



SVEUČILIŠTE U ZAGREBU

GRAFIČKI FAKULTET

Davor Donevski

**OPTIMIZACIJA MODELA IZLAZNIH UREĐAJA
U GRAFIČKOJ REPRODUKCIJI**

DOKTORSKI RAD

Zagreb, 2010



UNIVERSITY OF ZAGREB
FACULTY OF GRAPHIC ARTS

Davor Donevski

**OPTIMIZING OUTPUT DEVICE MODELS
IN GRAPHIC REPRODUCTION**

DOCTORAL THESIS

Zagreb, 2010



SVEUČILIŠTE U ZAGREBU

GRAFIČKI FAKULTET

DAVOR DONEVSKI

**OPTIMIZACIJA MODELA IZLAZNIH UREĐAJA
U GRAFIČKOJ REPRODUKCIJI**

DOKTORSKI RAD

Mentor:

prof. dr. sc. Diana Milčić

Zagreb, 2010

Zahvaljujem mentorici prof. dr. sc. Diani Milčić na svesrdnoj pomoći tijekom izrade ovoga rada. Zahvaljujem i članovima Povjerenstva Lidiji Mandić i Mislavu Grgiću na sugestijama, savjetima i pomoći u izradi rada.

Autor

UDK:	655.3:681.62:658.562
Znanstveno područje:	Tehničke znanosti
Znanstveno polje:	Grafička tehnologija
Institucija u kojoj je izrađen rad	Grafički fakultet Sveučilišta u Zagrebu
Naslov rada:	Optimizacija modela izlaznih uređaja u grafičkoj reprodukciji
Ključne riječi:	model uređaja, članovi modela, optimizacija modela
Voditelj rada:	prof. dr. sc. Diana Milčić
Broj stranica:	124
Broj slika:	137
Broj tablica:	80
Broj literturnih referenci:	69
Jezik teksta:	Hrvatski
Jezik sažetka:	Hrvatski i Engleski

Povjerenstvo za ocjenu doktorske disertacije:

1. doc. dr. sc. Lidija Mandić, Sveučilište u Zagrebu, Grafički fakultet, predsjednica
2. prof. dr. sc. Diana Milčić, Sveučilište u Zagrebu, Grafički fakultet, mentorica
3. prof. dr. sc. Mislav Grgić, Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva, vanjski član

Povjerenstvo za obranu doktorske disertacije:

1. doc. dr. sc. Lidija Mandić, Sveučilište u Zagrebu, Grafički fakultet, predsjednica
2. prof. dr. sc. Diana Milčić, Sveučilište u Zagrebu, Grafički fakultet, mentorica
3. prof. dr. sc. Mislav Grgić, Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva, vanjski član

Datum obrane doktorske disertacije: 22. prosinca 2010.g.

Mjesto obrane doktorske disertacije: Sveučilište u Zagrebu, Grafički fakultet

Povjerenstvo za obranu doktorske disertacije donijelo je sljedeću odluku:

„Obranio – jednoglasnom odlukom Povjerenstva“

Zagreb, 22. prosinca 2010.

Sažetak

Prijelazom postupaka grafičke reprodukcije s konvencionalnih na digitalne, koji je započeo u drugoj polovici 80-ih godina 20.st., otvorio se prostor razvoju različitih tehnologija. Tada su različiti proizvođači softvera i opreme razvijali vlastite sustave upravljanja bojama. Kako su ti sustavi bili ograničeni na platforme i softverske pakete za koje su bili razvijeni, proizvođači su 1993.g. osnovali Međunarodni konzorcij za boje (ICC – International Color Consortium), s ciljem razvoja univerzalnog sustava upravljanja bojama, neovisnog o platformi, operacijskom sustavu i softverskim paketima. Glavna namjera je bila, a i danas je, razvoj standarda zapisa profila uređaja te registracija potpisa i opisa podatkovnih struktura profila. Profili uređaja opisuju njihova svojstva reprodukcije boja, definirajući vezu između izvornog ili odredišnog prostora boja i poveznog prostora boja. Tijekom 2003.g. ICC i Tehnički odbor za grafičku tehnologiju, TC130 pri Međunarodnoj organizaciji za standarde, sklopili su ugovor kojim su se obavezali na suradnju u razvoju ISO standarda na osnovama dotadašnjeg rada ICC-a. ICC profil je računalna datoteka, čiji je zapis i podatkovne strukture standardizirao ICC. Uz to, ICC u svojim publikacijama daje načelne smjernice za korištenje podatkovnih struktura profila prilikom karakterizacije uređaja. No, to je sve što je kod tih datoteka standardizirano. Kako se pri izradi profila uređaja na osnovi mjerjenja izrađuje matematički model uređaja, izbor matematičke funkcije, kao i njezine raspodjele po podatkovnim strukturama profila, ostavljaju se razvojnim inženjerima softvera. Pri tome se koriste modeli za koje je dosadašnjim istraživanjima dokazano da dobro opisuju određeni tip uređaja. No, oni se u pojedinačnim slučajevima mogu pokazati nepreciznima. Razvijeni su različiti modeli za opis uređaja, a često se u tu svrhu koriste regresijski modeli. Polinom proizvoljnog, unaprijed zadanog reda i broja članova prilagođava se podacima u smislu najmanjih kvadratnih odstupanja. Izbor optimalnoga reda i članova za neki određeni uređaj nije očigledan. Cilj ovoga istraživanja bilo je određivanje signifikantnih članova modela za različite uređaje i pronalaženje veze između signifikantnosti pojedinih članova i karakteristika podataka o uređaju. U prvome dijelu istraživanja jednome modelu koji je odabran kao osnovni dodavani su proizvoljno odabrani članovi. Evaluacijom preciznosti na tri domene i jednom procesu utvrđeno je kako neki članovi mogu povećati, a neki smanjiti sposobnost prilagodbe i moći predviđanja modela, a učinak može biti različit na različitim domenama. U drugome dijelu istraživanja provedena su dva postupka eliminacije, eliminacija skupina članova i eliminacija članova na maksimalnim modelima za osam procesa i utvrđena je signifikantnost pojedinih članova u različitim procesima. Iako su se reducirani modeli pokazali preciznijima, zbog velikih međuovisnosti članova modela nije utvrđeno postojanje uzorka u izboru članova za pojedine procese pa ovim pristupom nije utvrđena veza između signifikantnosti članova i karakteristika podataka o uređaju.

Ključne riječi: model uređaja, članovi modela, optimizacija modela

Summary

The transition from analogue to digital graphic reproduction process at the second half of the 1980s gave way to the development of different technologies. At the time, different software and equipment vendors developed proprietary color management solutions. As those solutions weren't interoperable, in the year 1993 vendors founded the ICC - International Color Consortium with the aim of developing a universal color management system, independent on the platform, operating system and software packages. The main goal was the development of a standard device profile file format and the registration of data structure signatures and descriptions. Device profiles describe the device reproduction characteristics by defining the relationship between the source or destination color spaces and the connection space. During the year 2003, the International Color Consortium and the Technical committee 130 of the International Organization for Standardization entered into a cooperative agreement with the aim of developing an ISO standard based on the previous work of the ICC. ICC profile is a computer file. Its file format and data structures were developed and standardized by the ICC. In its publications, the ICC provides general guidelines on the use of the profile data structures for device characterization. However, only that segment is covered by the standard. As the device characterization process involves the development of a device model based on the data collected by measurements, the choice of a mathematical function and its mapping to the profile data structures are left to software developers. It is common to use models which are suitable for certain device types, as shown by previous research. However, in some cases they may be insufficiently accurate. There are different types of device models, and one commonly used type are the regression models. A polynomial of arbitrarily chosen order and number of terms is fitted to the data in terms of least squares. The choice of the optimum order and terms for a particular device is not known. The aim of this research was the determination of statistically significant model terms for different devices and defining a relationship between the statistical significance of model terms and device data characteristics. In the first part of the research, arbitrarily chosen terms were added to a model chosen as the base model. Model performance evaluations on three different domains of one process showed that some terms may improve and some may reduce the model accuracy, and the effect may differ on different domains. In the second part of the research, two elimination processes, the elimination of terms and the elimination of blocks of terms were conducted on the maximum models of eight different processes. Statistical significances of terms were determined for eight different processes. Although the reduced models performed significantly better, the pattern in significant terms for different processes was not found due to the suppressor effect. Therefore the relationship between the terms significances and device data characteristics could not be determined using this approach.

Keywords: device model, model terms, model optimization

Sadržaj

1.	Uvod	1
2.	Sustavi za upravljanje bojama.....	4
2.1.	Kalibracija i karakterizacija uređaja	4
2.2.	Karakterizacijske karte	4
2.3.	ICC profili.....	5
2.3.1.	Struktura profila.....	6
2.3.2.	Struktura izlaznih profila	7
2.3.3.	Transformacijski model.....	8
2.4.	Interpolacija	9
3.	Modeli izlaznih uređaja.....	12
3.1.	Fizikalni modeli.....	12
3.2.	Numerički modeli.....	15
3.3.	Neuronske mreže	16
3.4.	Tabele s interpolacijom.....	16
4.	Regresijske metode	17
4.1.	Modeliranje izlaznih uređaja.....	19
4.2.	Domene.....	21
4.3.	Inverzni modeli.....	22
4.4.	Pretjerana prilagodba modela	23
4.5.	Modifikacije metode najmanjih kvadratnih odstupanja	25
5.	Metode eksperimenata	26
5.1.	Materijali i uređaji korišteni u istraživanju	26
5.2.	Ispitivanja modela uređaja.....	26
5.3.	Postupci evaluacije modela.....	27
6.	Eksperiment: Evaluacija osnovnih modela uređaja	28
6.1.	Domena kolorimetrijskih gustoća i L*a*b* domena	28
6.2.	Domena skaliranih L*a*b* vrijednosti.....	37
7.	Eksperiment: Modeli s dodatnim međuproductima	44
7.1.	Domena kolorimetrijskih gustoća i L*a*b* domena	44
7.2.	Domena skaliranih L*a*b* vrijednosti.....	55

8.	Eksperiment: Optimizacija modela eliminacijom članova	65
9.	Zaključak	117
10.	Literatura.....	119
	PRILOG A	1
	PRILOG B	17

Popis tablica

Tabela 2.1, Podjela tablice boja na 33 točke	8
Tabela 4.1, Skup točaka	17
Tabela 6.1, Odstupanja modela 11-3 od empirijskih podataka	28
Tabela 6.2, Odstupanja modela 14-3 od empirijskih podataka	29
Tabela 6.3, Odstupanja modela 17-3 od empirijskih podataka	30
Tabela 6.4, Odstupanja modela 20-3 od empirijskih podataka	31
Tabela 6.5, Odstupanja modela 23-4 od empirijskih podataka	32
Tabela 6.6, Odstupanja modela 11-3 od empirijskih podataka	33
Tabela 6.7, Odstupanja modela 14-3 od empirijskih podataka	33
Tabela 6.8, Odstupanja modela 17-3 od empirijskih podataka	34
Tabela 6.9, Odstupanja modela 20-3 od empirijskih podataka	34
Tabela 6.10, Odstupanja modela 23-4 od empirijskih podataka	35
Tabela 6.11, Odstupanja modela 11-3 od empirijskih podataka	37
Tabela 6.12, Odstupanja modela 14-3 od empirijskih podataka	37
Tabela 6.13, Odstupanja modela 17-3 od empirijskih podataka	38
Tabela 6.14, Odstupanja modela 20-3 od empirijskih podataka	38
Tabela 6.15, Odstupanja modela 23-4 od empirijskih podataka	39
Tabela 6.16, Odstupanja modela 11-3 od empirijskih podataka	40
Tabela 6.17, Odstupanja modela 14-3 od empirijskih podataka	40
Tabela 6.18, Odstupanja modela 17-3 od empirijskih podataka	41
Tabela 6.19, Odstupanja modela 20-3 od empirijskih podataka	41
Tabela 6.20, Odstupanja modela 23-4 od empirijskih podataka	42
Tabela 7.1, Odstupanja modela 24-6 od empirijskih podataka	45
Tabela 7.2, Odstupanja modela 24x3 od empirijskih podataka	45
Tabela 7.3, Odstupanja modela 25-9 od empirijskih podataka	46
Tabela 7.4, Odstupanja modela 26-5 od empirijskih podataka	47
Tabela 7.5, Odstupanja modela 26-7 od empirijskih podataka	47
Tabela 7.6, Odstupanja modela 29-4 od empirijskih podataka	48
Tabela 7.7, Odstupanja modela 29-5 od empirijskih podataka	48
Tabela 7.8, Odstupanja modela 29-6 od empirijskih podataka	49
Tabela 7.9, Odstupanja modela 24-6 od empirijskih podataka	50
Tabela 7.10, Odstupanja modela 24-9 od empirijskih podataka	50
Tabela 7.11, Odstupanja modela 25-9 od empirijskih podataka	51
Tabela 7.12, Odstupanja modela 26-5 od empirijskih podataka	51
Tabela 7.13, Odstupanja modela 26-7 od empirijskih podataka	52
Tabela 7.14, Odstupanja modela 29-4 od empirijskih podataka	52
Tabela 7.15, Odstupanja modela 29-5 od empirijskih podataka	53
Tabela 7.16, Odstupanja modela 29-6 od empirijskih podataka	53
Tabela 7.17, Odstupanja modela 24-6 od empirijskih podataka	55
Tabela 7.18, Odstupanja modela 24-9 od empirijskih podataka	55

Tabela 7.19, Odstupanja modela 25-9 od empirijskih podataka	56
Tabela 7.20, Odstupanja modela 26-5 od empirijskih podataka	57
Tabela 7.21, Odstupanja modela 26-7 od empirijskih podataka	57
Tabela 7.22, Odstupanja modela 29-4 od empirijskih podataka	58
Tabela 7.23, Odstupanja modela 29-5 od empirijskih podataka	58
Tabela 7.24, Odstupanja modela 29-6 od empirijskih podataka	59
Tabela 7.25, Usporedba modela s dodatni međuproductima u odnosu na model 23-4 na skupu A	59
Tabela 7.26, Odstupanja modela 24-6 od empirijskih podataka	60
Tabela 7.27, Odstupanja modela 24-9 od empirijskih podataka	60
Tabela 7.28, Odstupanja modela 25-9 od empirijskih podataka	61
Tabela 7.29, Odstupanja modela 26-5 od empirijskih podataka	62
Tabela 7.30, Odstupanja modela 26-7 od empirijskih podataka	62
Tabela 7.31, Odstupanja modela 29-4 od empirijskih podataka	63
Tabela 7.32, Odstupanja modela 29-5 od empirijskih podataka	63
Tabela 7.33, Odstupanja modela 29-6 od empirijskih podataka	64
Tabela 8.1, Ispitivane tehnologije i materijali	65
Tabela 8.2, Proces A	65
Tabela 8.3, Proces B	66
Tabela 8.4, Proces C	66
Tabela 8.5, Proces D	66
Tabela 8.6, Proces E	67
Tabela 8.7, Proces F	67
Tabela 8.8, Proces G	67
Tabela 8.9, Proces H	68
Tabela 8.10, Eliminirane skupine članova u procesu A	85
Tabela 8.11, Eliminirane skupine članova u procesu B	86
Tabela 8.12, Eliminirane skupine članova u procesu C	87
Tabela 8.13, Eliminirane skupine članova u procesu D	88
Tabela 8.14, Eliminirane skupine članova u procesu E	89
Tabela 8.15, Eliminirane skupine članova u procesu F	90
Tabela 8.16, Eliminirane skupine članova u procesu G	91
Tabela 8.17, Eliminirane skupine članova u procesu H	92
Tabela 8.18, Eliminirani članovi u procesu A	109
Tabela 8.19, Eliminirani članovi u procesu B	110
Tabela 8.20, Eliminirani članovi u procesu C	111
Tabela 8.21, Eliminirani članovi u procesu D	112
Tabela 8.22, Eliminirani članovi u procesu E	113
Tabela 8.23, Eliminirani članovi u procesu F	114
Tabela 8.24, Eliminirani članovi u procesu G	115
Tabela 8.25, Eliminirani članovi u procesu H	116

Popis slika

Slika 2.3.1, Struktura ICC profila	6
Slika 2.3.2, Transformacijski model prema Specifikaciji ICC.1:2004-10.....	8
Slika 2.4.1, Linearna interpolacija	10
Slika 2.4.2, Trilinearna interpolacija.....	10
Slika 4.1, Prilagodba pravca skupu točaka	17
Slika 4.4.1, Prilagodba modela neskaliranim podacima	23
Slika 4.4.2, Prilagodba modela skaliranim podacima.....	23
Slika 6.1.1, Histogram odstupanja za model 11-3 RGB->Lab	28
Slika 6.1.2, Histogram odstupanja za model 11-3 Lab->RGB	28
Slika 6.1.3, Histogram odstupanja za model 11-3 RGB->D	28
Slika 6.1.4, Histogram odstupanja za model 14-3 RGB->Lab	29
Slika 6.1.5, Histogram odstupanja za model 14-3 Lab->RGB	29
Slika 6.1.6, Histogram odstupanja za model 14-3 RGB->D	29
Slika 6.1.7, Histogram odstupanja za model 17-3 RGB->Lab	30
Slika 6.1.8, Histogram odstupanja za model 17-3 Lab->RGB	30
Slika 6.1.9, Histogram odstupanja za model 17-3 RGB->D	30
Slika 6.1.10, Histogram odstupanja za model 20-3 RGB->Lab	31
Slika 6.1.11, Histogram odstupanja za model 20-3 Lab->RGB	31
Slika 6.1.12, Histogram odstupanja za model 20-3 RGB->D	31
Slika 6.1.13, Histogram odstupanja za model 20-4 RGB->Lab	32
Slika 6.1.14, Histogram odstupanja za model 20-4 Lab->RGB	32
Slika 6.1.15, Histogram odstupanja za model 20-4 RGB->D	32
Slika 6.1.16, Histogram odstupanja za model 11-3 RGB->Lab	33
Slika 6.1.17, Histogram odstupanja za model 11-3 RGB->D	33
Slika 6.1.18, Histogram odstupanja za model 14-3 RGB->Lab	33
Slika 6.1.19, Histogram odstupanja za model 14-3 RGB->D	33
Slika 6.1.20, Histogram odstupanja za model 17-3 RGB->Lab	34
Slika 6.1.21, Histogram odstupanja za model 17-3 RGB->D	34
Slika 6.1.22, Histogram odstupanja za model 20-3 RGB->Lab	34
Slika 6.1.23, Histogram odstupanja za model 20-3 RGB->D	34
Slika 6.1.24, Histogram odstupanja za model 23-4 RGB->Lab	35
Slika 6.1.25, Histogram odstupanja za model 11-3 RGB->D	35
Slika 6.2.1, Histogram odstupanja za model 11-3 RGB->Lab	37
Slika 6.2.2, Histogram odstupanja za model 14-3RGB->Lab	37
Slika 6.2.3, Histogram odstupanja za model 17-3 RGB->Lab	38
Slika 6.2.4, Histogram odstupanja za model 20-3 RGB->Lab	38
Slika 6.2.5, Histogram odstupanja za model 23-4 RGB->Lab	39
Slika 6.2.6, Histogram odstupanja za model 11-3 RGB->Lab	40
Slika 6.2.7, Histogram odstupanja za model 14-3 RGB->Lab	40
Slika 6.2.8, Histogram odstupanja za model 20-3 RGB->Lab	41

