variation	56.8888504	Std Error Mean	224374.346

Basic Statistical Measures

Location		Variability	
Mean	1115555	Std Deviation	634626
Median	820671	Variance	4.02751E11
Mode	.	Range	1594670
		Interquartile Range	1005366

Tests for Location: Mu0=0

Test	-Statistic-		-----p Value------	
Student's t	t	4.971848	Pr > |t|	0.0016
Sign	M	4	Pr >= |M|	0.0078
Signed Rank	S	18	Pr >= |S|	0.0078

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.809657	Pr < W	0.0363
Kolmogorov-Smirnov	D	0.287685	Pr > D	0.0491
Cramer-von Mises	W-Sq	0.12055	Pr > W-Sq	0.0476
Anderson-Darling	A-Sq	0.693146	Pr > A-Sq	0.0437

Quantiles (Definition 5)

Quantile	Estimate
100% Max	2180683
99%	2180683
95%	2180683
90%	2180683
75% Q3	1631784
50% Median	820671
25% Q1	626418
10%	586013
5%	586013
1%	586013
0% Min	586013

Deskriptivna statistika

The UNIVARIATE Procedure
Variable: var17

Extreme Observations

-----Lowest-----		-----Highest-----	
Value	Obs	Value	Obs
586013	1	792204	2
610758	6	849138	8
642078	3	1302523	4
792204	2	1961044	7
849138	8	2180683	5

```
Stem Leaf                     #             Boxplot                                Normal Probability Plot
 20 8                         1                |              2100000+                                     *+++
 18 6                         1                |                     |                                 * +++
 16                                       +-----+                     |                                +++
 14                                       |     |                     |                             +++
 12 0                         1           |     |           1300000+                          +++*
 10                                       |  +  |                     |                       +++
  8 5                         1           *-----*                     |                    +++   *
  6 149                       3           +-----+                     |                *+++*  *
  4 9                         1                |              500000+           *  +++
    ----+----+----+----+                                              +----+----+----+----+----+----+----+----+----+----+
Multiply Stem.Leaf by 10**+5                                              -2        -1         0        +1        +2
```

Deskriptivna statistika

The FREQ Procedure

var16	Frequency	Percent	Cumulative Frequency	Cumulative Percent
1	1	12.50	1	12.50
2	7	87.50	8	100.00

multivarijatna regresija-dijagnostika model

The CORR Procedure

16 Variables: var1 var2 var3 var4 var5 var6 var7 var8 var9 var10 var11 var12 var13 var14 var15 var17

Simple Statistics

Variable	N	Mean	Std Dev	Sum	Minimum	Maximum
var1	8	123.00000	97.46208	984.00000	10.00000	293.00000
var2	8	14.12500	9.41788	113.00000	4.00000	33.00000
var3	8	8.75000	2.81577	70.00000	4.00000	12.00000
var4	8	4.00000	0.92582	32.00000	3.00000	5.00000
var5	8	846.62500	281.32540	6773	284.00000	1100
var6	8	735.12500	292.07750	5881	223.00000	1170
var7	8	966.25000	681.48404	7730	140.00000	2193
var8	8	222.12500	197.37523	1777	72.00000	680.00000
var9	8	337.25000	191.97079	2698	140.00000	755.00000
var10	8	85.87500	45.64283	687.00000	0	144.00000
var11	8	471.87500	494.96131	3775	0	1560
var12	8	585.37500	444.65105	4683	100.00000	1323
var13	8	4315	1481	34522	2375	7345
var14	8	90.37500	54.02099	723.00000	38.00000	178.00000
var15	8	788.37500	740.17236	6307	189.00000	2540
var17	8	1115555	634626	8924441	586013	2180683

Pearson Correlation Coefficients, N = 8
Prob > |r| under H0: Rho=0

	var1	var2	var3	var4	var5	var6	var7	var8
var1	1.00000	-0.02770	0.27590	-0.63804	0.37942	0.47058	0.59094	-0.01987
		0.9481	0.5083	0.0887	0.3539	0.2393	0.1229	0.9628
var2	-0.02770	1.00000	0.83634	0.27853	0.33637	0.47218	-0.09398	0.53235
	0.9481		0.0097	0.5041	0.4153	0.2375	0.8248	0.1744
var3	0.27590	0.83634	1.00000	0.21920	0.30951	0.47998	0.11692	0.64808
	0.5083	0.0097		0.6020	0.4557	0.2287	0.7828	0.0822

	var9	var10	var11	var12	var13	var14	var15	var17
var1	0.50656	0.43238	-0.14499	0.38700	0.66768	0.18942	0.05354	0.33288
	0.2002	0.2847	0.7319	0.3436	0.0704	0.6532	0.8998	0.4204
var2	-0.40600	0.25926	0.19252	-0.46376	0.05886	-0.00151	0.82438	-0.45226
	0.3183	0.5352	0.6478	0.2471	0.8899	0.9972	0.0118	0.2605
var3	-0.15262	0.63442	0.44022	-0.39208	0.34454	0.04860	0.54587	-0.24654
	0.7182	0.0911	0.2750	0.3367	0.4033	0.9090	0.1616	0.5561