Slika 6.2.9, Histogram odstupanja za model 20-3 RGB->Lab	41
Slika 6.2.10, Histogram odstupanja za model 23-4 RGB->Lab	42
Slika 7.1.1, Histogram odstupanja za model 24-6 RGB->D	45
Slika 7.1.2, Histogram odstupanja za model 24-6 RGB->Lab	45
Slika 7.1.3, Histogram odstupanja za model 24-9 RGB->D	45
Slika 7.1.4, Histogram odstupanja za model 24-9 RGB->Lab	45
Slika 7.1.5, Histogram odstupanja za model 25-9 RGB->D	46
Slika 7.1.6, Histogram odstupanja za model 25-9 RGB->Lab	46
Slika 7.1.7, Histogram odstupanja za model 26-5 RGB->D	47
Slika 7.1.8, Histogram odstupanja za model 26-5 RGB->Lab	47
Slika 7.1.9, Histogram odstupanja za model 26-7 RGB->D	47
Slika 7.1.10, Histogram odstupanja za model 26-7 RGB->Lab	47
Slika 7.1.11, Histogram odstupanja za model 29-4 RGB->D	48
Slika 7.1.12, Histogram odstupanja za model 29-4 RGB->Lab	48
Slika 7.1.13, Histogram odstupanja za model 29-5 RGB->D	48
Slika 7.1.14, Histogram odstupanja za model 29-5 RGB->Lab	48
Slika 7.1.15, Histogram odstupanja za model 29-6 RGB->D	49
Slika 7.1.16, Histogram odstupanja za model 29-6 RGB->Lab	49
Slika 7.1.17, Histogram odstupanja za model 24-6 RGB->Lab	50
Slika 7.1.18, Histogram odstupanja za model 24-6 RGB->D	50
Slika 7.1.19, Histogram odstupanja za model 24-9 RGB->Lab	50
Slika 7.1.20, Histogram odstupanja za model 24-9 RGB->D	50
Slika 7.1.21, Histogram odstupanja za model 25-9 RGB->Lab	51
Slika 7.1.22, Histogram odstupanja za model 25-9 RGB->D	51
Slika 7.1.23, Histogram odstupanja za model 26-5 RGB->Lab	51
Slika 7.1.24, Histogram odstupanja za model 26-5 RGB->D	51
Slika 7.1.25, Histogram odstupanja za model 26-7 RGB->Lab	52
Slika 7.1.26, Histogram odstupanja za model 26-7 RGB->D	52
Slika 7.1.27, Histogram odstupanja za model 29-4 RGB->Lab	52
Slika 7.1.28, Histogram odstupanja za model 29-4 RGB->D	52
Slika 7.1.29, Histogram odstupanja za model 29-5 RGB->Lab	53
Slika 7.1.30, Histogram odstupanja za model 29-5 RGB->D	53
Slika 7.1.31, Histogram odstupanja za model 29-6 RGB->Lab	53
Slika 7.1.32, Histogram odstupanja za model 29-6 RGB->D	53
Slika 7.2.1, Histogram odstupanja za model 24-6 RGB->Lab	55
Slika 7.2.2, Histogram odstupanja za model 24-9 RGB->Lab	55
Slika 7.2.3, Histogram odstupanja za model 25-9 RGB->Lab	56
Slika 7.2.4, Histogram odstupanja za model 26-5 RGB->Lab	57
Slika 7.2.5, Histogram odstupanja za model 26-7 RGB->Lab	57
Slika 7.2.6, Histogram odstupanja za model 29-4 RGB->Lab	58
Slika 7.2.7, Histogram odstupanja za model 29-5 RGB->Lab	58
Slika 7.2.8, Histogram odstupanja za model 29-6 RGB->Lab	59

Slika 7.2.9, Histogram odstupanja za model 24-6 RGB->Lab	60
Slika 7.2.10, Histogram odstupanja za model 24-9 RGB->Lab	60
Slika 7.2.11, Histogram odstupanja za model 25-9 RGB->Lab	61
Slika 7.2.12, Histogram odstupanja za model 26-5 RGB->Lab	62
Slika 7.2.13, Histogram odstupanja za model 26-7 RGB->Lab	62
Slika 7.2.14, Histogram odstupanja za model 29-4 RGB->Lab	63
Slika 7.2.15, Histogram odstupanja za model 29-5 RGB->Lab	63
Slika 7.2.16, Histogram odstupanja za model 29-6 RGB->Lab	64
Slika 8.1, F vrijednosti za tri najsizifikantnije skupine članova s početka postupka eliminacije za proces A	69
Slika 8.2, F vrijednosti za tri najsizifikantnije skupine članova s kraja postupka eliminacije za proces A	69
Slika 8.3, F vrijednosti za tri najsizifikantnije skupine članova s početka postupka eliminacije za proces B	70
Slika 8.4, F vrijednosti za tri najsizifikantnije skupine članova s kraja postupka eliminacije za proces B	70
Slika 8.5, F vrijednosti za tri najsizifikantnije skupine članova s početka postupka eliminacije za proces C	71
Slika 8.6, F vrijednosti za tri najsizifikantnije skupine članova s kraja postupka eliminacije za proces C	71
Slika 8.7, F vrijednosti za tri najsizifikantnije skupine članova s početka postupka eliminacije za proces D	72
Slika 8.8, F vrijednosti za tri najsizifikantnije skupine članova s kraja postupka eliminacije za proces D	72
Slika 8.9, F vrijednosti za tri najsizifikantnije skupine članova s početka postupka eliminacije za proces E	73
Slika 8.10, F vrijednosti za tri najsizifikantnije skupine članova s kraja postupka eliminacije za proces E	73
Slika 8.11, F vrijednosti za tri najsizifikantnije skupine članova s početka postupka eliminacije za proces F	74
Slika 8.12, F vrijednosti za tri najsizifikantnije skupine članova s kraja postupka eliminacije za proces F	74
Slika 8.13, F vrijednosti za tri najsizifikantnije skupine članova s početka postupka eliminacije za proces G	75
Slika 8.14, F vrijednosti za tri najsizifikantnije skupine članova s kraja postupka eliminacije za proces G	75
Slika 8.15, F vrijednosti za tri najsizifikantnije skupine članova s početka postupka eliminacije za proces H	76
Slika 8.16, F vrijednosti za tri najsizifikantnije skupine članova s početka postupka eliminacije za proces H	76
Slika 8.17, relativne F vrijednosti za tri najsizifikantnije skupine članova s početka postupka eliminacije za proces A	77
Slika 8.18, relativne F vrijednosti za tri najsizifikantnije skupine članova s kraja postupka eliminacije za proces A	77
Slika 8.19, relativne F vrijednosti za tri najsizifikantnije skupine članova s početka postupka eliminacije za proces B	78

Slika 8.20, relativne F vrijednosti za tri najsizifikantnije skupine članova s kraja postupka eliminacije za proces B.....	78
Slika 8.21, relativne F vrijednosti za tri najsizifikantnije skupine članova s početka postupka eliminacije za proces C	79
Slika 8.22, relativne F vrijednosti za tri najsizifikantnije skupine članova s kraja postupka eliminacije za proces C.....	79
Slika 8.23, relativne F vrijednosti za tri najsizifikantnije skupine članova s početka postupka eliminacije za proces D	80
Slika 8.24, relativne F vrijednosti za tri najsizifikantnije skupine članova s kraja postupka eliminacije za proces D	80
Slika 8.25, relativne F vrijednosti za tri najsizifikantnije skupine članova s početka postupka eliminacije za proces E	81
Slika 8.26, relativne F vrijednosti za tri najsizifikantnije skupine članova s kraja postupka eliminacije za proces E	81
Slika 8.27, relativne F vrijednosti za tri najsizifikantnije skupine članova s početka postupka eliminacije za proces F	82
Slika 8.28, relativne F vrijednosti za tri najsizifikantnije skupine članova s kraja postupka eliminacije za proces F	82
Slika 8.29, relativne F vrijednosti za tri najsizifikantnije skupine članova s početka postupka eliminacije za proces G	83
Slika 8.30, relativne F vrijednosti za tri najsizifikantnije skupine članova s kraja postupka eliminacije za proces G	83
Slika 8.31, relativne F vrijednosti za tri najsizifikantnije skupine članova s početka postupka eliminacije za proces H	84
Slika 8.32, relativne F vrijednosti za tri najsizifikantnije skupine članova s kraja postupka eliminacije za proces H	84
Slika 8.33, F vrijednosti za tri najsizifikantnija člana s početka postupka eliminacije za proces A.....	93
Slika 8.34, F vrijednosti za tri najsizifikantnija člana s kraja postupka eliminacije za proces A.....	93
Slika 8.35, F vrijednosti za tri najsizifikantnija člana s početka postupka eliminacije za proces B	94
Slika 8.36, F vrijednosti za tri najsizifikantnija člana s kraja postupka eliminacije za proces B	94
Slika 8.37, F vrijednosti za tri najsizifikantnija člana s početka postupka eliminacije za proces C	95
Slika 8.38, F vrijednosti za tri najsizifikantnija člana s kraja postupka eliminacije za proces C	95
Slika 8.39, F vrijednosti za tri najsizifikantnija člana s početka postupka eliminacije za proces D.....	96
Slika 8.40, F vrijednosti za tri najsizifikantnija člana s kraja postupka eliminacije za proces D.....	96
Slika 8.41, F vrijednosti za tri najsizifikantnija člana s početka postupka eliminacije za proces E	97
Slika 8.42, F vrijednosti za tri najsizifikantnija člana s kraja postupka eliminacije za proces E	97
Slika 8.43, F vrijednosti za tri najsizifikantnija člana s početka postupka eliminacije za proces F	98
Slika 8.44, F vrijednosti za tri najsizifikantnija člana s kraja postupka eliminacije za proces F	98
Slika 8.45, F vrijednosti za tri najsizifikantnija člana s početka postupka eliminacije za proces G.....	99
Slika 8.46, F vrijednosti za tri najsizifikantnija člana s kraja postupka eliminacije za proces G.....	99
Slika 8.47, F vrijednosti za tri najsizifikantnija člana s početka postupka eliminacije za proces H.....	100
Slika 8.48, F vrijednosti za tri najsizifikantnija člana s kraja postupka eliminacije za proces H.....	100

Slika 8.49, relativne F vrijednosti za tri najsifikantnija člana s početka postupka eliminacije za proces A	101
Slika 8.50, relativne F vrijednosti za tri najsifikantnija člana s kraja postupka eliminacije za proces A	101
Slika 8.51, relativne F vrijednosti za tri najsifikantnija člana s početka postupka eliminacije za proces B	102
Slika 8.52, relativne F vrijednosti za tri najsifikantnija člana s kraja postupka eliminacije za proces B	102
Slika 8.53, relativne F vrijednosti za tri najsifikantnija člana s početka postupka eliminacije za proces C	103
Slika 8.54, relativne F vrijednosti za tri najsifikantnija člana s kraja postupka eliminacije za proces C	103
Slika 8.55, relativne F vrijednosti za tri najsifikantnija člana s početka postupka eliminacije za proces D	104
Slika 8.56, relativne F vrijednosti za tri najsifikantnija člana s kraja postupka eliminacije za proces D	104
Slika 8.57, relativne F vrijednosti za tri najsifikantnija člana s početka postupka eliminacije za proces E	105
Slika 8.58, relativne F vrijednosti za tri najsifikantnija člana s kraja postupka eliminacije za proces E	105
Slika 8.59, relativne F vrijednosti za tri najsifikantnija člana s početka postupka eliminacije za proces F	106
Slika 8.60, relativne F vrijednosti za tri najsifikantnija člana s kraja postupka eliminacije za proces F	106
Slika 8.61, relativne F vrijednosti za tri najsifikantnija člana s početka postupka eliminacije za proces G	107
Slika 8.62, relativne F vrijednosti za tri najsifikantnija člana s kraja postupka eliminacije za proces G	107
Slika 8.63, relativne F vrijednosti za tri najsifikantnija člana s početka postupka eliminacije za proces H	108
Slika 8.64, relativne F vrijednosti za tri najsifikantnija člana s kraja postupka eliminacije za proces H	108

1. Uvod

Sustavi za upravljanje bojama u današnje su vrijeme nezaobilazan dio procesa grafičke reprodukcije. Kvaliteta reprodukcije ovisi o vjernoj reprodukciji boja pa današnji međunarodni standardi propisuju ciljanje vrijednosti i tolerancije boja izmijerenih na kontrolnim elementima u procesu proizvodnje. U vremenu prijelaza postupaka grafičke reprodukcije s analognih na digitalne proizvođači softvera i opreme razvijali su vlastita rješenja za upravljanje bojama. Kako te različite sustave nije bilo moguće međusobno povezati, 1993. g. vodeći proizvođači osnovali su konzorcij ICC (International Color Consortium) s ciljem razvoja univerzalnog sustava upravljanja bojama. Konzorcij je razvio format podatkovnog zapisa za opis reprodukcijskih karakteristika uređaja i objavio ga kao ICC Specifikaciju. Specifikacija je sadržavala transformacijske modele (modele za transformaciju boje iz prostora boja uređaja u prostor boja neovisan o uređaju i obratno) i opis strukture datotečnog zapisa i podatkovnih struktura. Razvojem tehnologije i znanosti objavljivane su novije verzije Specifikacije koje su uključivale podršku za nove podatkovne strukture i transformacijske modele. Godine 2003. ICC je započeo suradnju s tehničkim odborom 130 pri Međunarodnoj organizaciji za standardizaciju (ISO). Cilj suradnje je nastavak razvoja formata datotečnog zapisa profila uređaja i objava novih verzija Specifikacije. Od tada se Specifikacija objavljuje i kao standard ISO 15076 jednakog tehničkog sadržaja. Treba naglasiti da su transformacijski modeli propisani ICC Specifikacijom različit pojam od modela uređaja. Transformacijski model se sastoji od nekoliko dijelova postavljenih na način da se poboljša preciznost predviđanja izlaznih vrijednosti ovisno o ulaznim vrijednostima. Model uređaja opisuje njegove reprodukcijske karakteristike, to jest vezu ulaza i izlaza i on se koristi za popunjavanje podatkovnih struktura profila uređaja. Modeli uređaja se općenito dijele na fizikalne i numeričke. Fizikalni modeli uzimaju u obzir fizikalne veličine koje utječu na transformaciju boja. Numerički modeli samo daju vezu između vrijednosti iz prostora boja uređaja i prostora boja neovisnih o uređaju. U numeričke modele spadaju i regresijski modeli koji su predmet ovoga istraživanja. Regresijom, odnosno metodom najmanjih kvadratnih odstupanja, podacima o uređaju se prilagođava unaprijed zadana funkcija, to jest određuju se parametri te funkcije. Funkcije koje se koriste u svrhu karakterizacije uređaja su polinomi. Kako je funkcija unaprijed zadana, ovisno o izboru članova i redu polinoma njezina se sposobnost prilagodbe i moć predviđanja za promatrani uređaj razlikuje. Optimalan izbor članova i reda modela nije unaprijed poznat. Različite komparativne studije evaluirale su sposobnost prilagodbe i moć predviđanja modela različitih redova s različitim članovima, obično na jednom uređaju. Ukazale su na problem određivanja maksimalnog dozvoljenog reda modela, to jest problem pretjerane prilagodbe modela podacima, te na vezu između preciznosti modela i broja članova modela. Zaključak tih istraživanja bio je taj da je model uređaja precizniji što je broj članova modela veći, uz uvjet da nije premašen maksimalni dozvoljeni red modela za promatrani uređaj. No, prema rezultatima iznesenim u brojnim ranijim istraživanjima vidljivo je da preciznost modela uključivanjem članova u nekim slučajevima raste monotono, a u nekim slučajevima oscilira i raste samo u generalnom trendu. Isto tako, treba uzeti u obzir da su u tim istraživanjima dodavane cijele skupine članova određenog reda, a ne članovi pojedinačno. Stoga se otvara nekoliko pitanja koja su predmet ovoga istraživanja. Prvo pitanje je utječu li svi članovi modela na poboljšanje njegove preciznosti ili ju neki članovi umanjuju. S obzirom da članovi modela utječu na njegovu prilagodbu podacima, a poznato je da nisu svi kanali i interakcije među kanalima uređaja jednako složene, postavlja

se pitanje koje članove odabrat. Različiti članovi mogu bolje ili lošije opisati kanale i interakcije među kanalima uređaja. Osim toga, postavlja se pitanje maksimalnog dozvoljenog reda modela. Kako su složenosti kanala i njihovih interakcija različite, optimalan model bi trebao imati različite maksimalne redove članova za različite kanale i različite maksimalne redove interakcijskih članova za opis interakcija među kanalima. Kako su se dosadašnja istraživanja ograničavala na uključivanje svih članova do nekog određenog reda, postavlja se pitanje mogućnosti optimizacije modela uređaja izborom njegovih članova.

Cilj ovoga istraživanja je utvrditi kriterije u podacima o uređaju za odabir signifikantnih članova modela uređaja, to jest odabir modela koji optimalno opisuje promatrani uređaj. U tu je svrhu potrebno utvrditi koji su članovi modela statistički signifikantni u različitim procesima. Za utvrđivanje statističke signifikantnosti članova modela u ovome je istraživanju korištena metoda eliminacije članova maksimalnih modela odabranih za osam različitih procesa. Eliminacija je provedena na osnovi rezultata parcijalnog F testa.

Istraživanje je provedeno na tzv. inkjet pisačima, na pisaču koji koristi termalnu tehnologiju formiranja kapljice bojila, te na pisačima koji koriste piezo tehnologiju ispisa. Pri istraživanju su se koristila komercijalna bojila predviđena za uporabu na promatranim uređajima.

Sami materijali, odnosno njihova svojstva, nisu bili predmet ovoga istraživanja. S obzirom da oni utječu na reproduksijske karakteristike uređaja pa su se različiti materijali u sklopu istraživanja koristili isključivo u svrhu izmjena reproduksijskih karakteristika uređaja. Svrha tih izmjena bilo je ispitivanje prilagodljivosti modela različitim reproduksijskim karakteristikama.

U prvom poglavlju disertacije postavljeni su ciljevi i hipoteze istraživanja. Prvi cilj je određivanje statistički signifikantnih članova modela u različitim procesima. Drugi cilj je pronalaženje kriterija u podacima o uređaju za odabir optimalne transformacijske funkcije.

Ciljevi su utemeljeni na sljedećim hipotezama:

- tražena svojstva modela je moguće odrediti prema kriterijima u podacima o uređaju
- prema određenim karakteristikama u podacima o uređaju moguće je predvidjeti odgovarajuće članove modela
- odabrani članovi modela mogu povećati ili smanjiti preciznost modela.

U drugome poglavlju obrađeni su sustavi upravljanja bojama. Objasnjen je njihov razvoj, princip rada i iznesen je pregled dosadašnjih istraživanja u pogledu njihovih performansi i tehničkih ograničenja. Istaknute su kritične točke transformacijskih modela sustava upravljanja bojama u kojima dolazi do pogrešaka te su navedena najnovija rješenja koja te pogreške umanjuju.

U trećem poglavlju iznesen je pregled različitih pristupa i dosadašnjih istraživanja na temu modeliranja uređaja te su navedeni rezultati ranijih komparativnih studija različitih modela uređaja.

U četvrtom poglavlju posvećena je posebna pažnja regresijskim modelima uređaja s obzirom da su upravo ti modeli predmet istraživanja u ovoj disertaciji. Prikazana je teoretska osnova regresijskih modela, te je dat pregled dosadašnjih istraživanja. Iz iznesenoga je vidljivo da su dosadašnjim

istraživanjima obuhvaćene metode s različitim kriterijima i uvjetima prilagodbe, ali nije provedeno sveobuhvatno istraživanje po pitanju izbora članova modela pa je ono predmet istraživanja ovoga rada.

U petome poglavlju izneseni su eksperimentalni plan i metode istraživanja. Navedeni su materijali i uređaji koji su korišteni u istraživanju te metode prikupljanja i obrade podataka. Istraživanje je provedeno metodom eliminacije članova maksimalnog modela prema kriteriju rezultata parcijalnog F testa. Modeli su prilagođavani podacima osam različitih procesa i evaluirani na nezavisnom skupu podataka i psihofizički na transformiranim slikama.

U šestome poglavlju izneseni su rezultati evaluacije pet osnovnih modela uređaja na tri domene. Utvrđene su razlike u njihovim performansama prema rezultatima deskriptivne statistike i razdiobama odstupanja modela od empirijskih podataka.

U sedmome poglavlju izneseni su rezultati evaluacije nepotpunih modela formiranih dodavanjem međuprodukata na model četvrtoga reda s 23 člana odabran kao osnovni model uređaja. Utvrđene su razlike u utjecaju dodatnih članova na sposobnost prilagodbe i moć predviđanja modela na različitim domenama.

U osmome poglavlju proveden je postupak optimizacije modela uređaja eliminacijom članova modela. Utvrđene su statističke signifikantnosti pojedinih članova i skupina članova modela. Evaluacijom performansi modela na nezavisnom skupu podataka i psihofizičkom evaluacijom utvrđeno je da reducirani modeli postižu znatno bolje rezultate u odnosu na maksimalne.

U devetom poglavlju dat je zaključak utvrđen na osnovu provedenih istraživanja, te je iznijet znanstveni doprinos provedenog istraživanja. Doprinos se sastoji u utvrđenim utjecajima članova na sposobnost prilagodbe i moć predviđanja modela te utvrđenoj primjenjivosti metode eliminacije članova u svrhu optimizacije regresijskih modela reproduktivskih uređaja.

2. Sustavi za upravljanje bojama

2.1. Kalibracija i karakterizacija uređaja

Svaki uređaj ima određene, sebi svojstvene reproduksijske karakteristike. Te karakteristike, osim o specifičnostima samoga uređaja, ovise i o njegovoj podešenosti. Postoje određeni uvjeti rada uređaja pod kojima on daje najbolje, to jest optimalne rezultate. Općenito govoreći, najboljim rezultatom smatramo postizanje maksimalnog raspona reprodukcije tonova, odnosno maksimalnog gamuta, uz zadržavanje kontinuiranih gradacija tonova, bez vidljivih prijelaza [1]. Dakle, kalibracija je postupak kojim se karakteristike uređaja mijenjaju kako bi se uređaj doveo u optimalno stanje i kako bi se osigurala ponovljivost rezultata. Karakterizacija, s druge strane, je postupak kojim se opisuju karakteristike uređaja. Ova se dva postupka najčešće izvode jedan za drugim. Uređaj se prvo kalibracijom dovodi u optimalno stanje, a zatim se opisuju njegove karakteristike. Za karakterizaciju uređaja koriste se karakterizacijske karte, a opis uređaja sadržan je u profilu koji se izrađuje na temelju vrijednosti izmjerena na karakterizacijskim kartama.

Jedna od karakteristika uređaja koja je ovisna o njegovoj podešenosti, to jest kalibraciji, je stabilnost uređaja. Pod stabilnošću se podrazumijeva da isti ulaz u uređaj uvijek izaziva isti odaziv uređaja. Ova se karakteristika ponekad u literaturi izdvaja kao posebno svojstvo koje može biti u suprotnosti sa zahtjevom za optimalnim ponašanjem u smislu postizanja maksimalnog raspona reprodukcije tonova. Kada je slučaj takav, cilj kalibracije je postići stabilnost nauštrb raspona reprodukcije.

Osim postizanja optimalnog stanja i stabilnosti uređaja, za čime se teži prije karakterizacije, kalibracija se može provoditi i nakon karakterizacije uređaja. Svi uređaji s vremenom mijenjaju svoje karakteristike pa profil uređaja s vremenom postaje sve neprecizniji. Stoga se uređaj povremenom kalibracijom vraća u stanje u kojem je opisan profilom.

2.2. Karakterizacijske karte

Karakterizacijske karte su sredstvo koje se koristi za karakterizaciju uređaja. Sastoje se od određenog broja obojanih polja čije su vrijednosti definirane u prostoru boja uređaja. Neovisno o veličini karte, to jest broju polja od kojih se sastoji, vrijednosti mogu biti ravnomjerno ili neravnomjerno raspoređene u prostoru boja uređaja. U slučaju ravnomjerne raspodjele u prostoru uređaja taj se skup vrijednosti naziva kockom (eng. training cube). Prema mnogim autorima, veću preciznost moguće je postići manjim brojem mjerjenja ako su razlike između odabranih vrijednosti percepcijski uniformne pa su neka istraživanja obuhvatila izbor optimalnih vrijednosti karakterizacijske karte [2; 3; 4; 5; 6]. Prostori boja uređaja mogu biti RGB, CMYK ili neki drugi, ovisno o broju primara uređaja koji se ulaznim vrijednostima u uređaj pozivaju eksplicitno ili implicitno. Tako na primjer takozvani HI-FI tisk ima sedam nosioca obojenja koji se pozivaju eksplicitno. S druge strane, stolni pisač mogu za ulaz imati RGB vrijednosti, iako sadrže CMYK primare, pa se te RGB vrijednosti posredstvom pogonitelja (eng. driver) pretvaraju u CMYK prostor primara. U tom se slučaju može reći da su CMYK primari implicitno određeni RGB ulazima u uređaj. Tiskom ili ispisom karte na nekom izlaznom uređaju (tiskarski stroj ili pisač), dobiva se otisak karte karakterističan za promatrani uređaj, podlogu i bojilo. Ovisno o reproduksijskim karakteristikama promatranog uređaja, obojena polja karte razlikuju se od uređaja do uređaja. Kako je svrha karakterizacije uređaja opis njegovih reproduksijskih karakteristika s obzirom na promatrača za kojega je

grafički proizvod namijenjen, vrijednosti boja obojanih polja izražavaju se u prostorima koji opisuju boje kako ih vidi promatrač. To su XYZ i L*a*b* prostor boja. Za prostore boja uređaja kaže se da su prostori boja ovisni o uređaju jer rezultat procesa tiska ili ispisa na pisaču ovisi o njihovim reproduksijskim karakteristikama. Na primjer, CMYK primari bojila prema ISO 2846 standardu razlikuju se od bojila prema starom Europascale standardu. S druge strane, za XYZ i L*a*b* prostor boja kaže se da su prostori boja neovisni o uređaju. Oni opisuju boju kako ju vidi promatrač. Zadaća karakterizacijskih karata je povezati prostor boja ovisan o uređaju s prostorom boja neovisnim o uređaju, to jest okarakterizirati uređaj u smislu boja koje će na njemu nastati kao rezultat određenih ulaznih vrijednosti. Nakon tiska ili ispisa karte, vrijednosti boje obojanih polja u XYZ ili L*a*b* sustavu mjere se spektrofotometrom. Rezultat mjerena je tekstualna datoteka u kojoj su sadržani svi ulazi od kojih se karta sastoji i njima pripadajuće izmjerene izlazne vrijednosti.

Veličina karte, odnosno broj polja koja sadrži, može se kretati od nekoliko stotina do nekoliko tisuća [7]. Uobičajen broj polja koji se u praksi koristi je oko 1000. O broju polja ovisi preciznost karakterizacije uređaja, to jest preciznost matematičkog modela koji se izrađuje na temelju karakterizacijske karte. ECI 2002 karta sastoji se od 1286 polja namijenjenih za karakterizaciju i 199 polja za kontrolu procesa.

2.3. ICC profili

ICC profili su računalne datoteke koje opisuju reproduksijske karakteristike uređaja za koji su izrađene. Najčešće se dijele na ulazne, izlazne i profile za monitore, dakle prema tipu uređaja čija svojstva opisuju. Postoje još neke vrste profila koje direktno opisuju transformacije iz prostora boja jednoga u prostor boja drugoga uređaja ili iz jednoga u drugi prostor boja, ali ovaj se rad ograničava na proučavanje izlaznih profila, to jest profila izlaznih uređaja poput pisača i tiskarskih strojeva.

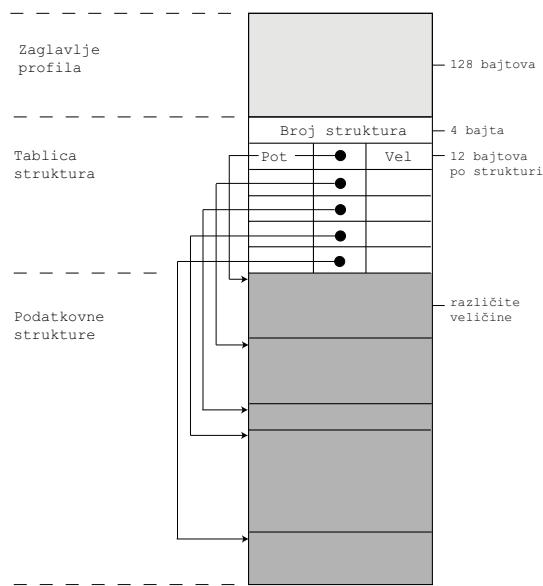
Profil opisuje reproduksijske karakteristike uređaja. Veza između ulaznih i izlaznih jedinica su CIE prostori boja. Prostori boja ovisni u uređaju su RGB i CMYK. Ti se prostori nazivaju ovisnima o uređaju zbog dobro poznatog problema zbog kojega sustavi upravljanja bojama i postoje. Na primjer, ako se s dva različita digitalna fotoaparata snimi isti motiv, RGB vrijednosti slike s dva aparata će se razlikovati zbog različitih karakteristika CCD čipova, različitih filtera na čipovima i različitih linearizacijskih i ostalih post procesnih funkcija ugrađenih u dva različita fotoaparata. Isto je tako poznato da tisak identičnih separacija na dva različita tiskarska stroja rezultira otiscima koji izazivaju različite doživljaje boje. S druge strane, prostori boja neovisni o uređaju poput XYZ i L*a*b*, opisuju boju kako ju percipira standardni promatrač. Za svaku vrijednost izraženu u jedinicama tih prostora poznat je odgovarajući doživljaj boje, odnosno, zbog načina na koji su ti prostori nastali, točnije je reći da su svakom poznatom doživljaju boje pripisane koordinate u CIE prostorima boja.

Profil sadrži tablice u kojima se nalaze vrijednosti koje povezuju prostor boja ovisan o uređaju i prostor boja neovisan o uređaju. Na primjer, profil digitalnog fotoaparata sadrži tablicu RGB vrijednosti u rastućem nizu i njima pripadajućih XYZ ili L*a*b* vrijednosti. Preko te tablice se dolazi do informacije koju je boju aparat „vidio“ kada je za nju generirao određenu RGB vrijednost. Osim te tablice, profil sadrži i tablicu koja prikazuje istu vezu u obratnom smjeru, to jest tablicu L*a*b* vrijednosti u rastućem nizu i njima pripadajućih RGB vrijednosti.

Reprodukcijski proces zahtijeva uporabu dva profila, jednog ulaznog i jednog izlaznog koji opisuju uređaj na kojemu je slika nastala (skener ili digitalni fotoaparat) i uređaj na kojemu će slika biti reproducirana. Za transformaciju slike iz prostora boja uređaja na kojemu je nastala u prostor boja uređaja na kojemu će biti reproducirana zadužen je CMM (eng. color management module). To je softver koji sliku iz prostora boja uređaja na kojemu je nastala prvo preko tablica njegova profila transformira u prostor boja neovisan o uređaju (eng. PCS – profile connection space), a zatim preko tablica profila uređaja na kojemu će slika biti reproducirana, sliku iz prostora boja neovisnog o uređaju (PCS) transformira u prostor toga uređaja. Profil, odnosno model uređaja vrijedi za uvjete u kojima je izrađen (uređaj, podloga i bojilo). Za promjenu bilo kojeg od navedenih faktora obično se ponavlja postupak karakterizacije uređaja, iako su razvijene metode brze prilagodbe novim podlogama s manjim brojem mjerjenja [8] i uvođenjem korektivnih modela [9].

2.3.1. Struktura profila

ICC profili se sastoje od zaglavja, polja u kojemu je zapisan broj podatkovnih struktura sadržanih u profilu, tablice podatkovnih struktura i samih podatkovnih struktura. Zaglavje profila sadrži informacije na temelju kojih ga softver interpretira. Neke od tih informacija su klasa profila (ulazni, izlazni ili profil monitora), prostor boja uređaja (RGB ili CMYK), prostor boja neovisan o uređaju (XYZ ili L*a*b*), preferirani modul (CMM), te informacije o vrsti medija (kod pisača i tiskarskih strojeva sjajni ili mat papir) i izvoru svjetla. Tablica podatkovnih struktura sadrži potpis, poziciju i veličinu svake od struktura sadržanih u profilu. Potpis je vrijednost koja označava tip podatkovne strukture i važna je informacija softveru koji koristi profil jer je jedino prema tome poznato što je potrebno učitati i čemu učitani podaci služe. Pozicija je redni broj (u bajtovima) i softveru daje informaciju gdje se u datoteci profila nalazi početak tražene podatkovne strukture. Slika 2.3.1 prikazuje strukturu ICC datoteka.



Slika 2.3.1, Struktura ICC profila

2.3.2. Struktura izlaznih profila

U prethodnom dijelu prikazana je struktura koja vrijedi općenito za bilo koju klasu (tip) profila. ICC Specifikacija za svaki tip profila propisuje podatkovne strukture koje taj tip profila mora sadržavati. Za izlazne profile je propisano da moraju sadržavati sljedeće podatkovne strukture:

```
profileDescriptionTag  
copyrightTag  
mediaWhitePointTag  
AToB0Tag  
AToB1Tag  
AToB2Tag  
BToA0Tag  
BToA1Tag  
BToA2Tag  
gamutTag
```

Ovdje je potrebno naglasiti problem u terminologiji zbog kojega lako dolazi do zabune. Gore navedeni obavezni dijelovi profila nazivaju se strukturama, ali zapravo su to potrebni sastavni dijelovi profila koji mogu biti sadržani u različitim tipovima podatkovnih struktura. Treba uočiti razliku između tablice struktura (koja sadrži listu gore navedenih obaveznih sastavnih dijelova s njihovim potpisima) i samih struktura koje sadrže svoje potpise. Tako npr. gamutTag-u može odgovarati lut8Type (8-bitna podatkovna struktura) ili lut16Type (16-bitna podatkovna struktura). AToB i BToA mogu odgovarati lut8Type, lut16Type ili lutAtoB, odnosno lutBtoA strukture.

profileDescriptionTag – sadrži tekstualni opis profila (najčešće opis uređaja za koji je profil izrađen). Tekst sadržan u ovoj strukturi prikazuje se u aplikacijama u listama profila
copyrightTag – sadrži tekstualne informacije o autoru profila

AToB0Tag – sadrži transformacijske tablice iz prostora boja uređaja u prostor boja neovisan o uređaju za percepcijsko preslikavanje gamuta

AToB1Tag – sadrži transformacijske tablice iz prostora boja uređaja u prostor boja neovisan o uređaju za kolorimetrijsko preslikavanje gamuta

AToB2Tag – sadrži transformacijske tablice iz prostora boja uređaja u prostor boja neovisan o uređaju za reprodukciju boja maksimalnog zasićenja

BToA0Tag – sadrži transformacijske tablice iz prostora boja neovisnog o uređaju u prostor boja uređaja za percepcijsko preslikavanje gamuta

BToA1Tag – sadrži transformacijske tablice iz prostora boja neovisnog o uređaju u prostor boja uređaja za percepcijsko preslikavanje gamuta

BToA2Tag – sadrži transformacijske tablice iz prostora boja neovisnog o uređaju u prostor boja uređaja za percepcijsko preslikavanje gamuta

gamutTag – sadrži tablice u koje je ulazna vrijednost koordinata u PCS-u, a izlazna vrijednost 0 ako je boja unutar gamuta uređaja, odnosno >0 ako je boja izvan gamuta

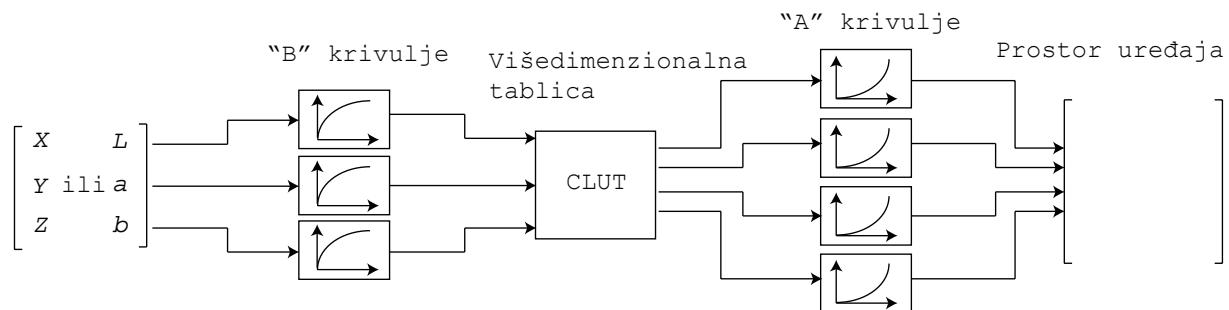
Posljednja verzija Specifikacije preporuča upotrebu referentnog gamuta (PRMG – Print reference media gamut), a neke studije su pokazale da upotreba PRMG-a dovodi do poboljšanja reprodukcije [10; 11].

2.3.3. Transformacijski model

ICC Specifikacija opisuje nekoliko osnovnih transformacijskih modela koji se razlikuju prema klasi uređaja za koje su namijenjeni. Transformacijski model je u osnovi postupak kojim se boja transformira iz jednoga u drugi prostor boja. Iz gore navedenog je jasno da postoje transformacijski modeli iz PCS-a u prostor boja uređaja i obratno, iz prostora boja uređaja u PCS.

Pet transformacijskih modela iz PCS-a u prostor boja uređaja navedenih u Specifikaciji mogu se prema svojim elementima podijeliti u dvije skupine. U jednu skupinu spadaju modeli koji koriste matrice i reproduksijske krivulje, a u drugu skupinu spadaju modeli koji koriste tablice boja (CLUT – color look up table) [12]. Modeli koji koriste matrice i reproduksijske krivulje primjenjuju se za jednostavnije, približno linearne uređaje. Takvi se modeli u pravilu ne primjenjuju za pisače i tiskarske strojeve jer ih ne mogu opisati dovoljno precizno, već se za spomenute uređaje rabe modeli koji koriste tablice boja (CLUT).

Slika 2.3.2 prikazuje najčešće korišteni transformacijski model koji je korišten i u sklopu ovoga istraživanja. Taj model koristi višedimenzionalnu tablicu boja u koju su ulazne vrijednosti boje iz prostora PCS-a, a izlazne vrijednosti boje iz prostora boja uređaja.



Slika 2.3.2, Transformacijski model prema Specifikaciji ICC.1:2004-10

Preciznost profila ovisi o dimenzijama tablice boja. Pri izradi profila odabire se broj točaka kojima će biti podijeljene osi ulaznog prostora u tablicu. Tabela 2.1 prikazuje podjelu PCS-a na 33 točke.