	var1	var2	var3	var4	var5	var6	var7	var8
var4	-0.63804	0.27853	0.21920	1.00000	-0.52655	-0.32332	-0.46281	0.35805
	0.0887	0.5041	0.6020		0.1800	0.4347	0.2482	0.3838
var5	0.37942	0.33637	0.30951	-0.52655	1.00000	0.79445	0.24908	0.51173
	0.3539	0.4153	0.4557	0.1800		0.0185	0.5519	0.1949
var6	0.47058	0.47218	0.47998	-0.32332	0.79445	1.00000	0.64159	0.38271
	0.2393	0.2375	0.2287	0.4347	0.0185		0.0864	0.3494
var7	0.59094	-0.09398	0.11692	-0.46281	0.24908	0.64159	1.00000	-0.26256
	0.1229	0.8248	0.7828	0.2482	0.5519	0.0864		0.5299
var8	-0.01987	0.53235	0.64808	0.35805	0.51173	0.38271	-0.26256	1.00000
	0.9628	0.1744	0.0822	0.3838	0.1949	0.3494	0.5299	
var9	0.50656	-0.40600	-0.15262	-0.15674	0.02264	0.39674	0.75903	-0.15452
	0.2002	0.3183	0.7182	0.7109	0.9576	0.3305	0.0290	0.7149
var10	0.43238	0.25926	0.63442	-0.30426	0.44087	0.42923	0.41632	0.38263
	0.2847	0.5352	0.0911	0.4637	0.2742	0.2886	0.3049	0.3495
var11	-0.14499	0.19252	0.44022	0.42710	0.26827	0.14280	-0.20557	0.86199
	0.7319	0.6478	0.2750	0.2913	0.5206	0.7359	0.6253	0.0059
var12	0.38700	-0.46376	-0.39208	-0.18045	-0.10896	0.10528	0.36037	-0.32431
	0.3436	0.2471	0.3367	0.6689	0.7973	0.8041	0.3805	0.4332
var13	0.66768	0.05886	0.34454	-0.32413	0.61020	0.82483	0.74833	0.36171
	0.0704	0.8899	0.4033	0.4335	0.1082	0.0117	0.0327	0.3786
var14	0.18942	-0.00151	0.04860	0.26279	-0.03783	0.36763	0.42890	0.08762
	0.6532	0.9972	0.9090	0.5295	0.9291	0.3703	0.2890	0.8366
var15	0.05354	0.82438	0.54587	0.04149	0.19020	0.49060	0.21023	0.00536
	0.8998	0.0118	0.1616	0.9223	0.6519	0.2171	0.6173	0.9899
var17	0.33288	-0.45226	-0.24654	-0.53447	0.33841	0.47168	0.81836	-0.22620
	0.4204	0.2605	0.5561	0.1724	0.4123	0.2380	0.0130	0.5901

	var9	var10	var11	var12	var13	var14	var15	var17
var4	-0.15674	-0.30426	0.42710	-0.18045	-0.32413	0.26279	0.04149	-0.53447
	0.7109	0.4637	0.2913	0.6689	0.4335	0.5295	0.9223	0.1724
var5	0.02264	0.44087	0.26827	-0.10896	0.61020	-0.03783	0.19020	0.33841
	0.9576	0.2742	0.5206	0.7973	0.1082	0.9291	0.6519	0.4123
var6	0.39674	0.42923	0.14280	0.10528	0.82483	0.36763	0.49060	0.47168

	0.3305	0.2886	0.7359	0.8041	0.0117	0.3703	0.2171	0.2380

	var9	var10	var11	var12	var13	var14	var15	var17
var7	0.75903	0.41632	-0.20557	0.36037	0.74833	0.42890	0.21023	0.81836
	0.0290	0.3049	0.6253	0.3805	0.0327	0.2890	0.6173	0.0130
var8	-0.15452	0.38263	0.86199	-0.32431	0.36171	0.08762	0.00536	-0.22620
	0.7149	0.3495	0.0059	0.4332	0.3786	0.8366	0.9899	0.5901
var9	1.00000	0.01766	-0.00229	0.64342	0.73494	0.75133	-0.19993	0.68179
		0.9669	0.9957	0.0852	0.0378	0.0316	0.6350	0.0626
var10	0.01766	1.00000	0.36858	-0.22110	0.51929	-0.29622	0.03490	0.37146
	0.9669		0.3689	0.5988	0.1872	0.4762	0.9346	0.3649
var11	-0.00229	0.36858	1.00000	-0.41555	0.31105	0.19668	-0.31274	-0.03101
	0.9957	0.3689		0.3059	0.4533	0.6406	0.4507	0.9419
var12	0.64342	-0.22110	-0.41555	1.00000	0.35226	0.23819	-0.24975	0.32255
	0.0852	0.5988	0.3059		0.3921	0.5700	0.5508	0.4359
var13	0.73494	0.51929	0.31105	0.35226	1.00000	0.49612	0.01611	0.66409
	0.0378	0.1872	0.4533	0.3921		0.2111	0.9698	0.0725
var14	0.75133	-0.29622	0.19668	0.23819	0.49612	1.00000	0.12170	0.23692
	0.0316	0.4762	0.6406	0.5700	0.2111		0.7741	0.5721
var15	-0.19993	0.03490	-0.31274	-0.24975	0.01611	0.12170	1.00000	-0.23655
	0.6350	0.9346	0.4507	0.5508	0.9698	0.7741		0.5727
var17	0.68179	0.37146	-0.03101	0.32255	0.66409	0.23692	-0.23655	1.00000
	0.0626	0.3649	0.9419	0.4359	0.0725	0.5721	0.5727	