Tabela 2.1, Podjela tablice boja na 33 točke

Točka	L*	a*	b*
1	0,000	-128	-128
2	3,125	-120	-120
3	6,250	-112	-112
.	.	.	.
.	.	.	.
.	.	.	.
31	93,750	111	111
32	96,875	119	119
33	100,000	127	127

Ulazi u tablicu boja su vrijednosti $L^*a^*b^*$ od (0,-128,-128) do (100,127,127), poredane u rastućem nizu tako da b^* raste najbrže, a L^* najsporije. Tablice boja s 33 točke i 3 ulazne vrijednosti (3 osi PCS-a) sadrže $33^3 = 35\ 937$ unosa (ulaznih i izlaznih vrijednosti). Očigledno je da se podjelom osi PCS-a na određeni broj

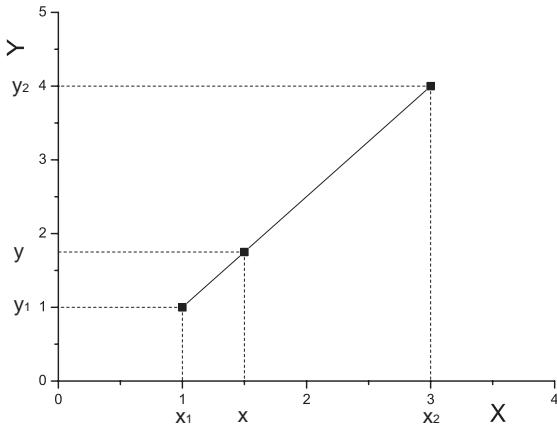
točaka stvaraju stepenasti prijelazi i da tablica boja ne može sadržavati sve vrijednosti PCS-a. Kada bi sadržavala samo sve cijele vrijednosti PCS-a, imala bi $100 \times 256 \times 256 = 6\ 553\ 600$ unosa, što bi bilo vrlo nepraktično, kako u pogledu veličine profila, tako i u pogledu vremena potrebnog da softver za izradu profila preko matematičkog modela izračuna procijenjene izlazne vrijednosti za toliki broj ulaznih vrijednosti. S obzirom da tablica boja ne sadrži sve vrijednosti mogućih ulaza, CMM za neku ulaznu vrijednost koje u tablici nema mora odrediti određeni broj poznatih ulaznih vrijednosti koje tu nepoznatu vrijednost okružuju, a zatim izlaznu vrijednost odrediti interpolacijom. Broj poznatih točaka koji je potreban za interpolaciju ovisi o vrsti interpolacije. Kako većina modula koristi neki oblik linearne interpolacije, a odazivi uređaja su u pravilu nelinearni, tablicu boja moguće je linearizirati kako bi se povećala preciznost vrijednosti predviđenih interpolacijom. U tu se svrhu koriste „B“ krivulje i „A“ krivulje. Njihova je svrha linearizacija tablice boja u odnosu na izlazni prostor boja. Te su krivulje unutar profila implementirane kao jednodimenzionalne tablice. Prema transformacijskom modelu za neku traženu vrijednost $L^*a^*b^*$ prvo se u jednodimenzionalnoj tablici određuje njoj pripadajuća nova vrijednost $L^* a^* b^*$ te se ta vrijednost koristi kao ulazna vrijednost u višedimenzionalnu tablicu boja (CLUT). Kada se pomoću višedimenzionalne tablice odredi odgovarajuća vrijednost u prostoru boja uređaja, na primjer CMYK, za te se vrijednosti preko „A“ krivulja, jednodimenzionalnih tablica inverznih „B“ krivuljama, nalaze odgovarajuće $C' M' Y' K'$ vrijednosti te se one koriste kao procijenjene vrijednosti ulaza u uređaj koji rezultira traženim $L^*a^*b^*$ odazivom. Potrebna veličina jednodimenzionalnih tablica jedno je od otvorenih pitanja ICC profila. Kako Specifikacija određuje samo načelni transformacijski model, dolazi do različitih interpretacija pa time i implementacija pri razvoju softvera za izradu ICC profila, ali i pri razvoju CMM-ova. Tako neki CMM-ovi koriste samo jednodimenzionalne tablice profila, dok drugi vrijednosti u tim tablicama interpoliraju kako bi dobili veći broj točaka [13]. Novije verzije ICC profila podržavaju opis jednodimenzionalnih krivulja u parametarskom obliku.

Ovdje prikazani transformacijski model služi za transformacije boja iz prostora boja neovisnog o uređaju u prostor boja uređaja koristeći BToAxTag-ove. Kako je u prethodnom dijelu prikazano, sastavni dio izlaznih profila su i AToBxTag-ovi i njih koristi inverzni model za transformaciju boje iz prostora boja uređaja u prostor boja neovisan o uređaju. Na preciznost profila utječe i odabir PCS-a. Specifikacija dozvoljava upotrebu niza različitih PCS-ova, ali ne sugerira odabir. Prema nekim istraživanjima [14; 13], za profile pisača se preporučuje odabir $L^*a^*b^*$ prostora, a za uređaje koji se mogu precizno okarakterizirati jednostavnijim transformacijskim modelom preporučuje se upotreba XYZ prostora.

2.4. Interpolacija

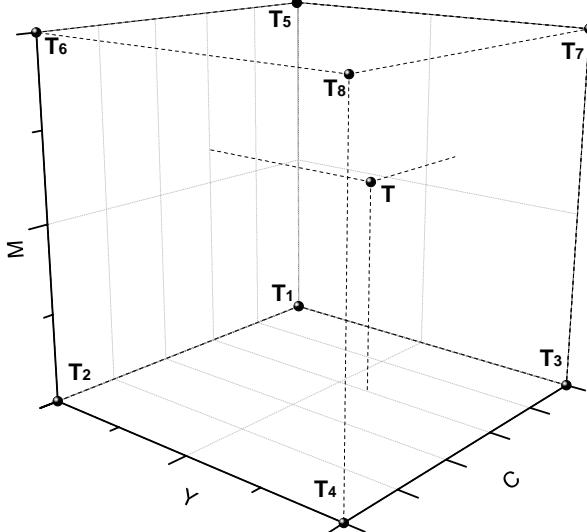
U ovome dijelu rada detaljnije je objašnjeno ranije spomenuto određivanje izlaznih vrijednosti interpolacijom za ulazne vrijednosti koje nisu sadržane u tablicama boja. Najjednostavniji oblik interpolacije koji se primjenjuje na prostore boja je trilinearna interpolacija. Ona je rezultat prirodnog proširenja jednostavne linearne interpolacije na bilinearnu, te zatim na trilinearnu.

Linearnom interpolacijom (Slika 2.4.1) određuje se vrijednost zavisne varijable y iz poznate vrijednosti nezavisne varijable x i poznate koordinate dviju točaka. Pri tome je prepostavka da y linearno ovisi o x , to jest da sve točke leže na istom pravcu.



Slika 2.4.1, Linearna interpolacija

Kao što je za linearnu interpolaciju potrebno znati koordinate 2 točke i jednu vrijednost tražene točke, tako je za trilinearnu interpolaciju (Slika 2.4.2) potrebno znati koordinate osam vrhova kocke u ulaznom prostoru boja i njima pripadajuće vrijednosti u izlaznom prostoru boja. Ako se traži položaj točke T u XYZ prostoru boja za neki poznati položaj točke T u CMY prostoru boja, T=(c,m,y), prvo je iz tablice boja u odgovarajućem AToBxTag-u potrebno odrediti osam poznatih točaka T₁=(c₁,m₁,y₁)... T₈=(c₈,m₈,y₈) koje predstavljaju vrhove kocke unutar koje se nalazi točka T i za koje su poznate pripadajuće koordinate u izlaznom prostoru boja T₁=(X₁,Y₁,Z₁)... T₈=(X₈,Y₈,Z₈). Zatim se interpolacijom po svakoj od c,m i y osi posebno prvo određuju vrijednosti u točkama koje leže na bridovima i pobočkama kocke, t₁...t₆ da bi se interpolacijom po zadnjoj preostaloj osi odredila vrijednost u točki T.



Slika 2.4.2, Trilinearna interpolacija

$$\begin{aligned}
 X(T) &= \left[X(t_1) \frac{y_2 - y}{y_2 - y_1} + X(t_2) \frac{y - y_1}{y_2 - y_1} \right] \frac{m_2 - m}{m_2 - m_1} + \left[X(t_4) \frac{y_2 - y}{y_2 - y_1} + X(t_5) \frac{y - y_1}{y_2 - y_1} \right] \frac{m - m_1}{m_2 - m_1} \\
 X(T) &= X(t_1) \frac{m_2 - m}{m_2 - m_1} \cdot \frac{y_2 - y}{y_2 - y_1} + X(t_2) \frac{m_2 - m}{m_2 - m_1} \cdot \frac{y - y_1}{y_2 - y_1} + \\
 &\quad + X(t_4) \frac{y_2 - y}{y_2 - y_1} \cdot \frac{m - m_1}{m_2 - m_1} + X(t_5) \frac{y - y_1}{y_2 - y_1} \cdot \frac{m - m_1}{m_2 - m_1}
 \end{aligned}$$

$$\begin{aligned}
X(T) = & X_1 \frac{c_2 - c}{c_2 - c_1} \cdot \frac{m_2 - m}{m_2 - m_1} \cdot \frac{y_2 - y}{y_2 - y_1} + X_2 \frac{c - c_1}{c_2 - c_1} \cdot \frac{m_2 - m}{m_2 - m_1} \cdot \frac{y_2 - y}{y_2 - y_1} + \\
& + X_3 \frac{c_2 - c}{c_2 - c_1} \cdot \frac{m_2 - m}{m_2 - m_1} \cdot \frac{y - y_1}{y_2 - y_1} + X_4 \frac{c - c_1}{c_2 - c_1} \cdot \frac{m_2 - m}{m_2 - m_1} \cdot \frac{y - y_1}{y_2 - y_1} + \\
& + X_5 \frac{c_2 - c}{c_2 - c_1} \cdot \frac{y_2 - y}{y_2 - y_1} \cdot \frac{m - m_1}{m_2 - m_1} + X_6 \frac{c - c_1}{c_2 - c_1} \cdot \frac{y_2 - y}{y_2 - y_1} \cdot \frac{m - m_1}{m_2 - m_1} + \\
& + X_7 \frac{c_2 - c}{c_2 - c_1} \cdot \frac{y - y_1}{y_2 - y_1} \cdot \frac{m - m_1}{m_2 - m_1} + X_8 \frac{c - c_1}{c_2 - c_1} \cdot \frac{y - y_1}{y_2 - y_1} \cdot \frac{m - m_1}{m_2 - m_1}
\end{aligned}$$

U pojednostavljenom obliku, pripisu li se vrijednosti $c_1=0$, $m_1=0$, $y_1=0$, $c_2=1$, $m_2=1$ i $y_2=1$, gornji izraz poprima oblik:

$$\begin{aligned}
X(T) = & X_1(1 - c)(1 - m)(1 - y) + X_2c(1 - m)(1 - y) + X_3(1 - c)(1 - m)y + X_4c(1 - m)y \\
& + X_5(1 - c)m(1 - y) + X_6cm(1 - y) + X_7(1 - c)my + X_8cmy
\end{aligned}$$

O drugim metodama interpolacije više je izneseno u dijelu 2.4. Metoda interpolacije nije definirana Specifikacijom, ali su rezultati konzistentni među različitim implementacijama [15].

Preciznost vrijednosti određenih interpolacijom ovisi o gustoći tablice boja (o broju točaka po kanalu) i o lineranosti podataka u tablici boja. Ako podaci nisu linearizirani pomoću jednodimenzionalnih tablica, a gustoća trodimenzionalne tablice je još k tome mala, greška interpolacije može biti prilično velika. Takav profil uređaja moguće je poboljšati. U jednome radu autori su primijenili spline interpolaciju na tablicu boja nepreciznog profila pisača, te su izgradili novu tablicu boja s većim brojem vrijednosti i znatno povećali preciznost profila [16].

Gore prikazani postupak određuje XYZ tristimulusne vrijednosti na osnovu količine CMY bojila. Kako je obično potrebno odrediti količinu bojila kojom se postiže neka ciljana XYZ ili L*a*b* vrijednost, potrebno je odrediti inverznu funkciju. Kako ona ne postoji, razvijene su posebne metode poput optimizacije prilagodbom uvjeta kojom je na CMYK pisaču postignuta srednja vrijednost pogreške $\Delta E < 2$, a primjenjiva je i na procese s većim brojem primara [17]. Jednostavnije i ranije rješenje bila je upotreba Shepardove interpolacije koja omogućuje interpolaciju pravilno raspoređenih vrijednosti iz nepravilno raspoređenih vrijednosti [18]. Noviji pristup koristi metode računalne geometrije [19].

U jednoj studiji [20] uspoređene su performanse interpolacije klasičnim pristupom i tzv. pristupom zatvorene petlje. Prvi pristup podrazumijeva izgradnju zasebnih transformacijskih tablica iz prostora ulaznog uređaja u PCS i zasebnih tablica za transformaciju iz PCSa u prostor izlaznog uređaja. Drugim pristupom izrađuju se samo jedne transformacijske tablice, direktno iz prostora ulaznog uređaja u prostor izlaznog uređaja. Prema rezultatima iznesenim u studiji, pristup zatvorene petlje dao je bolje rezultate.

U jednoj implementaciji tablica boja osim transformacije boja uključuje i preslikavanje gamuta [21].

3. Modeli izlaznih uređaja

Kako je ranije već spomenuto, modeli uređaja imaju svrhu povezati prostore boja uređaja s prostorima boja neovisnim o uređaju. Različitim pristupima razvijeni su modeli koji se mogu svrstati u dvije skupine: fizikalni modeli i numerički modeli. Fizikalni modeli nastoje opisati uređaje na način da uzimaju u obzir njihova fizikalna svojstva. Češće korišteni numerički modeli vezu između prostora boja određuju na temelju mjerena odaziva uređaja u odnosu na vrijednosti ulaza.

3.1. Fizikalni modeli

Osim modela koji imaju zadaću opisati vezu među prostorima boja, neki fizikalni modeli imaju zadaću opisati vezu između reflektancije i rastertonske vrijednosti (RTV) ili gustoće obojenja (D)

Gustoća obojenja

$$D = -\log R$$

Pokrivenost površine

U modele koji opisuju vezu između pokrivenosti površine i reflektancije ili gustoće obojenja spadaju Murray-Davies, Yule-Nielsen i Clapper-Yule modeli

Murray-Davies

Murray-Daviesova jednadžba daje vezu između pokrivenosti površine i reflektancije, odnosno gustoće obojenja. Ovisno o tome treba li prikazivati vezu s reflektancijom ili s gustoćom obojenja, poprima odgovarajući oblik supstitucijom prema gore prikazanom izrazu za gustoću obojenja. Najčešće dolazi u obliku s gustoćama obojenja normaliziranim na bjelinu papira:

$$A = \frac{1 - 10^{-D_t}}{1 - 10^{-D_s}}$$

gdje su

A (eng. area) – pokrivenost površine

D_t (eng. tint) – gustoća obojenja za koju se računa RTV

D_s (eng. solid) – gustoća obojenja na polju punog tona

Yule-Nielsen

Pokrivenost površine osim o geometrijskoj veličini rasterskih elemenata ovisi i o lomovima svjetla unutar tiskovne podloge, to jest o optičkim svojstvima podloge. Kada je potrebno odrediti geometrijsku pokrivenost površine (bez geometrijskog prirasta) ili ciljanu pokrivenost površine (bez geometrijskog i bez optičkog prirasta), potrebno je uvesti korekciju. Uvođenjem eksponenta n nad reflektancijom dolazi se do Yule-Nielsenove jednadžbe:

$$A = \frac{1 - 10^{-D_t/n}}{1 - 10^{-D_s/n}}$$

Clapper-Yule

Clapper-Yuleov model nastoji obuhvatiti rasipanje svjetlosti u podlozi, transmitanciju kroz sloj bojila i reflektanciju s površine.

$$R = K_s + \frac{xIr(1 - A + At)^2}{1 - r(1 - x)(1 - A + At^2)}$$

K_s – refleksija s površine

t – transmitancija bojila

I – svjetlost koja prodire u podlogu

x – udio unutrašnje reflektirane svjetlosti

Modifikacija ovoga modela, proširena u skladu s Beerovim zakonom kako bi se u obzir uzela debljina sloja bojila, pokazala se učinkovitom u predviđanju spektralnih reflektancija uzoraka izrađenih na ink-jet pisačima [22]. Ink-jet pisači mogu formirati elemente različitih veličina nanošenjem više kapljica bojila na isto mjesto.

Neugebauer

Neugebauerov model prepostavlja da je reflektancija s neke površine aditivna kombinacija reflektancija s primara i mjesta njihova preklapanja. Oslanja se na Demichelov rad kojime je pokazano da su, uz prepostavku slučajne strukture rastera, reflektancije sa svake od pojedinih površina (primara, sekundara i tercijara) umnožak reflektancije s polja punoga tona i iznosa promatrane površine. U svrhu predviđanja X, Y i Z tristimulusa za CMYK primare, Neugebauerov model poprima sljedeći oblik:

$$X = A_w X_w + A_c X_c + A_m X_m + A_y X_y + A_r X_r + A_g X_g + A_b X_b + A_k X_k$$

$$Y = A_w Y_w + A_c Y_c + A_m Y_m + A_y Y_y + A_r Y_r + A_g Y_g + A_b Y_b + A_k Y_k$$

$$Z = A_w Z_w + A_c Z_c + A_m Z_m + A_y Z_y + A_r Z_r + A_g Z_g + A_b Z_b + A_k Z_k$$

Često se prikazuje i kao suma umnožaka stimulusnih vrijednosti i težinskih vrijednosti zadanih Demichelovom jednadžbom. U slučaju tri primara Neugebauerov model je istovjetan trilinearnoj interpolaciji.

S obzirom da struktura rastera nije slučajna, rasterski elementi nisu uniformno obojeni, u podlozi dolazi do lomova svjetlosti, a Neugebauerov model te činjenice ne uzima u obzir uvedene su modifikacije kojima je poboljšana moć predviđanja modela [23].

n-korekcija: Rasipanje svjetlosti u podlozi korigira se uvođenjem eksponenta n, a u novijoj modifikaciji iznos eksponenta n ovisi o upotrijebljenom bojilu [24].

vektorska korekcija: uvodi se korektivni faktor na osnovu vektorske udaljenosti izmjerene (empirijske) vrijednosti od one predviđene izvornim ili na neki drugi način modificiranim Neugebauerovim modelom.

Proširenje s čelijama: prostor boja dijeli se na više manjih prostora većim brojem mjerena. Na taj se način umanjuju greške nastale interpolacijom. Postizanje prihvativljive preciznosti može zahtijevati velik broj mjerena pa su neka istraživanja bila usmjereni na smanjenje broja mjerena uz zadržavanje preciznosti modela [25; 26].

Jedna verzija nazvana dvostrukim Neugebauerovim modelom proširuje skup kombinacija primara uvezši u obzir veća manja područja pojedinih primara čime udvostručuje skup kombinacija primara [27].

Proširenje na domenu spektralnih reflektancija: Umjesto predviđanja tristimulusnih vrijednosti, ovaj model predviđa reflektancije po pojasevima spektra određene širine [28].

Problem Neugebauerovog modela je u tome što nije analitički invertibilan, već ju za njegovu inverziju potrebno primijeniti numeričke ili statističke metode [29; 30].

Neugebauerov model može se prilagoditi za predviđanje spektralnih transmitancija, kao što je skupina autora pokazala u studiji s dvostrano otisnutim arcima papira [31].

Modeli primara

Ovi modeli predviđaju reflektanciju ili transmitanciju slojeva boljila različitih debljina nanosa

Jednadžbe maski

Ove jednadžbe prepostavljaju da su gustoće obojenja tiskarskih bojila aditivne. Uzeviši u obzir neželjene apsorpcije i prepostavivši da su one konstantne (proporcionalne količini bojila), dolazi se do izraza:

$$\begin{bmatrix} C_r \\ M_g \\ Y_b \end{bmatrix} = A \begin{bmatrix} D_r \\ D_g \\ D_b \end{bmatrix}$$

Te je jednadžbe prvi objavio Yule 1938.g., a kasnije Clapper i Yule predlažu uvođenje članova viših redova i međuprodukata za opis procesa za koje ne vrijede aditivnost i proporcionalnost [32].

Beer-Bouguer

Vezu između transmitancije i količine bojila u apsorpcijskim filtrima moguće je opisati na osnovu fizikalnih zakona Beera, Lambertia i Bouguera. Transmitancija svjetlosti kroz medij proporcionalna je njegovoj debljini i apsorptivnosti.

$$A = \log\left(\frac{1}{T}\right)$$

A – apsorbancija

T – transmitancija

$$A = \varepsilon c w$$

ε – konstanta apsorptivnosti medija

c – koncentracija bojila

w – debljina medija

Kubelka-Munk

Ovaj model opisuje reflektanciju svjetlosti s obojene reflektivne površine uzimajući u obzir apsorbanciju i rasipanje svjetlosti u sloju bojila i refleksiju svjetlosti s podloge.

$$\frac{K}{S} = \frac{(1 - R)^2}{2R}$$

R – faktor refleksije

K – koeficijent apsorpcije

S – koeficijent rasipanja

$$R = 1 + \frac{K}{S} - \left(\left(1 + \frac{K}{S} \right)^2 - 1 \right)^{\frac{1}{2}}$$

Konstante K i S određuju se empirijski, bilo pojedinačno, bilo kao kvocijent K/S.

Postoje modifikacije Kubelka-Munk modela koje nastoje preciznije opisati utjecaj mehaničkog prirasta rasterskih elemenata i rasipanje svjetlosti u papiru [33] i generalizacija Kubelka-Munk modela i povezivanje s Neugebauerovim u jedinstven model [34].

Performanse ovdje navedenih fizikalnih modela u jednoj su studiji bile uspoređene na jednom laserskom pisaču. Najbolji rezultati postignuti su Yule-Nielsenovim modelom [35].

3.2. Numerički modeli

Pod numeričkim modelima podrazumijevaju se regresijski modeli. Funkcija koja se prilagođava vrijednostima na cijeloj domeni uređaja je polinom proizvoljnog reda i s proizvoljno odabranim članovima. Odabir optimalnoga reda i članova za zadani uređaj nije očigledan. S obzirom da su upravo ovi modeli predmet istraživanja ovoga rada, u nastavku im je posvećeno posebno poglavlje. Rijetko se nalaze i primjeri primjene iteracijskih metoda prilagodbe modela koji daju rezultate slične regresijskim modelima [36].

Spline interpolacija

Naziv spline dolazi od engleskog „spliced line“. Kod ove se tehnikе domena dijeli na segmente kojima se prilagođavaju polinomi nižih redova (obično trećega reda). Izraz prilagođavaju treba uzeti s rezervom jer za razliku od prilagodbe u smislu najmanjih kvadrata interpolacija podrazumijeva da dobivena funkcija prolazi kroz svaku od točaka. Kod spline interpolacije definiraju se segmenti polinoma između susjednih parova točaka i to na način da segmenti prolaze kroz obje točke te da dva susjedna segmenta u zajedničkoj točki imaju jednake derivacije čime se osigurava „gladak“ prijelaz. Prema rezultatima iznesenim u jednoj komparativnoj studiji, spline interpolacijom postiže se preciznost slična polinomima trećega reda [37].

3.3. Neuronske mreže

Umetne neuronske mreže razvijene su u pokušaju da se simulira način na koji ljudski mozak obrađuje informacije. Prve neuronske mreže sastavljane su od fizičkog sklopovlja, a u današnje se vrijeme često samo simuliraju na računalima. Od brojnih tipova umjetnih neuronskih mreža, u praktičnoj upotrebi se najčešće nalazi MLP (eng. multilayer perceptron) [38]. Među prvim neuronskim mrežama za karakterizaciju uređaja korištена je mreža bez povratnih veza (eng. feedforward) trenirana algoritmom s povratnom propagacijom pogreške (eng. backpropagation). Dobiveni rezultati bili su usporedivi s drugim metodama karakterizacije uređaja [39]. Mreža se načelno sastoji od ulaznih, izlaznih i skrivenih jedinica (umjetnih neurona). Broj ulaznih jedinica odgovara dimenzijama ulaznog vektora, a broj izlaznih jedinica odgovara dimenzijama izlaznog vektora. Broj skrivenih jedinica određuje se empirijski. Neuronske mreže u osnovi transformiraju ulazne vektore u izlazne. To čine pomoću aktivacijskih funkcija svakog pojedinog neurona koje za određeni ulaz daju odgovarajući izlaz. U izgradnji neuronskih mreža korištene su različite aktivacijske funkcije, a pri karakterizaciji izlaznih uređaja često su korištene funkcije radikalne baze [40]. Gledano u cjelini, mreža je aproksimator funkcije koja opisuje vezu između ulaznih i izlaznih vektora. U kontekstu neuronskih mreža javljaju se dva pojma: memorizacija i generalizacija. Memorizacija označava prilagođenost mreže podacima koji su korišteni tijekom njenog učenja, a generalizacija označava prilagođenost mreže drugim podacima, to jest sposobnost predviđanja izlaza za ulazne vrijednosti koje nisu korištene tijekom učenja mreže. Slično kao i kod regresijskih modela, vrlo složena mreža može postići vrlo dobro memorizaciju, ali i vrlo lošu generalizaciju. Potrebno je odrediti optimum za određeni uređaj. Prema rezultatima komparativnih studija, performanse optimalnih neuronskih mreža slične su onima optimalnih regresijskih modela [41; 42].

3.4. Tabele s interpolacijom

Kada je veza između prostora boja složena, traženu vrijednost izlaza za određeni ulaz brže je odrediti interpolacijom nego evaluacijom neke vrlo složene funkcije. U najjednostavnijem obliku tablica za tri primara sadrži osam vrijednosti koje odgovaraju uglovima kocke, upravo kako je prikazano u dijelu 1.4. Općenito, sve što je o interpolaciji navedeno u kontekstu CMM-a, vrijedi i u kontekstu karakterizacije uređaja. Naravno, ako je glavna prednost interpolacije brzina u slučaju složenih odaziva uređaja, takva jednostavna tablica u tim slučajevima ne daje dovoljnu preciznost. Stoga se ovakve tablice često sastavljaju podjelom prostora velikim brojem mjerjenja i direktnim unošenjem tih vrijednosti u tablicu, što se ponekad naziva „potpunom karakterizacijom“, [43].

Osim trilinearne interpolacije opisane u dijelu 1.4, razvijen je niz sličnih geometrijskih tehnika kojima je cilj smanjenje složenosti operacije, to jest veća efikasnost pri računaju. To postiže smanjenjem broja vrijednosti među kojima se izvodi interpolacija, podjelom kocke (osam vrhova) na neke druge poliedre [44; 45].

Alternativna tehnika, takozvana sekvenčna linearna interpolacija, umjesto ravnomjerno raspodijeljenih točaka bira točke na osnovu značajki prijenosne funkcije (nelinearnosti). Na taj način umanjuje grešku koja nastaje interpolacijom [46; 47]. U kombinaciji s ovom tehnikom može se izvršiti i „izglađivanje“ podataka spline interpolacijom kako bi se umanjili šumovi u izmjerениh podacima [48].

Pri inverznim transformacijama može doći do znatnih grešaka u reprodukciji u područjima u blizini granice gamuta. Razlog tome je kombinacija interpolacije i preslikavanja gamuta pa je razvijen postupak ekstrapolacije kojime se čuva odnos vrhova prostora boja uređaja s vrhovima PCS-a [49].

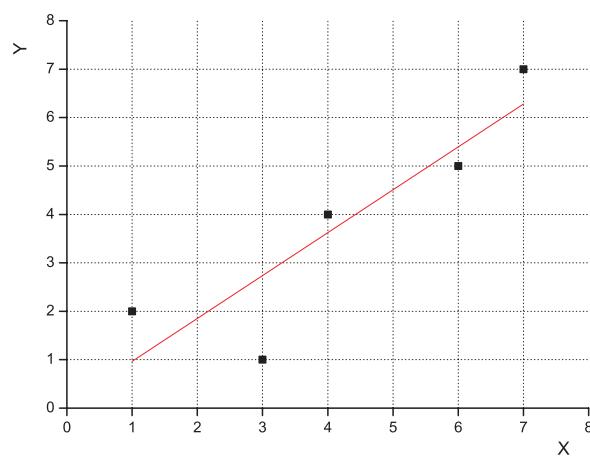
4. Regresijske metode

Uobičajena metoda modeliranja izlaznih uređaja je regresija. Taj se naziv često nalazi u literaturi, ali je potrebno naglasiti da je taj izraz posuđen iz regresijske analize, a sama metoda koja se zapravo koristi je prilagodba u smislu najmanjih kvadrata. To je metoda modeliranja odnosa između jedne ili više zavisnih varijabli i jedne ili više nezavisnih varijabli. Pri tome je model ovisan o nepoznatim parametrima koje je potrebno odrediti na temelju empirijskih podataka. Problem je najjednostavnije prikazati na slučaju jedne zavisne i jedne nezavisne varijable.

Neka je x nezavisna, a y zavisna varijabla. Ako je x ulazna vrijednost u neki proces, a y izlazna vrijednost ovisna o veličini ulaza x , onda je moguće odrediti analitički izraz koji opisuje ovisnost tih dviju varijabli. Postupak započinje prikupljanjem podataka, to jest mjerenjem veličina izlaza iz procesa za određen broj različitih veličina ulaza u proces. Tabela 4.1, Skup točaka prikazuje empirijske podatke zadanih ulaza x u proces i njima pripadajućih izlaza y iz procesa.

Tabela 4.1, Skup točaka

X	Y
1	2
3	1
4	4
6	5
7	7



Slika 4.1, Prilagodba pravca skupu točaka

Slika 4.1 prikazuje prikupljene podatke kao skup točaka u x-y ravnini. Na temelju slike potrebno je odabrati oblik modela, to jest tip funkcije kojom će se opisati ovisnost $y=f(x)$. Najjednostavnija funkcija koja može biti odabrana je polinom prvog stupnja, čiji graf predočava pravac. Kako u ovom slučaju ne postoji jedinstven pravac koji se može provući kroz sve točke, postavlja se zahtjev da pravac bude takav da što manje odstupa od svake pojedine točke.

Opći oblik jednadžbe pravca glasi:

$$kx + l = y$$

pa se uz poznate koordinate x i y za 5 točaka dolazi do 5 jednadžbi s dvije nepoznanice:

$$\begin{aligned} k + l &= 2 \\ 3k + l &= 1 \\ 4k + l &= 4 \\ 6k + l &= 5 \\ 7k + l &= 7 \end{aligned}$$

U matričnom obliku sustav se zapisuje na sljedeći način:

$$\begin{bmatrix} 1 & 1 \\ 3 & 1 \\ 4 & 1 \\ 6 & 1 \\ 7 & 1 \end{bmatrix} \begin{bmatrix} k \\ l \end{bmatrix} = \begin{bmatrix} 2 \\ 1 \\ 4 \\ 5 \\ 7 \end{bmatrix}$$

Pa se uvođenjem oznaka

$$A = \begin{bmatrix} 1 & 1 \\ 3 & 1 \\ 4 & 1 \\ 6 & 1 \\ 7 & 1 \end{bmatrix} \quad x = \begin{bmatrix} k \\ l \end{bmatrix} \quad b = \begin{bmatrix} 2 \\ 1 \\ 4 \\ 5 \\ 7 \end{bmatrix}$$

Sustav zapisuje kao $Ax = b$

S obzirom da se kao rješenje sustava traži takav vektor x , to jest takav koeficijent smjera k i odsječak l na osi y , koji daju jednadžbu pravca koji od zadanih točaka minimalno odstupa po y , taj se zahtjev može zapisati na sljedeći način:

$$\|Ax - b\| \rightarrow \min$$

Pa isto vrijedi:

$$\|Ax - b\|^2 \rightarrow \min$$

Prema definiciji norme vektora, gornji se izraz može raspisati:

$$(Ax - b)^T(Ax - b) = x^T A^T A x - b^T A x - x^T A^T b + b^T b$$

Taj izraz možemo zapisati kao funkciju:

$$Q(x) = x^T B x - 2x^T c + \beta$$

Uz supstitucije:

$$B = A^T A \quad c = A^T b \quad \beta = b^T b = \|b\|^2$$

Uzmememo li da su x, B, c i β realni brojevi, izraz poprima oblik kvadratne funkcije:

$$Q(x) = x^2 B - 2x c + \beta$$

Za koju znamo da ima minimum u:

$$x = \frac{c}{B}$$

Pa rješenje u višedimenzionalnom obliku glasi

$$x = B^{-1} c$$

Odnosno uz vraćanje supstitucija

$$x = (A^T A)^{-1} A^T b$$

Metodom najmanjih kvadrata je moguće odrediti parametre bilo koje po volji zadane funkcije, s proizvoljnim brojem zavisnih i nezavisnih varijabli. Za pronaalaženje pseudoinverzne matrice koriste se Moore-Penrose postupak ili češće singularna dekompozicija koja daje numerički stabilnija rješenja [50; 51].

4.1. Modeliranje izlaznih uređaja

Kao što je u uvodnom dijelu o regresijskim metodama spomenuto, pri modeliranju izlaznih uređaja, to jest pisača i tiskarskih strojeva, služimo se metodom prilagodbe u smislu najmanjih kvadratnih odstupanja. Princip je isti kao u gore navedenom primjeru, samo se izlazni uređaji opisuju funkcijama više varijabli jer modeliramo transformacije iz jednoga u drugi prostor boja, koji su u pravilu višedimenzionalni.

Kao što je u prethodnom dijelu pokazano, za postupak modeliranja potrebni su empirijski podaci. Oni se prikupljaju mjeranjem karakteričkih karata, to jest mjeranjem odaziva uređaja u izlaznom prostoru boja za poznate vrijednosti ulaza. Te se vrijednosti skupljaju u matrice koje se najčešće označavaju slovima C (eng. color), čiji retci odgovaraju vektorima iz prostora boja neovisnog o uređaju, i D (eng. device), čiji retci odgovaraju vektorima iz prostora boja ovisnog o uređaju. U oba slučaja broj redaka matrice jednak je broju obojanih polja karakterizacijske karte. Najjednostavniji oblik glasi:

$$[X \ Y \ Z] = [R \ G \ B] \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix}$$

$$C = D \cdot A$$

U literaturi se gore navedeni sustav često prikazuje u transponiranom obliku, ali u se u praksi pojavljuje gore navedeni oblik iz praktičnog razloga unošenja vektora boja i uređaja za svako polje karakterizacijske karte u matrice.

Slično primjeru navedenom u prethodnom dijelu, matrica koeficijenata A računa se prema sljedećem izrazu:

$$A = (D^T D)^{-1} D^T C$$

Dobivena matrica koeficijenata koristi se za predviđanje izlazne vrijednosti boje kojom treba rezultirati neka ulazna vrijednost. U najjednostavnijem slučaju c i d su vektori-retci s po 3 elementa, a A je matrica dimenzija 3×3 .

Gore prikazani jednostavni sustav primjenjiv je samo za približno linearne uređaje, obično ulazne poput skenera kojima su odazivi senzora linearni u odnosu na funkcije promatrača [7].

Izlazni uređaji opisuju se polinomima drugog ili viših stupnjeva. Obično se ne koriste polinomi viši od trećega stupnja jer svakim dodatnim redom funkcija dobiva dodatne zavoje u kojima mijenja smjer pa se javlja problem što se takav model predobro prilagođava šumovima (smetnjama) u podacima.

$$\begin{aligned} [X \quad Y \quad Z] &= [R \ G \ B \ R^2 \ G^2 \ B^2] \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \\ a_{41} & a_{42} & a_{43} \\ a_{51} & a_{52} & a_{53} \\ a_{61} & a_{62} & a_{63} \end{bmatrix} \\ [X \quad Y \quad Z] &= [R \ G \ B \ R^2 \ G^2 \ B^2 \ R^3 \ G^3 \ B^3] \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \\ a_{41} & a_{42} & a_{43} \\ a_{51} & a_{52} & a_{53} \\ a_{61} & a_{62} & a_{63} \\ a_{71} & a_{72} & a_{73} \\ a_{81} & a_{82} & a_{83} \\ a_{91} & a_{92} & a_{93} \end{bmatrix} \end{aligned}$$

Gore prikazani modeli drugog i trećeg reda obično se ne koriste jer ne opisuju uređaje dovoljno dobro. Veća preciznost postiže se modelima koji koriste međuproekte (npr. dolje prikazani model trećega reda s 11 članova) [52]. Takvi modeli su se u usporedbi s modelima bez međuproprodukata pokazali preciznijima čak i u slučajevima kada je stupanj polinoma s međuproduktima niži od onoga bez međuproprodukata, što je lako razumljivo s obzirom da međuproducti predstavljaju (modeliraju) interakciju među kanalima.

$$[1 \quad R \quad G \quad B \quad RG \quad GB \quad RB \quad R^2 \quad G^2 \quad B^2 \quad RGB]$$

4.2. Domene

Na preciznost modela velik utjecaj ima izbor domena ulaznih i izlaznih vrijednosti. Pogreške modela u načelu su manje što je korelacijska veza između ulaznih i izlaznih vrijednosti jača. Kod pisača i tiskarskih strojeva koji za prostor boja imaju CMYK, prikladnom domenom izlaznih vrijednosti pokazala se domena kolorimetrijskih gustoća. One su definirane na sljedeći način:

$$\begin{bmatrix} D_r \\ D_g \\ D_b \end{bmatrix} = \log \begin{bmatrix} \frac{X_0}{X} \\ \frac{Y_0}{Y} \\ \frac{Z_0}{Z} \end{bmatrix}$$

gdje su $[D_r, D_g \text{ i } D_b]$ kolorimetrijske gustoće, $[X_0, Y_0 \text{ i } Z_0]$ tristimulusne vrijednosti podloge, a $[X, Y \text{ i } Z]$ su tristimulusne vrijednosti izmjerene na obojenim poljima karakterizacijske karte.

Regresijom se određuju koeficijenti matrice A u izrazu:

$$[D_r \quad D_g \quad D_b] = [c \quad m \quad y] A$$

Gdje su $[c, m \text{ i } y]$ udjeli nosioca obojenja.

Kako je za PCS profila izlaznih uređaja prema ICC Specifikaciji moguće odabrati samo XYZ ili L*a*b* prostor boja, vrijednosti predviđene modelom koji koristi neku prikladniju domenu potrebno je preračunati u domenu PCS-a pri popunjavanju tablice boja.

CIE L*a*b* i XYZ prostori boja pokazali su se neprikladnima za korištenje kao domene regresijskih modela pisača i tiskarskih strojeva koji za prostor boja imaju CMYK. Ranija istraživanja su pokazala da se korištenjem kolorimetrijskih gustoća postiže najbolja preciznost, ali i da se odabirom L*a*b* prostora boja postiže veća preciznost u odnosu na XYZ prostor boja. Ta se pojava objašnjava sličnošću iracionalnih funkcija kojima se XYZ vrijednosti preračunavaju u L*a*b* vrijednosti s logaritamskom funkcijom.

Takozvani RGB pisači za prostor boja imaju RGB. Pretvorba u CMYK nosioce obojenja, to jest fizičke kolorante koje pisač koristi, odvija se posredno preko pogonitelja (eng. driver) uređaja. S obzirom da na takvim uređajima nema potpune kontrole, već se pogonitelj tretira kao konzistentna „crna kutija“, preciznost karakterizacije je manja nego kod uređaja s potpunom kontrolom primara. Testiranjem različitih modela utvrđeno je da su regresijski modeli prikladni za karakterizaciju RGB pisača [53].

4.3. Inverzni modeli

Kako je ranije prikazano, profil uređaja sastoji se od tablica boja kojima je opisana transformacija iz prostora boja uređaja u prostor boja neovisan o uređaju i zasebnih tablica kojima je opisan inverzni postupak, to jest transformacija iz prostora boja neovisnog o uređaju u prostor boja uređaja. U prethodnome dijelu prikazani su modeli transformacije iz prostora boja uređaja u prostor boja neovisan o uređaju. Inverzni modeli imaju isti oblik funkcije, samo se mijenjaju uloge zavisnih varijabli u nezavisne i obratno.

$$[R \quad G \quad B] = [X \quad Y \quad Z] \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix}$$

$$D = C \cdot A$$

Koeficijenti matrice A određuju se prema sljedećem izrazu:

$$A = (C^T C)^{-1} C^T D$$

Problem koji se pri tome javlja je da taj model nije idealno inverzan. Ako se modelom za transformaciju boje iz prostora uređaja u PCS za neki određeni RGB ulaz predviđi neki XYZ izlaz, a zatim se te predviđene XYZ vrijednosti iskoriste kao ulaz u inverzni model, on će predvidjeti neke R'G'B' vrijednosti koje se razlikuju od prvotnih RGB vrijednosti.

Razlog iz kojega te razlike nastaju su različiti kriteriji pri određivanju matrice koeficijenata A u dva međusobno inverzna modela. U prvome slučaju, to jest u slučaju transformacije iz prostora uređaja u PCS, traže se takvi koeficijenti matrice A da sume kvadratnih odstupanja empirijskih X, Y i Z vrijednosti od X, Y i Z vrijednosti predviđenih modelom budu minimalne. Kod inverznoga modela zavisne i nezavisne varijable zamjenjuju uloge pa se traže takvi koeficijenti matrice A da sume kvadratnih odstupanja empirijskih R, G i B vrijednosti od R, G i B vrijednosti predviđenih modelom budu minimalne.