The REG Procedure
Model: MODEL1
Dependent Variable: var17

R-Square Selection Method

Number of Observations Read 8
Number of Observations Used 8

Number in Model	R-Square	Adjusted R-Square	C(p)	Root MSE	Variables in Model
1	0.6697	0.6147	.	393946	var7
1	0.4648	0.3756	.	501458	var9
1	0.4410	0.3478	.	512499	var13
1	0.2857	0.1666	.	579356	var4
1	0.2225	0.0929	.	604429	var6
1	0.2045	0.0720	.	611365	var2
1	0.1380	-.0057	.	636429	var10
1	0.1145	-.0331	.	645032	var5
1	0.1108	-.0374	.	646383	var1
1	0.1040	-.0453	.	648838	var12
1	0.0608	-.0958	.	664317	var3
1	0.0561	-.1012	.	665959	var14
1	0.0560	-.1014	.	666020	var15
1	0.0512	-.1070	.	667707	var8
1	0.0288	-.1331	.	675541	var16
1	0.0010	-.1655	.	685145	var11
2	0.8444	0.7821	.	296217	var7 var15
2	0.8119	0.7366	.	325705	var2 var7
2	0.8088	0.7323	.	328338	var2 var6
2	0.7885	0.7038	.	345372	var3 var7
2	0.7046	0.5865	.	408105	var1 var7
2	0.7006	0.5808	.	410891	var4 var7
2	0.6974	0.5763	.	413070	var3 var13
2	0.6913	0.5678	.	417207	var8 var13
2	0.6894	0.5651	.	418503	var7 var11
2	0.6890	0.5646	.	418744	var5 var7
2	0.6857	0.5599	.	421000	var7 var14
2	0.6833	0.5566	.	422594	var2 var13
2	0.6784	0.5497	.	425842	var7 var9
2	0.6758	0.5461	.	427561	var7 var13
2	0.6746	0.5444	.	428371	var6 var7
2	0.6709	0.5392	.	430797	var7 var10
3	0.9088	0.8405	.	253489	var3 var7 var11
3	0.9028	0.8299	.	261742	var3 var7 var10
3	0.9027	0.8297	.	261880	var2 var5 var7
3	0.8968	0.8194	.	269732	var3 var7 var8
3	0.8951	0.8164	.	271912	var1 var7 var15
3	0.8852	0.7990	.	284499	var5 var7 var15
3	0.8846	0.7980	.	285211	var2 var6 var7
3	0.8805	0.7908	.	290243	var3 var10 var14
3	0.8744	0.7802	.	297558	var7 var9 var15
3	0.8674	0.7680	.	305663	var2 var6 var10
3	0.8657	0.7651	.	307610	var6 var7 var15
3	0.8647	0.7632	.	308827	var3 var7 var15
3	0.8608	0.7563	.	313269	var7 var12 var15
3	0.8606	0.7561	.	313409	var2 var7 var8
3	0.8568	0.7494	.	317696	var7 var14 var15
3	0.8565	0.7489	.	318005	var4 var7 var15
4	0.9989	0.9974	.	32104	var1 var4 var9 var10
4	0.9917	0.9806	.	88305	var1 var4 var5 var13
4	0.9885	0.9731	.	104180	var6 var7 var13 var15
4	0.9868	0.9693	.	111187	var2 var3 var10 var14
4	0.9837	0.9619	.	123797	var3 var7 var11 var14
4	0.9822	0.9585	.	129242	var7 var10 var11 var14
4	0.9810	0.9556	.	133756	var1 var2 var5 var7
4	0.9777	0.9481	.	144633	var1 var5 var7 var15
4	0.9758	0.9436	.	150731	var3 var7 var8 var10
4	0.9735	0.9381	.	157879	var3 var10 var14 var15
4	0.9728	0.9366	.	159755	var3 var7 var9 var11
4	0.9690	0.9278	.	170567	var3 var7 var10 var11
4	0.9621	0.9117	.	188622	var1 var4 var7 var15
4	0.9619	0.9110	.	189341	var3 var6 var10 var14
4	0.9584	0.9029	.	197776	var3 var7 var8 var14
4	0.9580	0.9020	.	198683	var3 var7 var11 var16
5	1.0000	1.0000	.	3450.81816	var1 var2 var4 var9 var10
5	1.0000	0.9999	.	5329.93638	var1 var3 var4 var9 var10
5	1.0000	0.9999	.	6340.44379	var3 var6 var7 var8 var9
5	1.0000	0.9999	.	7018.97635	var1 var4 var6 var7 var13
5	0.9999	0.9997	.	10425	var1 var4 var5 var7 var15
5	0.9999	0.9997	.	11156	var3 var9 var10 var11 var15
5	0.9998	0.9994	.	15880	var1 var4 var9 var10 var15
5	0.9998	0.9994	.	15989	var1 var4 var6 var9 var10
5	0.9998	0.9992	.	18377	var1 var4 var7 var13 var15
5	0.9996	0.9986	.	23761	var2 var3 var9 var10 var16
5	0.9995	0.9983	.	26190	var1 var4 var9 var10 var14
5	0.9994	0.9981	.	27972	var1 var4 var7 var9 var10
5	0.9994	0.9977	.	30243	var1 var4 var6 var7 var15
5	0.9993	0.9977	.	30625	var1 var4 var9 var10 var13
5	0.9993	0.9976	.	31305	var1 var2 var4 var7 var8
5	0.9993	0.9976	.	31318	var1 var4 var5 var9 var10
6	1.0000	1.0000	.	9.20251	var3 var7 var10 var11 var15 var16
6	1.0000	1.0000	.	21.39483	var1 var4 var7 var11 var13 var15
6	1.0000	1.0000	.	232.32289	var1 var3 var4 var5 var7 var15
6	1.0000	1.0000	.	293.54914	var3 var6 var7 var8 var9 var10
6	1.0000	1.0000	.	362.41939	var1 var3 var4 var9 var11 var15
6	1.0000	1.0000	.	414.28423	var1 var2 var4 var9 var10 var16
6	1.0000	1.0000	.	418.65830	var1 var4 var6 var7 var11 var15
6	1.0000	1.0000	.	460.42466	var1 var5 var7 var11 var12 var15
6	1.0000	1.0000	.	469.63435	var3 var8 var9 var10 var11 var15
6	1.0000	1.0000	.	568.47470	var1 var2 var4 var5 var11 var13
6	1.0000	1.0000	.	625.96427	var1 var2 var8 var10 var14 var15
6	1.0000	1.0000	.	664.61626	var1 var2 var3 var9 var10 var12
6	1.0000	1.0000	.	668.05781	var2 var6 var7 var8 var13 var14