Zbog navedenog problema postoje dva načina izrade inverznog modela. Prvi način obuhvaća sabiranje vektora boja koji se formiraju na temelju vrijednosti izmjerena na karakterizacijskim kartama u matrice prema ranije opisanom postupku, samo sa zamijenjenim ulogama nezavisnih i zavisnih varijabli. Pri tome gore navedeni problem može postati jako izražen. Drugi način izrade inverznog modela umanjuje te razlike. On se sastoji u tome da se matrice C i D popunjavaju vektorima formiranim iz vrijednosti predviđenih osnovnim modelom. Za proizvoljan broj RGB vrijednosti osnovnim modelom se predviđaju pripadajuće XYZ vrijednosti. Pri tome je važno da odabrane RGB vrijednosti budu ravnomjerno raspoređene u RGB prostoru. Zatim se prema odabranim RGB vrijednostima formira matrica D, a prema predviđenim XYZ vrijednostima formira se matrica C. Matrica koeficijenata A određuje se prema uobičajenom postupku iz matrica C i D.

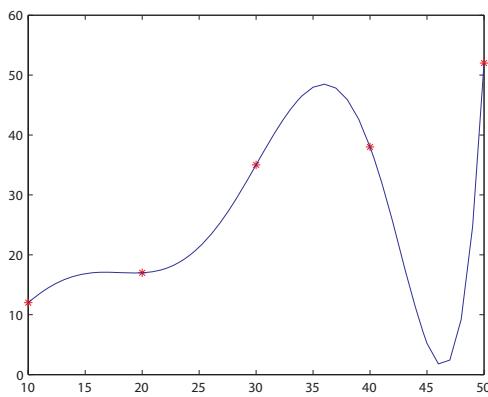
4.4. Pretjerana prilagodba modela

Pretjerana prilagodba modela je neželjena pojava koja se očituje u tome da je model dobro prilagođen podacima za koje su njegovi parametri bili određivani, ali je nedovoljno dobro prilagođen ostalim vrijednostima domene. Razlog te pojave su male fluktuacije vrijednosti u podacima kojima se modeli viših redova prilagođavaju na način da ih prenaglašavaju. Pri tome se javljaju lokalni ekstremi koji mogu znatno odstupati od stvarnih vrijednosti. Empirijski podaci uvijek sadrže određeni udio šuma (54). U kontekstu preciznosti modela pojavljuju se dva izraza, memorizacija i generalizacija. Memorizacija označava prilagođenost modela podacima za koje su njegovi parametri bili određeni, a generalizacija označava prilagođenost modela ostalim vrijednostima domene. Pretjeranu prilagodbu modela moguće je izbjegći odabirom modela nižih redova. No, kako modeli nižih redova mogu biti nedovoljno precizni, potrebno je naći optimalan model, to jest model najvišega reda pri kojemu se još ne javlja pretjerana prilagodba. Jedan od postupaka određivanja optimalnoga modela predlaže prilagodbu najsloženijeg modela (iz skupa odabralih modela) podacima i njegovu evaluaciju. Postupak se nastavlja odbacivanjem jednoga po jednoga člana modela kako bi se formirali manje složeni modeli. Svaki od njih se prilagođava podacima, evaluira, a postupak se zaustavlja kada se nakon posljednjega u nizu sve boljih rezultata javi prvi lošiji. U svrhu verifikacije poboljšanja postignutog odbacivanjem pojedinih članova modela koristi se F-test.

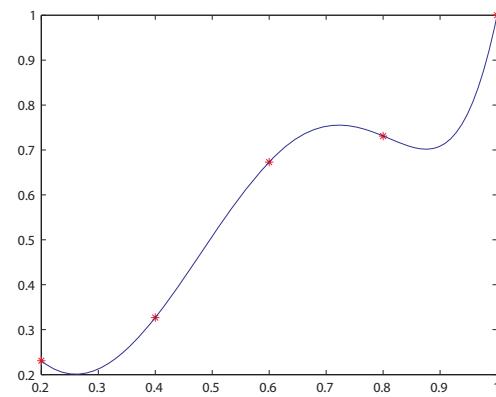
Slika 4.4.1, Prilagodba modela neskaliranim podacima i Slika 4.4.2 prikazuju prilagodbu polinoma sedmoga reda oblika

$$P(x) = a_0 + a_1x + a_2x^2 + a_3x^3 + a_4x^4 + a_5x^5 + a_6x^6 + a_7x^7$$

skupini podataka. Vidljivo je da je polinom vrlo dobro prilagođen podacima za koje su njegovi parametri bili određivani, ali da u ostalim točkama prilično odstupa od generalnog trenda podataka. Lako je uočljivo i to da je skaliranjem podataka na raspon [0,1] postignuta puno bolja prilagodba modela generalnom trendu podataka.



Slika 4.4.1, Prilagodba modela neskaliranim podacima



Slika 4.4.2, Prilagodba modela skaliranim podacima

Problemu pretjerane prilagodbe modela ili prilagodbe šumovima u kontekstu karakterizacije uređaja nije temeljito istražen. Napravljen je niz komparativnih studija u kojima su ispitivane performanse modela

različitih redova na raznim uređajima i uspoređivani rezultati, ali u tim studijama nisu proučavane karakteristike tih uređaja. Prema studiji provedenoj na digitalnim fotoaparatima (55) u kojoj su korišteni nepotpuni modeli trećega reda, navodi se potreban broj od 40 do 60 vrijednosti za treniranje modela kako bi ispitivani modeli imali dovoljnu sposobnost generalizacije. Navodi se i signifikantnost odsječka i članova prvoga reda u modelu. Zaključeno je i kako povećanjem broja članova u modelu raste njegova preciznost, no pažljivijim promatranjem rezultata iznesenih u toj studiji (55) vidljivo je da s povećanjem broja članova postoji generalni trend poboljšanja preciznosti modela, ali i da uvođenjem pojedinih članova dolazi do signifikantnih pogoršanja, čak i udvostručavanja maksimalne greške.

U studiji provedenoj na skenerima (56) autori su ispitali jedan bilinearni model (nepotpuni model drugoga reda) i potpune modele viših redova, do petoga reda. Na svima od pet ispitivanih uređaja najbolje performanse imao je potpuni model četvrtoga reda, a model petoga reda nije bio primjenjiv uz veličinu karte od 228 polja.

Pretjeranu prilagodbu je moguće izbjegići nekim od oblika regularizacije. U eksperimentu opisanom u (57), Tikhonovljeva regularizacija i skraćena dekompozicija singularnih vrijednosti dale su slične rezultate, a obje su uspješno smanjile pretjeranu prilagodbu modela viših redova.

Skupina autora provela je istraživanje utjecaja šuma dodanog L^* , a^* i b^* vrijednostima trodimenzionalne tablice boja. Ispitano je ukupno pet slučajeva s obzirom na omjer razina signala i šuma, a za predviđanje vrijednosti korištene su različite metode interpolacije. Istraživanje je pokazalo da razina dodanog šuma ima velik utjecaj na preciznost predviđanja vrijednosti, mnogo veći od izbora metode interpolacije (58).

4.5. Modifikacije metode najmanjih kvadratnih odstupanja

Prilagodbu modela u smislu najmanjih kvadratnih odstupanja moguća je izvršiti uz razne dodatne uvjete. Skupina autora primjenila je metodu potpunih najmanjih kvadratnih odstupanja (TLS – total least squares) pri određivanju parametara Neugebauerovog modela [59]. Ovdje je potrebno uočiti razliku u odnosu na numeričke regresijske modele kojima je ovo poglavlje posvećeno. Metodom potpunih najmanjih kvadratnih odstupanja funkcija se prilagođava na način da se u obzir uzimaju odstupanja modela od empirijskih podataka i u zavisnim i u nezavisnim varijablama. Ovom metodom postignuta je veća moć predviđanja modela u odnosu na klasičnu metodu najmanjih kvadrata (LS – least squares). Prema [60], TLS je fizikalno prikladniji u odnosu na LS jer uzima u obzir i pogreške mjerena reflektancije primara i pogreške modela, pri čemu je još i matematički fleksibilnija u odnosu na LS.

Pri izradi samih numeričkih, regresijskih modela, uvođeni su razni dodatni uvjeti. U prvoj publikaciji o primjeni regresije s dodatnim uvjetima na karakterizaciju uređaja autori navode mogućnost definiranja većeg broja površina koje se mogu točno povezati s nekim željenim vrijednostima, ali se u studiji zadržavaju na jednoj vrijednosti, bijeloj točki. Ta je studija bila ograničena na ulazne uređaje pa je u ispitivanjima odabrana XYZ domena [61]. Metoda najmanjih kvadrata s očuvanjem bijelog tona (WPPLS – white point preserving least squares) koristi se kako bi se bijela točka točno povezala s njoj pripadajućim XYZ koordinatama [62]. Kod pisača se za domenu obično odabiru kolorimetrijske gustoće pa se bijela povezuje s nulvektorom. Metoda je proširena na način da su se uz uvjet očuvanja bijele točke uveli i uvjet očuvanja prosječne sive točke (GPPLS – grey point preserving least squares) te uvjet očuvanja niza sivih tonova (GSPLS – greyspace preserving least squares). Obje modifikacije, GPPLS i GSPLS dale su bolje rezultate pri evaluaciji akromatskih tonova, ali i nešto lošije ukupne rezultate, što je razumljivo s obzirom da LS metoda daje najmanju sumu kvadratnih odstupanja [63]. Ipak, svrha GPPLS i GSPLS metoda bila je vjerna reprodukcija sivih tonova s obzirom na osjetljivost ljudskoga oka na odstupanja upravo u tim tonovima, a u tome su obje metode dale znatna poboljšanja.

Metoda dvostupanjskih najmanjih kvadrata (2SLS – Two-stage least squares) u jednome je radu [64] primjenjena na polinomu drugoga reda na način da su zasebno određeni koeficijenti modela za transformaciju iz CMY u domenu kolorimetrijskih gustoća i K u domenu kolorimetrijskih gustoća. Za četverobojna (CMYK) polja određeni su dodatni koeficijenti, to jest izgrađen je model miješanja CMY i K komponenti. S obzirom da se radilo o polinomu niskoga reda, obična LS metoda je dala prilično loše rezultate, a 2SLS metodom dobiveni su prilično zadovoljavajući rezultati.

Kada se govori o regresijskim metodama, potrebno je posebno izdvojiti lokalne regresijske metode. Kod lokalnih regresijskih metoda prostor se dijeli na manje dijelove i lokalni modeli prilagođavaju podacima unutar tih manjih dijelova. Postoje razne modifikacije koje poboljšavaju rezultate dobivene lokalnom regresijom poput regularizacije i metode čelijske regresije koja uzima u obzir pravilan raspored podataka [65; 66].

5. Metode eksperimenata

5.1. Materijali i uređaji korišteni u istraživanju

Istraživanje je provedeno na četiri pisača različitih proizvođača i tehnologija ispisa. Dva pisača koriste termalnu inkjet tehnologiju ispisa, jedan koristi piezoelektričnu inkjet tehnologiju ispisa, a posljednji za tehnologiju ispisa koristi lasersku elektrofotografiju. Jedan termalni inkjet pisač i laserski pisač za ispis koriste četiri boje (CMYK), a preostala dva inkjet pisača za ispis koriste šest boja (CcMmYK). Svaki od navedenih pisača korišten je kao RGB uređaj. Ispis je izvršen na dvije vrste podloge, što je ukupno osam različitih slučajeva, odnosno osam različitih procesa. Podaci o pisačima dobiveni su ispisom standardne TC 9.18 RGB karte boja koja se isporučuje uz komercijalni softver i mjerjenjem ispisane karte refleksijskim spektrofotometrom s geometrijom mjerjenja $45^\circ/0^\circ$. Mjerjenjem su dobivene standardne tekstualne datoteke u kojima je sadržano 918 RGB vrijednosti ulaza u uređaj i njima pripadajuće izmjerene izlazne vrijednosti spektralnih reflektancija za izvor svjetlosti D50.

5.2. Ispitivanja modela uređaja

U prvome dijelu rada ispitane su performanse pet osnovnih oblika modela koji se često mogu naći u do sada objavljenim komparativnim studijama. Ostali modeli formirani su dodavanjem članova različitih redova najsloženijem od pet osnovnih modela čime su formirani nepotpuni modeli, to jest modeli koji ne sadrže sve moguće članove svih redova do maksimalnoga. Performanse tih modela evaluirane su na nekoliko domena kako bi se utvrdilo ovisi li signifikantnost dodanih članova o njihovom redu i broju.

U drugome dijelu rada ispitana je mogućnost optimizacije modela postupkom eliminacije skupina članova i postupkom eliminacije pojedinih članova. Iako je mogla biti korištena metoda dodavanja članova, odabrana je metoda eliminacije članova koja se općenito smatra boljom zbog „efekta tlačitelja“, to jest efekta da je neka varijabla signifikantna samo uz prisustvo neke druge varijable [67; 68]. Za tu je svrhu napisan poseban program. Postupak se sastojao u tome da su performanse maksimalnoga modela, to jest modela koji sadrži sve članove, evaluirane na nezavisnom skupu podataka (u ovome radu skup B). Zatim je iz maksimalnoga modela eliminirana jedna po jedna skupina članova i evaluirane su performanse tih modela. Suma kvadratnih odstupanja vrijednosti predviđenih maksimalnim modelom od empirijskih uspoređena je se sa sumom kvadratnih odstupanja svakoga od reduciranih modela F-testom. Najmanje signifikantan član je odbačen i postupak ponavljan za na taj način dobivene reducirane modele dok više niti jedan od članova nije bio nesignifikantan na nivou značajnosti 10%. Time je dobiven optimizirani, reducirani model, a postupak je proveden za svaki od osam procesa. Cilj te analize bilo je utvrđivanje postoji li pravilnost među eliminiranim, odnosno zadržanim članovima i je li signifikantnost članova moguće predvidjeti prema karakteristikama podataka o uređaju. Određivanje reda modela poseban je problem i nije dio ovoga istraživanja. Maksimalni modeli za svaki od pojedinih uređaja određeni su konverzijom slike iz $L^*a^*b^*$ prostora u RGB prostor boja. Umjesto ispisa tih slika, zbog uštede materijala su pregledane konverzijom u $L^*a^*b^*$ prostor pomoću ICC profila kreiranog komercijalnim softverom. Na taj je način utvrđeno nastaju li na slikama pogreške uzrokovane pretjeranom prilagodbom modela, odnosno utvrđeni su maksimalni modeli za pojedine uređaje. Važno je napomenuti da su početne $L^*a^*b^*$ slike bile preslikane na gamute uređaja apsolutnim

kolorimetrijskim načinom. To znači da su veliki dijelovi slike sadržavali boje s granica gamuta uređaja, a poznato je da se u tim dijelovima javljaju najveća odstupanja.

5.3. Postupci evaluacije modela

Evaluacija modela koji predviđaju vrijednosti u prostorima boja neovisnima o uređaju za zadane RGB ulazne vrijednosti provedena je izračunom odstupanja vrijednosti predviđenih modelom od izmjerjenih vrijednosti. Korištena su dva skupa vrijednosti. Prvi skup vrijednosti su karakterizacijski podaci dobiveni mjerjenjem karte boja i taj će se skup u nastavku navoditi kao skup A. S obzirom da je taj skup podataka upravo onaj kojima su regresijski modeli prilagođavani, rezultati evaluacije modela na tom skupu vrijednosti mogu biti vrlo dobri, dok na nekim drugim vrijednostima model može biti vrlo neprecizan. Stoga je provedena dodatna evaluacija sa skupom B koji sadrži 918 vrijednosti različitih od onih sadržanih u skupu A. Skup B formiran je odabirom 918 RGB vrijednosti, ispisom tih vrijednosti na uređaju i mjerjenjem njima pripadajućih odaziva spektrofotometrom. Postupak evaluacije jednak je za oba skupa. Za svaku od 918 RGB vrijednosti ulaza u uređaj modelom su predviđene njima pripadajuće vrijednosti u $L^*a^*b^*$ prostoru boja. Za svaku od 918 predviđenih vrijednosti izračunato je kolorimetrijsko odstupanje ΔE od pripadajućih izmjerjenih vrijednosti. Rezultat opisanog postupka je skup od 918 vrijednosti odstupanja modela od empirijskih podataka. Iz tih su vrijednosti izdvojeni minimalno odstupanje, maksimalno odstupanje, aritmetička sredina odstupanja, medijan odstupanja i interval pouzdanosti. Distribucije odstupanja prikazane su histogramima jer ti prikazi daju najpotpunije informacije o prilagođenosti pojedinih modela empirijskim podacima. Uobičajena je aproksimacija χ^2 razdiobom [69].

Postupak evaluacije inverznih modela, to jest modela koji predviđaju RGB ulazne vrijednosti potrebne za postizanje zadanog odaziva je složeniji. Za 918 ciljanih $L^*a^*b^*$ vrijednosti odaziva modelom su predviđeni odgovarajući RGB ulazi. Predviđeni RGB ulazi ispisani su na uređaju i njima pripadajući odazivi izmjereni su spektrofotometrom. Odstupanja izmjerjenih vrijednosti od ciljanih obrađena su i izražena na način identičan onome koji je proveden kod modela koji predviđaju vrijednosti u prostorima boja neovisnima o uređaju za zadane RGB ulazne vrijednosti.

6. Eksperiment: Evaluacija osnovnih modela uređaja

U ovome dijelu rada prikazani su rezultati evaluacija pet osnovnih modela na različitim domenama. Pod osnovnim modelima podrazumijevaju se oni nižih redova koji se često nalaze u ranijim istraživanjima.

6.1. Domena kolorimetrijskih gustoća i L*a*b* domena

U ovome dijelu rada prikazani su rezultati evaluacija osnovnih modela na domeni kolorimetrijskih gustoća i na L*a*b* domeni u jedinicama L*a*b* sustava.