6	1.0000	1.0000	.	695.92281	var1 var4 var6 var7 var13 var15
6	1.0000	1.0000	.	756.62712	var1 var2 var3 var4 var7 var13
6	1.0000	1.0000	.	792.85105	var2 var3 var4 var9 var10 var12
7	1.0000	.	.	.	var4 var5 var9 var11 var13 var15 var16
7	1.0000	.	.	.	var3 var4 var6 var9 var13 var15 var16
7	1.0000	.	.	.	var1 var3 var6 var9 var13 var15 var16
7	1.0000	.	.	.	var3 var6 var9 var11 var13 var15 var16
7	1.0000	.	.	.	var1 var3 var5 var9 var13 var15 var16
7	1.0000	.	.	.	var1 var5 var6 var11 var13 var15 var16
7	1.0000	.	.	.	var1 var3 var5 var9 var11 var13 var16
7	1.0000	.	.	.	var1 var3 var5 var6 var13 var15 var16
7	1.0000	.	.	.	var3 var5 var6 var9 var13 var14 var15
7	1.0000	.	.	.	var1 var3 var9 var11 var13 var15 var16
7	1.0000	.	.	.	var1 var4 var6 var9 var11 var13 var16
7	1.0000	.	.	.	var1 var5 var6 var9 var13 var15 var16
7	1.0000	.	.	.	var1 var6 var9 var11 var13 var14 var16
7	1.0000	.	.	.	var2 var3 var6 var8 var12 var13 var16
7	1.0000	.	.	.	var4 var5 var6 var10 var11 var14 var16
7	1.0000	.	.	.	var4 var5 var6 var8 var13 var15 var16

NOTE: Models of not full rank are not included.

The REG Procedure
Model: MODEL1
Dependent Variable: var17

R-Square Selection Method

Number of Observations Read 8
Number of Observations Used 8

Number in Model	R-Square	Adjusted R-Square	C(p)	Root MSE	Variables in Model
1	0.6697	0.6147	.	393946	var7
1	0.4648	0.3756	.	501458	var9
1	0.4410	0.3478	.	512499	var13
1	0.2857	0.1666	.	579356	var4
1	0.2225	0.0929	.	604429	var6
1	0.2045	0.0720	.	611365	var2
1	0.1380	-.0057	.	636429	var10
1	0.1145	-.0331	.	645032	var5
1	0.1108	-.0374	.	646383	var1
1	0.1040	-.0453	.	648838	var12
1	0.0608	-.0958	.	664317	var3
1	0.0561	-.1012	.	665959	var14
1	0.0560	-.1014	.	666020	var15
1	0.0512	-.1070	.	667707	var8
1	0.0288	-.1331	.	675541	var16
1	0.0010	-.1655	.	685145	var11
2	0.8444	0.7821	.	296217	var7 var15
2	0.8119	0.7366	.	325705	var2 var7
2	0.8088	0.7323	.	328338	var2 var6
2	0.7885	0.7038	.	345372	var3 var7
2	0.7046	0.5865	.	408105	var1 var7
2	0.7006	0.5808	.	410891	var4 var7
2	0.6974	0.5763	.	413070	var3 var13
2	0.6913	0.5678	.	417207	var8 var13
2	0.6894	0.5651	.	418503	var7 var11
2	0.6890	0.5646	.	418744	var5 var7
2	0.6857	0.5599	.	421000	var7 var14
2	0.6833	0.5566	.	422594	var2 var13
2	0.6784	0.5497	.	425842	var7 var9
2	0.6758	0.5461	.	427561	var7 var13
2	0.6746	0.5444	.	428371	var6 var7
2	0.6709	0.5392	.	430797	var7 var10
3	0.9088	0.8405	.	253489	var3 var7 var11
3	0.9028	0.8299	.	261742	var3 var7 var10
3	0.9027	0.8297	.	261880	var2 var5 var7
3	0.8968	0.8194	.	269732	var3 var7 var8
3	0.8951	0.8164	.	271912	var1 var7 var15
3	0.8852	0.7990	.	284499	var5 var7 var15
3	0.8846	0.7980	.	285211	var2 var6 var7
3	0.8805	0.7908	.	290243	var3 var10 var14
3	0.8744	0.7802	.	297558	var7 var9 var15
3	0.8674	0.7680	.	305663	var2 var6 var10
3	0.8657	0.7651	.	307610	var6 var7 var15
3	0.8647	0.7632	.	308827	var3 var7 var15
3	0.8608	0.7563	.	313269	var7 var12 var15
3	0.8606	0.7561	.	313409	var2 var7 var8
3	0.8568	0.7494	.	317696	var7 var14 var15
3	0.8565	0.7489	.	318005	var4 var7 var15
4	0.9989	0.9974	.	32104	var1 var4 var9 var10
4	0.9917	0.9806	.	88305	var1 var4 var5 var13
4	0.9885	0.9731	.	104180	var6 var7 var13 var15
4	0.9868	0.9693	.	111187	var2 var3 var10 var14
4	0.9837	0.9619	.	123797	var3 var7 var11 var14
4	0.9822	0.9585	.	129242	var7 var10 var11 var14
4	0.9810	0.9556	.	133756	var1 var2 var5 var7
4	0.9777	0.9481	.	144633	var1 var5 var7 var15
4	0.9758	0.9436	.	150731	var3 var7 var8 var10
4	0.9735	0.9381	.	157879	var3 var10 var14 var15
4	0.9728	0.9366	.	159755	var3 var7 var9 var11
4	0.9690	0.9278	.	170567	var3 var7 var10 var11
4	0.9621	0.9117	.	188622	var1 var4 var7 var15
4	0.9619	0.9110	.	189341	var3 var6 var10 var14
4	0.9584	0.9029	.	197776	var3 var7 var8 var14
4	0.9580	0.9020	.	198683	var3 var7 var11 var16
5	1.0000	1.0000	.	3450.81816	var1 var2 var4 var9 var10
5	1.0000	0.9999	.	5329.93638	var1 var3 var4 var9 var10
5	1.0000	0.9999	.	6340.44379	var3 var6 var7 var8 var9
5	1.0000	0.9999	.	7018.97635	var1 var4 var6 var7 var13
5	0.9999	0.9997	.	10425	var1 var4 var5 var7 var15
5	0.9999	0.9997	.	11156	var3 var9 var10 var11 var15
5	0.9998	0.9994	.	15880	var1 var4 var9 var10 var15
5	0.9998	0.9994	.	15989	var1 var4 var6 var9 var10
5	0.9998	0.9992	.	18377	var1 var4 var7 var13 var15
5	0.9996	0.9986	.	23761	var2 var3 var9 var10 var16
5	0.9995	0.9983	.	26190	var1 var4 var9 var10 var14
5	0.9994	0.9981	.	27972	var1 var4 var7 var9 var10
5	0.9994	0.9977	.	30243	var1 var4 var6 var7 var15
5	0.9993	0.9977	.	30625	var1 var4 var9 var10 var13
5	0.9993	0.9976	.	31305	var1 var2 var4 var7 var8
5	0.9993	0.9976	.	31318	var1 var4 var5 var9 var10
6	1.0000	1.0000	.	9.20251	var3 var7 var10 var11 var15 var16
6	1.0000	1.0000	.	21.39483	var1 var4 var7 var11 var13 var15
6	1.0000	1.0000	.	232.32289	var1 var3 var4 var5 var7 var15
6	1.0000	1.0000	.	293.54914	var3 var6 var7 var8 var9 var10
6	1.0000	1.0000	.	362.41939	var1 var3 var4 var9 var11 var15
6	1.0000	1.0000	.	414.28423	var1 var2 var4 var9 var10 var16
6	1.0000	1.0000	.	418.65830	var1 var4 var6 var7 var11 var15
6	1.0000	1.0000	.	460.42466	var1 var5 var7 var11 var12 var15
6	1.0000	1.0000	.	469.63435	var3 var8 var9 var10 var11 var15
6	1.0000	1.0000	.	568.47470	var1 var2 var4 var5 var11 var13
6	1.0000	1.0000	.	625.96427	var1 var2 var8 var10 var14 var15
6	1.0000	1.0000	.	664.61626	var1 var2 var3 var9 var10 var12