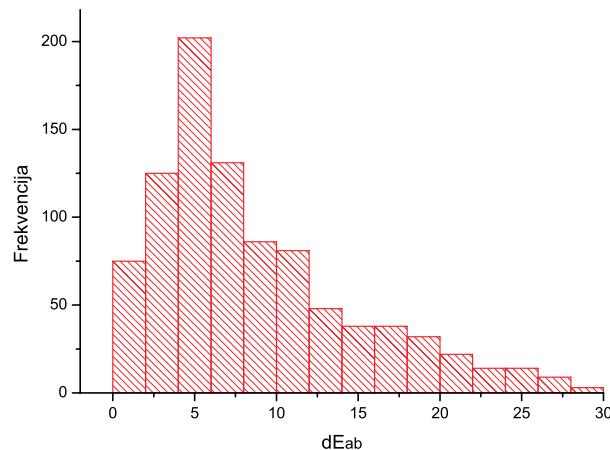
SKUP A

Model trećega reda s 11 članova

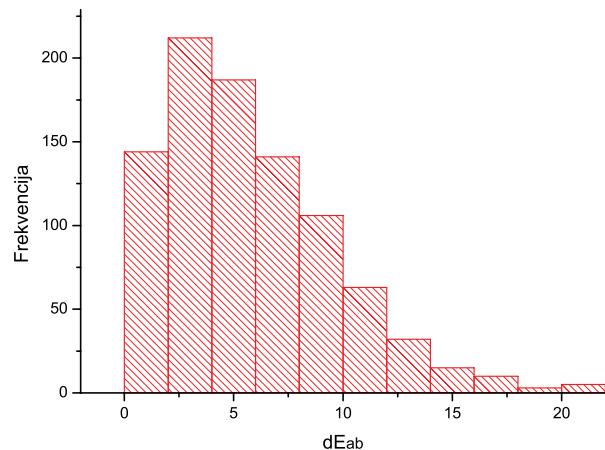
[1 R G B RG GB RB R² G² B² RGB]

Tabela 6.1. Odstupanja modela 11-3 od empirijskih podataka

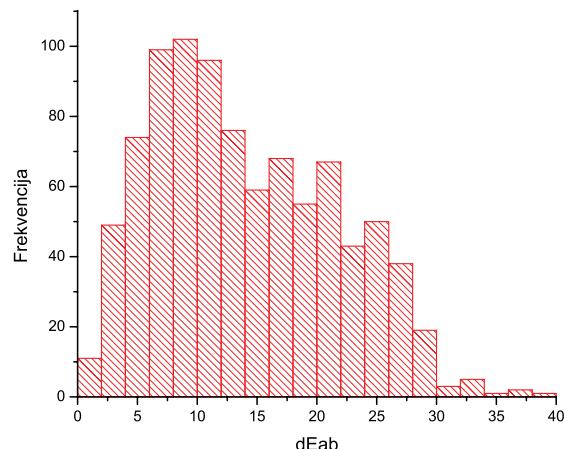
	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	8,66	0,17	6,78	28,42	0,79
Lab->RGB	918	5,77	0,12	5,07	21,19	0,50
RGB->D	918	14,02	1,56	12,61	38,01	0,98



Slika 6.1.1. Histogram odstupanja za model 11-3 RGB->Lab



Slika 6.1.2. Histogram odstupanja za model 11-3 Lab->RGB



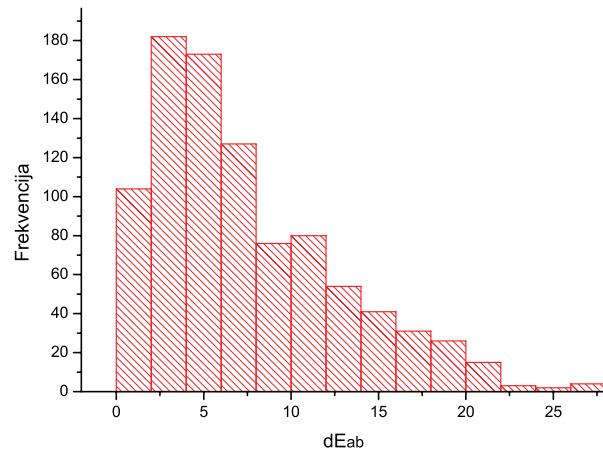
Slika 6.1.3. Histogram odstupanja za model 11-3 RGB->D

Model trećega reda s 14 članova

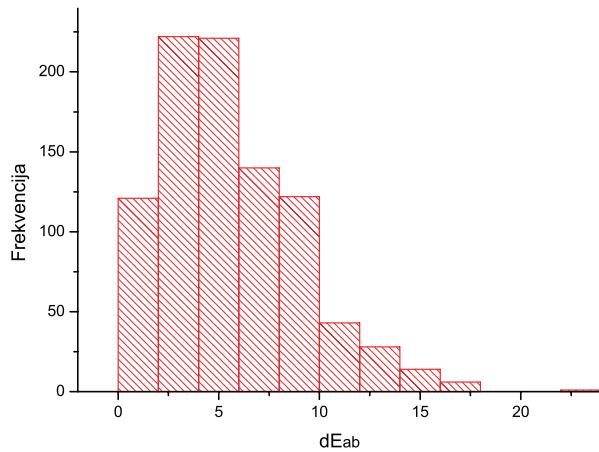
$$[1 \ R \ G \ B \ RG \ GB \ RB \ R^2 \ G^2 \ B^2 \ RGB \ R^3 \ G^3 \ B^3]$$

Tabela 6.2, Odstupanja modela 14-3 od empirijskih podataka

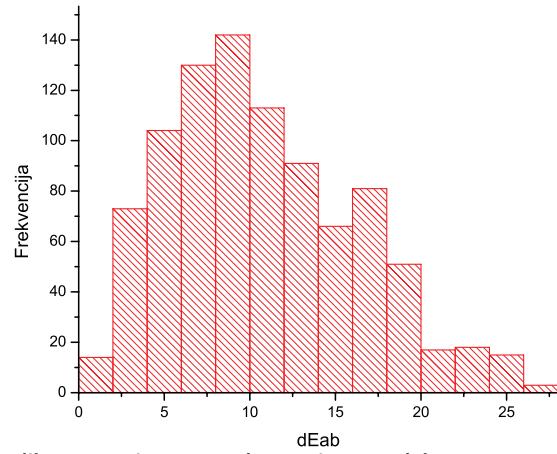
	N – broj polja	$\bar{\Delta E_{ab}}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	7,46	0,15	6,01	26,96	0,68
Lab->RGB	918	5,54	0,18	4,93	23,25	0,44
RGB->D	918	10,78	1,07	9,91	27,34	0,71



Slika 6.1.4, Histogram odstupanja za model 14-3 RGB->Lab



Slika 6.1.5, Histogram odstupanja za model 14-3 Lab->RGB



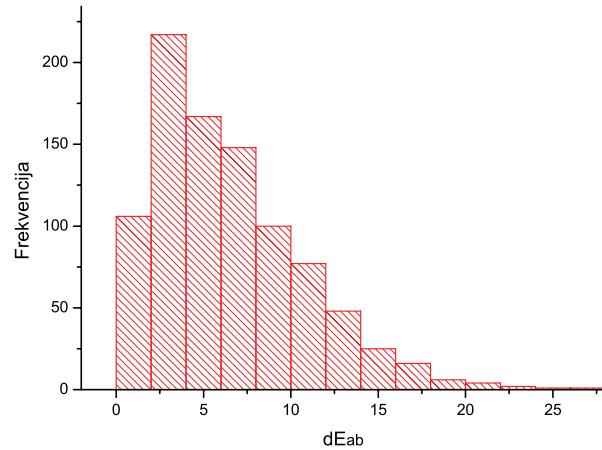
Slika 6.1.6, Histogram odstupanja za model 14-3 RGB->D

Model trećega reda sa 17 članova

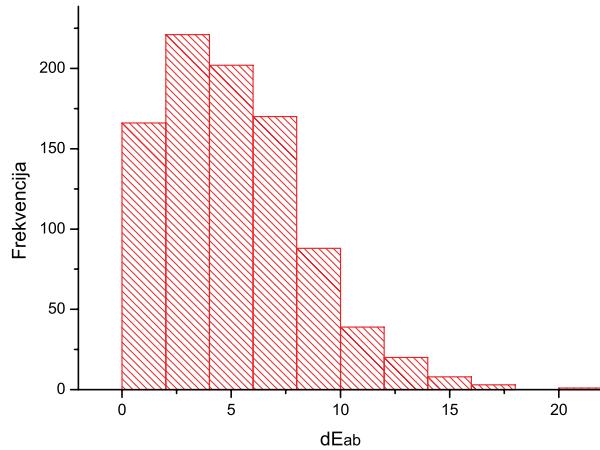
$$[1 \ R \ G \ B \ RG \ GB \ RB \ R^2 \ G^2 \ B^2 \ RGB \ R^2G \ G^2B \ B^2R \ R^3 \ G^3 \ B^3]$$

Tabela 6.3, Odstupanja modela 17-3 od empirijskih podataka

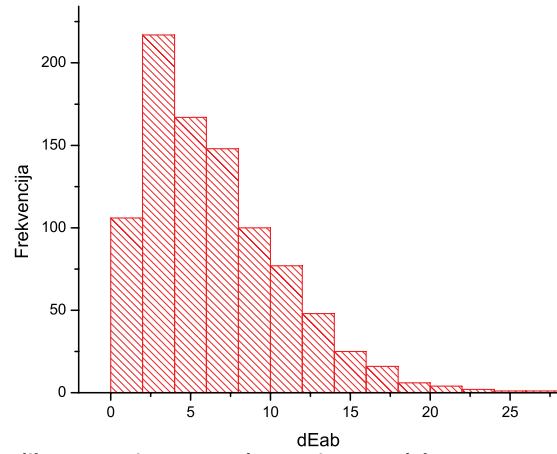
	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	6,52	0,13	5,58	26,63	0,55
Lab->RGB	918	5,12	0,14	4,65	20,34	0,41
RGB->D	918	6,52	0,13	5,58	26,64	0,55



Slika 6.1.7, Histogram odstupanja za model 17-3 RGB->Lab



Slika 6.1.8, Histogram odstupanja za model 17-3 Lab->RGB



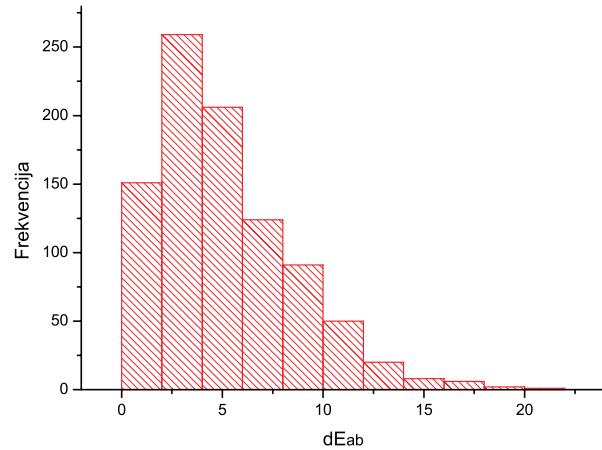
Slika 6.1.9, Histogram odstupanja za model 17-3 RGB->D

Model trećega reda s 20 članova

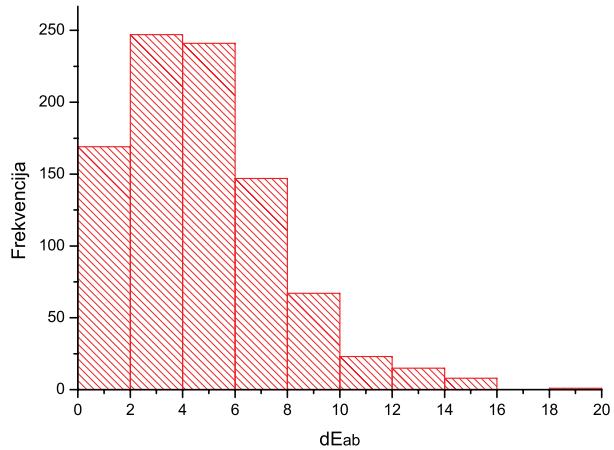
[1 R G B RG GB RB R^2 G^2 B^2 RGB R^2G G^2B B^2R R^2B G^2R B^2G R^3 G^3 B^3]

Tabela 6.4, Odstupanja modela 20-3 od empirijskih podataka

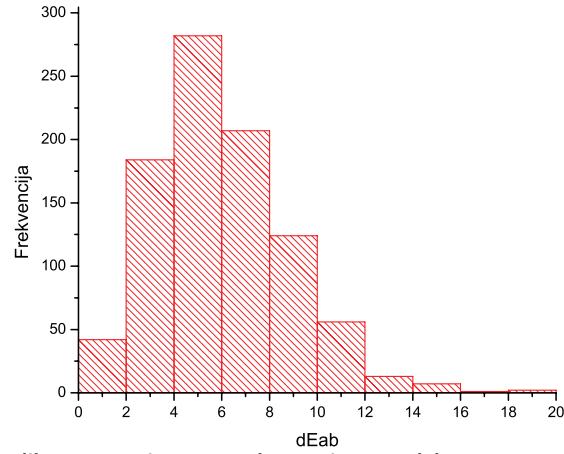
	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	5,15	0,17	4,36	21,90	0,44
Lab->RGB	918	4,70	0,15	4,32	18,07	0,38
RGB->D	918	6,01	0,79	5,66	18,82	0,36



Slika 6.1.10, Histogram odstupanja za model 20-3 RGB->Lab



Slika 6.1.11, Histogram odstupanja za model 20-3 Lab->RGB



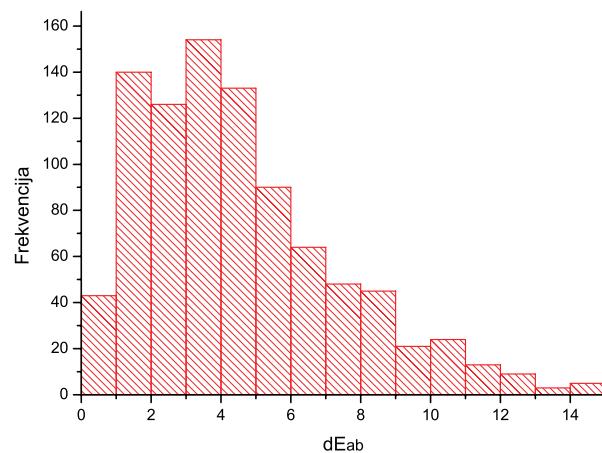
Slika 6.1.12, Histogram odstupanja za model 20-3 RGB->D

Model četvrtoga reda s 23 člana

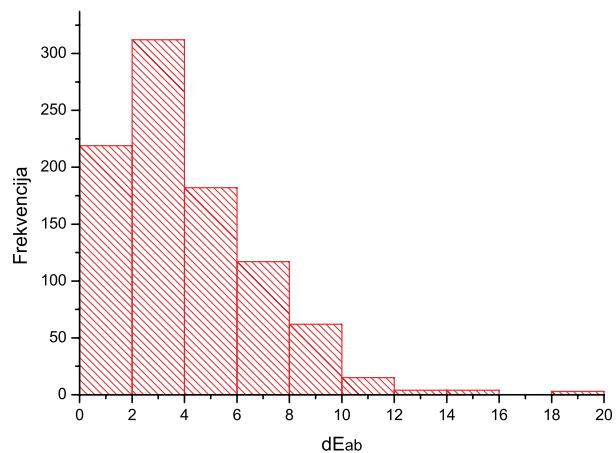
[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B RGB²]

Tabela 6.5, Odstupanja modela 23-4 od empirijskih podataka

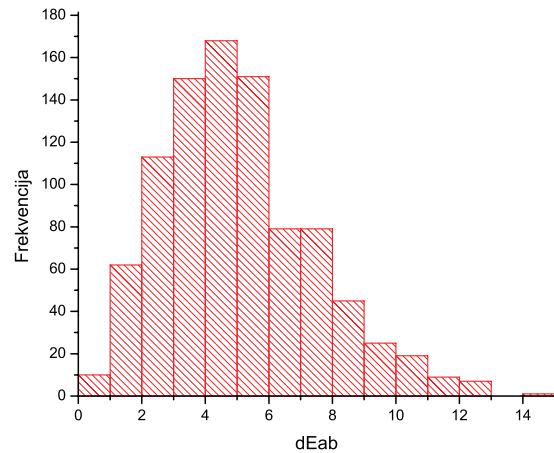
	N – broj polja	\bar{dEab}	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	4,51	0,21	3,98	14,65	0,37
Lab->RGB	918	4,11	0,17	3,44	18,80	0,36
RGB->D	918	5,02	0,69	4,68	14,68	0,31



Slika 6.1.13, Histogram odstupanja za model 20-4 RGB->Lab



Slika 6.1.14, Histogram odstupanja za model 20-4 Lab->RGB



Slika 6.1.15, Histogram odstupanja za model 20-4 RGB->D

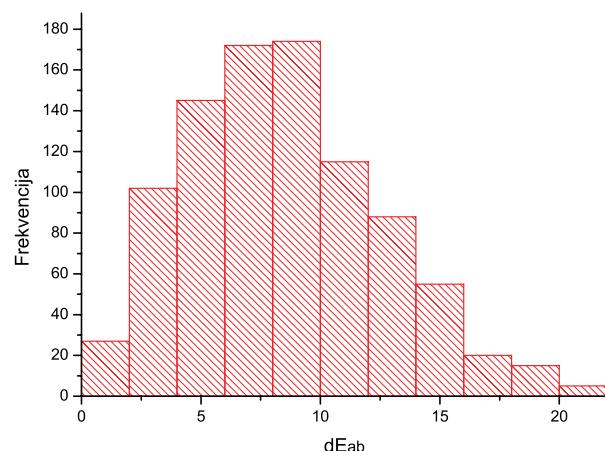
SKUP B

Model trećega reda s 11 članova

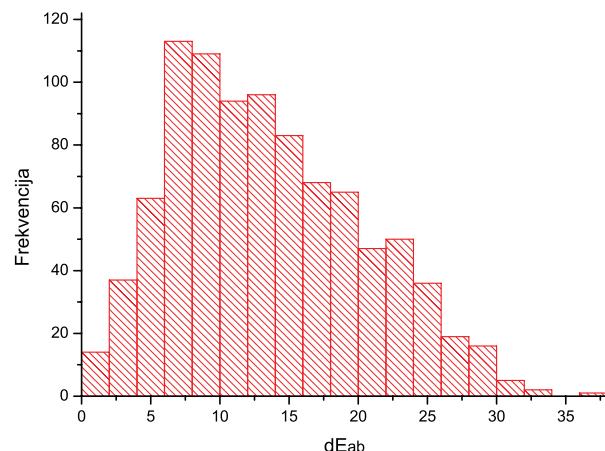
[1 R G B RG GB RB R² G² B² RGB]

Tabela 6.6, Odstupanja modela 11-3 od empirijskih podataka

	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	8,45	0,48	8,15	20,94	0,53
RGB->D	918	13,47	0,64	12,62	37,18	0,88



Slika 6.1.16, Histogram odstupanja za model 11-3 RGB->Lab



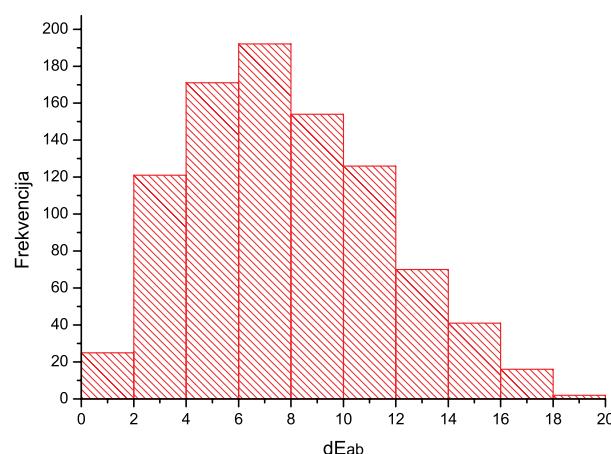
Slika 6.1.17, Histogram odstupanja za model 11-3 RGB->D

Model trećega reda s 14 članova

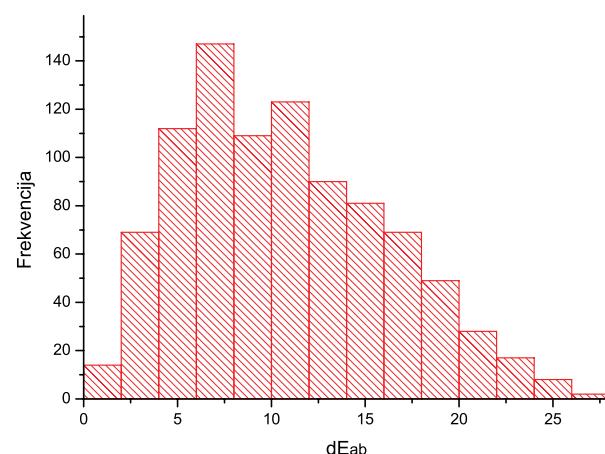
[1 R G B RG GB RB R² G² B² RGB R³ G³ B³]

Tabela 6.7, Odstupanja modela 14-3 od empirijskih podataka

	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	7,86	0,50	7,57	18,70	0,47
RGB->D	918	10,76	0,33	10,13	26,10	0,70



Slika 6.1.18, Histogram odstupanja za model 14-3 RGB->Lab



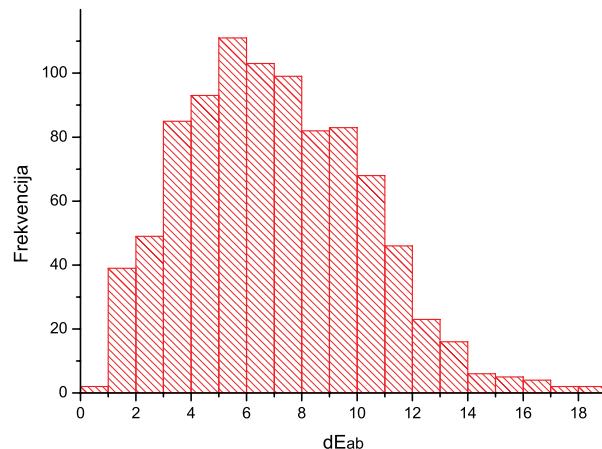
Slika 6.1.19, Histogram odstupanja za model 14-3 RGB->D