6	1.0000	1.0000	.	668.05781	var2 var6 var7 var8 var13 var14
6	1.0000	1.0000	.	695.92281	var1 var4 var6 var7 var13 var15
6	1.0000	1.0000	.	756.62712	var1 var2 var3 var4 var7 var13
6	1.0000	1.0000	.	792.85105	var2 var3 var4 var9 var10 var12
7	1.0000	.	.	.	var4 var5 var9 var11 var13 var15 var16
7	1.0000	.	.	.	var3 var4 var6 var9 var13 var15 var16
7	1.0000	.	.	.	var1 var3 var6 var9 var13 var15 var16
7	1.0000	.	.	.	var3 var6 var9 var11 var13 var15 var16
7	1.0000	.	.	.	var1 var3 var5 var9 var13 var15 var16
7	1.0000	.	.	.	var1 var5 var6 var11 var13 var15 var16
7	1.0000	.	.	.	var1 var3 var5 var9 var11 var13 var16
7	1.0000	.	.	.	var1 var3 var5 var6 var13 var15 var16
7	1.0000	.	.	.	var3 var5 var6 var9 var13 var14 var15
7	1.0000	.	.	.	var1 var3 var9 var11 var13 var15 var16
7	1.0000	.	.	.	var1 var4 var6 var9 var11 var13 var16
7	1.0000	.	.	.	var1 var5 var6 var9 var13 var15 var16
7	1.0000	.	.	.	var1 var6 var9 var11 var13 var14 var16
7	1.0000	.	.	.	var2 var3 var6 var8 var12 var13 var16
7	1.0000	.	.	.	var4 var5 var6 var10 var11 var14 var16
7	1.0000	.	.	.	var4 var5 var6 var8 var13 var15 var16

NOTE: Models of not full rank are not included.

The REG Procedure
Model: MODEL1
Dependent Variable: var17

Number of Observations Read	8
Number of Observations Used	8

Stepwise Selection: Step 1

Variable var7 Entered: R-Square = 0.6697 and C(p) = .

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	1	1.888096E12	1.888096E12	12.17	0.0130
Error	6	9.31159E11	1.551932E11		
Corrected Total	7	2.819255E12			

Variable	Parameter Estimate	Standard Error	Type II SS	F Value	Pr > F
Intercept	379184	252921	3.488204E11	2.25	0.1845
var7	762.09195	218.49001	1.888096E12	12.17	0.0130

Bounds on condition number: 1, 1

Stepwise Selection: Step 2

Variable var15 Entered: R-Square = 0.8444 and C(p) = .

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	2	2.380532E12	1.190266E12	13.57	0.0096
Error	5	4.387234E11	87744678658		
Corrected Total	7	2.819255E12			

Variable	Parameter Estimate	Standard Error	Type II SS	F Value	Pr > F
Intercept	587281	209484	6.896192E11	7.86	0.0378
var7	845.78152	168.04322	2.222773E12	25.33	0.0040
var15	-366.52886	154.71907	4.924356E11	5.61	0.0640

Bounds on condition number: 1.0462, 4.185

All variables left in the model are significant at the 0.1500 level.

No other variable met the 0.1500 significance level for entry into the model.

Summary of Stepwise Selection

Step	Variable Entered	Variable Removed	Number Vars In	Partial R-Square	Model R-Square	C(p)	F Value	Pr > F
1	var7		1	0.6697	0.6697	.	12.17	0.0130
2	var15		2	0.1747	0.8444	.	5.61	0.0640

modeli s jednom varijablom

The REG Procedure
Model: MODEL1
Dependent Variable: var17

Number of Observations Read	8
Number of Observations Used	8

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	1	1.888096E12	1.888096E12	12.17	0.0130
Error	6	9.31159E11	1.551932E11		
Corrected Total	7	2.819255E12			

Root MSE	393946	R-Square	0.6697
Dependent Mean	1115555	Adj R-Sq	0.6147
Coeff Var	35.31387		

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
Intercept	1	379184	252921	1.50	0.1845
var7	1	762.09195	218.49001	3.49	0.0130

Output Statistics

Obs	Dependent Variable	Predicted Value	Std Error Mean Predict	Residual	Std Error Residual	Student Residual	-2-1 0 1 2	Cook's D
1	586013	735081	176912	-149068	351988	-0.424	| | |	0.023
2	792204	1108506	139295	-316302	368497	-0.858	| *| |	0.053
3	642078	485877	228012	156201	321254	0.486	| | |	0.060
4	1302523	837963	160415	464560	359806	1.291	| |** |	0.166
5	2180683	1683885	214355	496798	330522	1.503	| |*** |	0.475
6	610758	1170997	140185	-560239	368159	-1.522	| ***| |	0.168
7	1961044	2050451	302061	-89407	252888	-0.354	| | |	0.089
8	849138	851681	158500	-2543	360653	-0.0071	| | |	0.000

Sum of Residuals	0
Sum of Squared Residuals	9.31159E11
Predicted Residual SS (PRESS)	1.487504E12

modeli s jednom varijablom

The REG Procedure
Model: MODEL1
Dependent Variable: var17

Number of Observations Read	8
Number of Observations Used	8

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	1	1.310495E12	1.310495E12	5.21	0.0626
Error	6	1.50876E12	2.5146E11		
Corrected Total	7	2.819255E12			

Root MSE	501458	R-Square	0.4648
Dependent Mean	1115555	Adj R-Sq	0.3756
Coeff Var	44.95142		

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
Intercept	1	355429	377227	0.94	0.3825
var9	1	2253.89426	987.30266	2.28	0.0626

Output Statistics

Obs	Dependent Variable	Predicted Value	Std Error Mean Predict	Residual	Std Error Residual	Student Residual	-2-1 0 1 2	Cook's D
1	586013	882841	204509	-296828	457860	-0.648	| *| |	0.042
2	792204	1130769	177417	-338565	469024	-0.722	| *| |	0.037
3	642078	738591	242279	-96513	439045	-0.220	| | |	0.007
4	1302523	1027090	181478	275433	467467	0.589	| |* |	0.026
5	2180683	1160070	178361	1020613	468665	2.178	| |**** |	0.343
6	610758	670974	263360	-60216	426734	-0.141	| | |	0.004
7	1961044	2057119	448936	-96075	223419	-0.430	| | |	0.373
8	849138	1256987	187805	-407849	464962	-0.877	| *| |	0.063

Sum of Residuals	0
Sum of Squared Residuals	1.50876E12
Predicted Residual SS (PRESS)	2.2243E12

modeli s jednom varijablom

The REG Procedure
Model: MODEL1
Dependent Variable: var17

Number of Observations Read	8
Number of Observations Used	8

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	1	1.243322E12	1.243322E12	4.73	0.0725
Error	6	1.575933E12	2.626556E11		
Corrected Total	7	2.819255E12			

Root MSE	512499	R-Square	0.4410
Dependent Mean	1115555	Adj R-Sq	0.3478
Coeff Var	45.94119		

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
Intercept	1	-112053	592617	-0.19	0.8563
var13	1	284.48123	130.75403	2.18	0.0725

Output Statistics

Obs	Dependent Variable	Predicted Value	Std Error Mean Predict	Residual	Std Error Residual	Student Residual	-2-1 0 1 2	Cook's D
1	586013	563590	311758	22423	406770	0.0551	| | |	0.001
2	792204	1188880	184303	-396676	478213	-0.829	| *| |	0.051
3	642078	1219320	187367	-577242	477021	-1.210	| **| |	0.113
4	1302523	992019	189884	310504	476025	0.652	| |* |	0.034
5	2180683	1254311	192092	926372	475138	1.950	| |*** |	0.311
6	610758	961864	194479	-351106	474166	-0.740	| *| |	0.046
7	1961044	1977462	435624	-16418	269976	-0.0608	| | |	0.005
8	849138	766994	241864	82144	451838	0.182	| | |	0.005

Sum of Residuals	0
Sum of Squared Residuals	1.575933E12
Predicted Residual SS (PRESS)	2.126853E12

modeli s dvije varijable

The REG Procedure
Model: MODEL1
Dependent Variable: var17

Number of Observations Read	8
Number of Observations Used	8

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	2	2.380532E12	1.190266E12	13.57	0.0096
Error	5	4.387234E11	87744678658		
Corrected Total	7	2.819255E12			

Root MSE	296217	R-Square	0.8444
Dependent Mean	1115555	Adj R-Sq	0.7821
Coeff Var	26.55335		

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
Intercept	1	587281	209484	2.80	0.0378
var7	1	845.78152	168.04322	5.03	0.0040
var15	1	-366.52886	154.71907	-2.37	0.0640

Output Statistics

Obs	Dependent Variable	Predicted Value	Std Error Mean Predict	Residual	Std Error Residual	Student Residual	-2-1 0 1 2	Cook's D
1	586013	854342	142232	-268329	259836	-1.033	| **| |	0.107
2	792204	1159183	106902	-366979	276255	-1.328	| **| |	0.088
3	642078	541485	173047	100593	240415	0.418	| | |	0.030
4	1302523	1027167	144665	275356	258490	1.065	| |** |	0.118
5	2180683	1845397	175005	335286	238993	1.403	| |** |	0.352
6	610758	535065	288394	75693	67630	1.119	| |** |	7.593
7	1961044	2127598	229449	-166554	187344	-0.889	| *| |	0.395
8	849138	834203	119408	14935	271084	0.0551	| | |	0.000

Sum of Residuals	0
Sum of Squared Residuals	4.387234E11
Predicted Residual SS (PRESS)	3.001304E12

modeli s dvije varijable

The REG Procedure
Model: MODEL1
Dependent Variable: var17

Number of Observations Read	8
Number of Observations Used	8

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	2	1.986508E12	9.93254E11	5.96	0.0474
Error	5	8.327475E11	1.665495E11		
Corrected Total	7	2.819255E12			

Root MSE	408105	R-Square	0.7046
Dependent Mean	1115555	Adj R-Sq	0.5865
Coeff Var	36.58311		

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
Intercept	1	441527	274277	1.61	0.1684
var1	1	-1508.05222	1961.84612	-0.77	0.4768
var7	1	889.54104	280.57239	3.17	0.0248

Output Statistics

Obs	Dependent Variable	Predicted Value	Std Error Mean Predict	Residual	Std Error Residual	Student Residual	-2-1 0 1 2	Cook's D
1	586013	783048	193603	-197035	359260	-0.548	| *| |	0.029
2	792204	850958	364801	-58754	182947	-0.321	| | |	0.137
3	642078	481611	236272	160467	332754	0.482	| | |	0.039
4	1302523	811144	169803	491379	371102	1.324	| |** |	0.122
5	2180683	1790995	262157	389688	312767	1.246	| |** |	0.364
6	610758	1202890	151034	-592132	379128	-1.562	| ***| |	0.129
7	1961044	2025833	314552	-64789	260013	-0.249	| | |	0.030
8	849138	977961	232269	-128823	335560	-0.384	| | |	0.024

Sum of Residuals	0
Sum of Squared Residuals	8.327475E11
Predicted Residual SS (PRESS)	1.534232E12

modeli s dvije varijable

The REG Procedure
Model: MODEL1
Dependent Variable: var17

Number of Observations Read	8
Number of Observations Used	8

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	2	1.975097E12	9.875485E11	5.85	0.0491
Error	5	8.441584E11	1.688317E11		
Corrected Total	7	2.819255E12			

Root MSE	410891	R-Square	0.7006
Dependent Mean	1115555	Adj R-Sq	0.5808
Coeff Var	36.83290		

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
Intercept	1	1005069	910921	1.10	0.3201
var4	1	-135840	189231	-0.72	0.5050
var7	1	676.68393	257.07730	2.63	0.0464

Output Statistics

Obs	Dependent Variable	Predicted Value	Std Error Mean Predict	Residual	Std Error Residual	Student Residual	-2-1 0 1 2	Cook's D
1	586013	641881	225621	-55868	343405	-0.163	| | |	0.004
2	792204	1245136	239446	-452932	333912	-1.356	| **| |	0.315
3	642078	420605	254609	221473	322500	0.687	| |* |	0.098
4	1302523	1004913	286501	297610	294532	1.010	| |** |	0.322
5	2180683	1756032	245127	424651	329764	1.288	| |** |	0.305
6	610758	1164784	146471	-554026	383898	-1.443	| **| |	0.101
7	1961044	1945677	347220	15367	219704	0.0699	| | |	0.004
8	849138	745413	221911	103725	345814	0.300	| | |	0.012

Sum of Residuals	0
Sum of Squared Residuals	8.441584E11
Predicted Residual SS (PRESS)	1.803324E12

modeli s tri varijable

The REG Procedure
Model: MODEL1
Dependent Variable: var17

Number of Observations Read	8
Number of Observations Used	8

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	3	2.52351E12	8.411701E11	11.38	0.0199
Error	4	2.95745E11	73936261289		
Corrected Total	7	2.819255E12			

Root MSE	271912	R-Square	0.8951
Dependent Mean	1115555	Adj R-Sq	0.8164
Coeff Var	24.37461		

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
Intercept	1	672820	201895	3.33	0.0290
var1	1	-1825.07167	1312.42209	-1.39	0.2367
var7	1	1004.08091	191.71032	5.24	0.0064
var15	1	-384.30237	142.59808	-2.70	0.0544

Output Statistics

Obs	Dependent Variable	Predicted Value	Std Error Mean Predict	Residual	Std Error Residual	Student Residual	-2-1 0 1 2	Cook's D
1	586013	918176	138396	-332163	234057	-1.419	| **| |	0.176
2	792204	849952	243060	-57748	121893	-0.474	| | |	0.223
3	642078	539020	158858	103058	220682	0.467	| | |	0.028
4	1302523	1003886	133846	298637	236689	1.262	| |** |	0.127
5	2180683	1982855	188621	197828	195853	1.010	| |** |	0.237
6	610758	542824	264789	67934	61830	1.099	| |** |	5.535
7	1961044	2101546	211454	-140502	170948	-0.822	| *| |	0.258
8	849138	986183	154786	-137045	223556	-0.613	| *| |	0.045

Sum of Residuals	0
Sum of Squared Residuals	2.95745E11
Predicted Residual SS (PRESS)	2.502444E12