Model trećega reda sa 17 članova

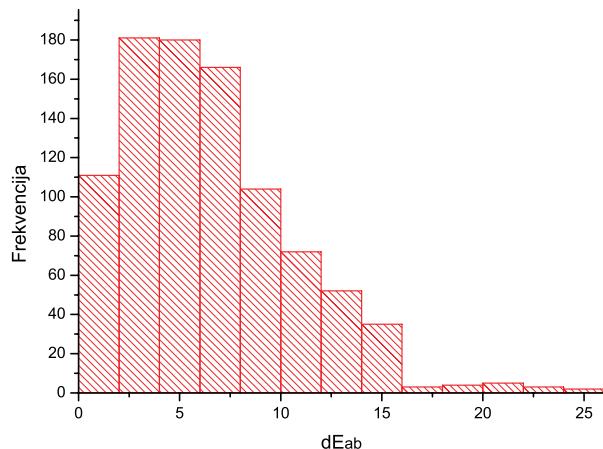
[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R³ G³ B³]

Tabela 6.8, Odstupanja modela 17-3 od empirijskih podataka

	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	7,04	0,92	6,72	18,38	0,42
RGB->D	918	6,55	0,25	5,89	25,17	0,54



Slika 6.1.20, Histogram odstupanja za model 17-3 RGB->Lab



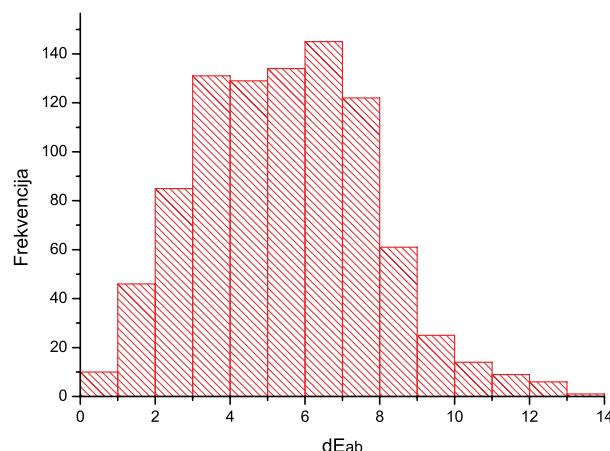
Slika 6.1.21, Histogram odstupanja za model 17-3 RGB->D

Model trećega reda s 20 članova

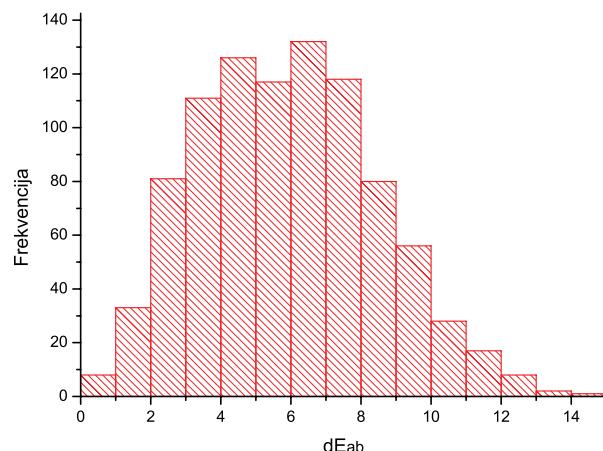
[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³]

Tabela 6.9, Odstupanja modela 20-3 od empirijskih podataka

	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	5,46	0,32	5,43	13,08	0,30
RGB->D	918	5,91	0,34	5,87	14,01	0,33



Slika 6.1.22, Histogram odstupanja za model 20-3 RGB->Lab



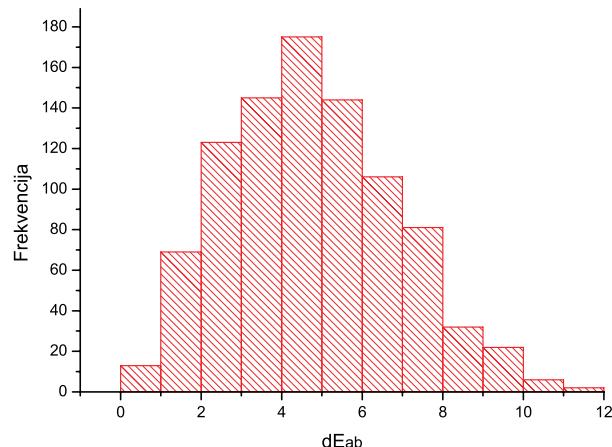
Slika 6.1.23, Histogram odstupanja za model 20-3 RGB->D

Model četvrtoga reda s 23 člana

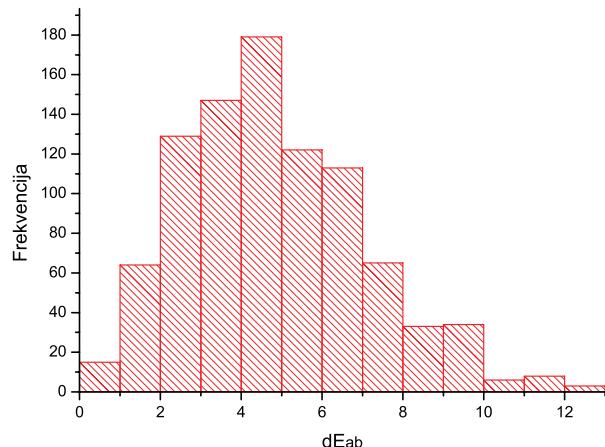
[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B RGB²]

Tabela 6.10, Odstupanja modela 23-4 od empirijskih podataka

	N – broj polja	$\bar{\Delta}E_{ab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	4,76	0,09	4,67	11,87	0,27
RGB->D	918	4,83	0,40	4,53	12,70	0,29



Slika 6.1.24, Histogram odstupanja za model 23-4 RGB->Lab



Slika 6.1.25, Histogram odstupanja za model 11-3 RGB->D

Pet promatranih modela pokazali su se preciznijima na L*a*b* domeni nego na domeni kolorimetrijskih gustoća. Prateći rezultate u tablicama uočljivo je i to da je na L*a*b* domeni precizniji Lab->RGB model. Taj je rezultat interesantan zbog toga što se evaluacija RGB->Lab modela provodi samo predviđanjem L*a*b* vrijednosti za određene RGB ulaze te usporedbom tih vrijednosti s izmjerenim, dok se evaluacija Lab->RGB modela provodi ispisom RGB vrijednosti predviđenih modelom na pisaču te usporedbom dobivenih L*a*b* odaziva s ciljanim vrijednostima. Pri ispisu se javlja problem ponovljivosti rezultata pa preciznost Lab-RGB modela ovisi o varijabilnosti u procesu ispisa.

Razdioba odstupanja na skupu podataka A nije se znatno mijenjala povećanjem složenosti modela na L*a*b* domeni. Na domeni kolorimetrijskih gustoća razdioba odstupanja znatnije se promjenila uvođenjem interakcijskih članova trećega reda, ali se nakon toga više nije znatno mijenjala. Razlog je taj što jednostavniji modeli nisu bili dovoljno dobro prilagođeni trendu podataka. Osim promjene razdiobe (Slika 6.1.6 i Slika 6.1.9), uočljiva je i drastična promjena mjera centralne tendencije odstupanja (Tabela 6.2 i Tabela 6.3). Takva nagla promjena nije zabilježena ni na domeni kolorimetrijskih gustoća između neka druga dva modela, niti na Lab domeni. Evaluacije modela na domenama RGB->Lab i RGB->D pokazale su se dovoljnima pa se evaluacije inverznih modela u daljem istraživanju napuštaju zbog njihove složenosti.

Razdioba odstupanja na nezavisnom skupu podataka B nije se znatno mijenjala povećanjem složenosti modela na L*a*b* domeni. Slično kao i kod skupa A, na domeni kolorimetrijskih gustoća došlo je do

znatne promjene razdiobe odstupanja uvođenjem interakcijskih članova trećega reda (Slika 6.1.19 i Slika 6.1.21). Uočljiva je i znatna promjena mjera centralne tendencije odstupanja (Tabela 6.7 i Tabela 6.8). Dobiveni rezultati daju naznake da je odnos nezavisnih i zavisnih varijabli (ulaza u uređaj i izlaza iz uređaja) složeniji na domeni kolorimetrijskih gustoća nego na L*a*b* domeni. Takvo tumačenje proizlazi iz činjenice da se povećanjem složenosti modela na L*a*b* domeni preciznost povećavala postupno za male iznose, bez naglih promjena, a i razdioba odstupanja je zadržavala sličan oblik i nije se bitno mijenjala. Na domeni kolorimetrijskih gustoća prijelazom s modela trećega reda s 14 članova na model trećega reda sa 17 članova došlo je do znatne promjene u razdiobi odstupanja i znatnog smanjenja mjera centralne tendencije odstupanja. Posebno treba izdvojiti da je ta pojava uočena na zavisnom skupu podataka A, što znači da mu se jednostavniji modeli na domeni kolorimetrijskih gustoća nisu uspjeli prilagoditi dovoljno dobro.

Najbolji rezultat postignut je s modelom četvrtoga reda s 23 člana na L*a*b* domeni (Tabela 6.5), ali se taj rezultat ne smatra zadovoljavajućim. Cilj je smanjiti medijan i srednju vrijednost odstupanja ispod ΔE_3 .

6.2. Domena skaliranih L*a*b* vrijednosti

U ovome dijelu rada prikazani su rezultati evaluacija modela na L*a*b* domeni normaliziranoj na raspon vrijednosti [0,1], pri čemu 1 odgovara L = 100, odnosno a,b = 127.

SKUP A

Model trećega reda s 11 članova

[1 R G B RG GB RB R² G² B² RGB]

Tabela 6.11, Odstupanja modela 11-3 od empirijskih podataka

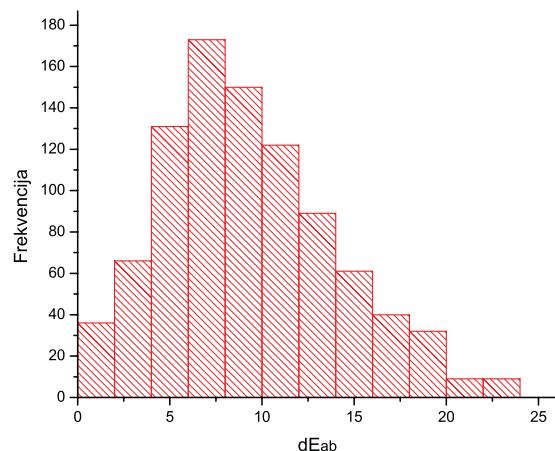
	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	9,31	0,78	8,57	23,99	0,60

Model trećega reda s 14 članova

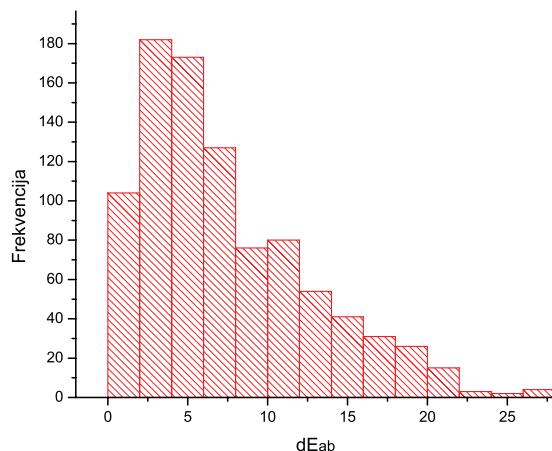
[1 R G B RG GB RB R² G² B² RGB R³ G³ B³]

Tabela 6.12, Odstupanja modela 14-3 od empirijskih podataka

	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	8,00	0,79	7,59	20,19	0,49



Slika 6.2.1, Histogram odstupanja za model 11-3 RGB->Lab



Slika 6.2.2, Histogram odstupanja za model 14-3 RGB->Lab

Usporedbom rezultata dobivenih dvama modelima na L*a*b* domeni s vrijednostima normaliziranim na skalu [0,1] s rezultatima istih modela na L*a*b* domeni s L*a*b* jedinicama vidljivo je da su u slučaju modela trećega reda s 11 članova medijan i aritmetička sredina odstupanja povećani, a maksimalno odstupanje je smanjeno (Tabela 6.11 i Tabela 6.1). Ista kretanja uočljiva su i u slučaju modela trećega reda s 14 članova (Tabela 6.12 i Tabela 6.2).

Model trećega reda sa 17 članova

[1 R G B RG GB RB R^2 G^2 B^2 RGB R^2G G^2B B^2R R^3 G^3 B^3]

Tabela 6.13, Odstupanja modela 17-3 od empirijskih podataka

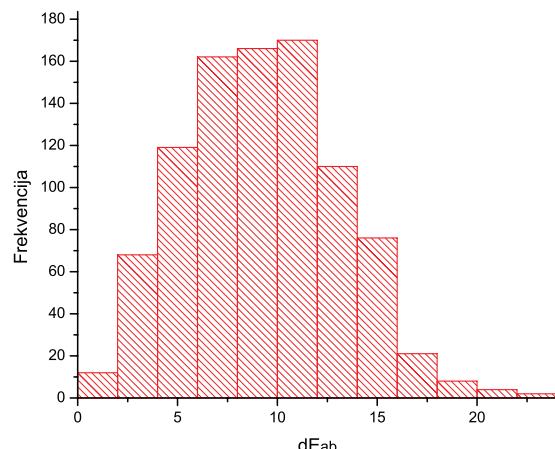
	N – broj polja	$\bar{ΔEab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	9,30	0,82	9,13	22,78	0,50

Model trećega reda s 20 članova

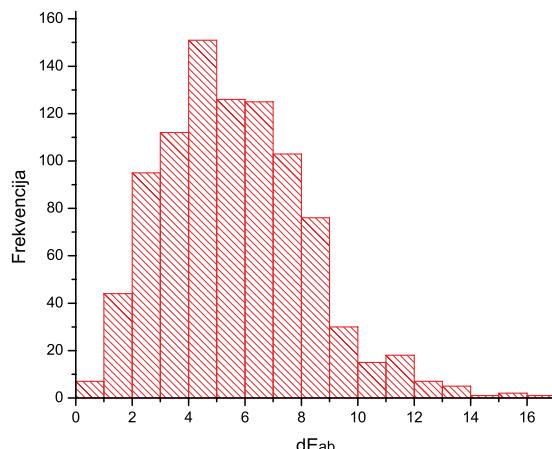
[1 R G B RG GB RB R^2 G^2 B^2 RGB R^2G G^2B B^2R R^2B G^2R B^2G R^3 G^3 B^3]

Tabela 6.14, Odstupanja modela 20-3 od empirijskih podataka

	N – broj polja	$\bar{ΔEab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	5,63	0,68	5,36	16,36	0,33



Slika 6.2.3, Histogram odstupanja za model 17-3 RGB->Lab



Slika 6.2.4, Histogram odstupanja za model 20-3 RGB->Lab

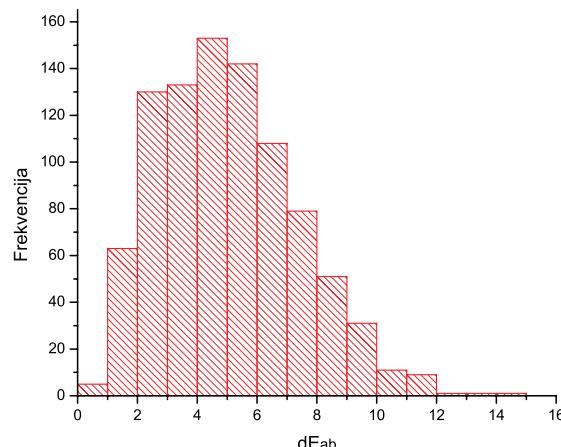
Usporedbom rezultata dobivenih dvama modelima na $L^*a^*b^*$ domeni s vrijednostima normaliziranim na skalu [0,1] s rezultatima istih modela na $L^*a^*b^*$ domeni s $L^*a^*b^*$ jedinicama vidljivo je da su u slučaju modela trećega reda sa 17 članova medijan i aritmetička sredina odstupanja povećani, a maksimalno odstupanje je smanjeno (Tabela 6.13 i Tabela 6.3). U slučaju modela trećega reda s 20 članova medijan, aritmetička sredina i maksimalno odstupanje su smanjeni (Tabela 6.14 i Tabela 6.4). Te su promjene vidljive i u prikazima razdiobe odstupanja (Slika 6.2.1 do Slika 6.2.5), a može se uočiti i to da se povećanjem složenosti modela oblik razdiobe odstupanja na skaliranoj $L^*a^*b^*$ domeni ne mijenja značajno, kao što je bio slučaj i s izvornom $L^*a^*b^*$ domenom. Usporedbom performansi modela na dvije različite domene uočljivo je da su njihove razlike slične za sva četiri do sada ispitana modela.

Model četvrtoga reda s 23 člana

[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B RGB²]

Tabela 6.15, Odstupanja modela 23-4 od empirijskih podataka

	N – broj polja	\bar{dEab}	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	5,05	0,27	4,80	14,93	0,30



Slika 6.2.5, Histogram odstupanja za model 23-4 RGB->Lab

Usporedbom rezultata dobivenih dvama modelima na L*a*b* domeni s vrijednostima normaliziranim na skalu [0,1] s rezultatima istih modela na L*a*b* domeni s L*a*b* jedinicama vidljivo je da su u slučaju modela četvrtoga reda s 23 člana medijan i aritmetička sredina odstupanja povećani, a maksimalno odstupanje je smanjeno. Ti su rezultati dosljedni ranije iznesenim rezultatima za prva četiri modela, osim za model trećega reda sa 17 članova pa je moguće reći da su razlike u performansama svih pet osnovnih modela bile slične na dvama domenama. Razlike se, dakle, očituju u promjeni razdiobe odstupanja između dvije promatrane domene, a sličnost je u zadržavanju oblika razdiobe povećanjem složenosti modela na obje promatrane domene. Iako je model trećega reda sa 17 članova u prethodnim slučajevima imao bolje performanse u odnosu na jednostavnije modele, na domeni skaliranih L*a*b* vrijednosti imao je slabije performanse, posebno s obzirom na centralne tendencije odstupanja. Pri tome je značajno da se on sastoji od nepotpunog bloka interakcijskih članova, a uvođenje ostatka članova u model s 20 članova dovelo je do znatnih poboljšanja. Iz iznesenoga je vidljivo kako su se u gotovo svim slučajevima medijan i aritmetička sredina odstupanja povećali, a maksimum odstupanja se smanjio u odnosu na rezultate iz dijela 6.1. Kao i u prethodnom dijelu ispitivanja modela na domenama kolorimetrijskih gustoća i na L*a*b* domeni u L*a*b* jedinicama, i u ovome se dijelu preciznost modela povećavala s redom i brojem članova polinoma. No, ovdje je potrebno uočiti da se o povećanju preciznosti može govoriti kao o generalnom trendu, jer vrijednosti osciliraju sa složenošću modela (slučaj modela trećega reda sa 17 članova). S obzirom da je u prethodnom dijelu zaključeno da se niti jedan od ispitanih modela ne može smatrati dovoljno preciznim, a u ovome su dijelu, to jest na skaliranoj L*a*b* domeni odstupanja povećana, može se zaključiti da preciznost niti jednoga od pet ispitanih modela nije dovoljna ni na kojoj od do sada ispitanih domena.

SKUP B

Model trećega reda s 11 članova

[1 R G B RG GB RB R² G² B² RGB]

Tabela 6.16, Odstupanja modela 11-3 od empirijskih podataka

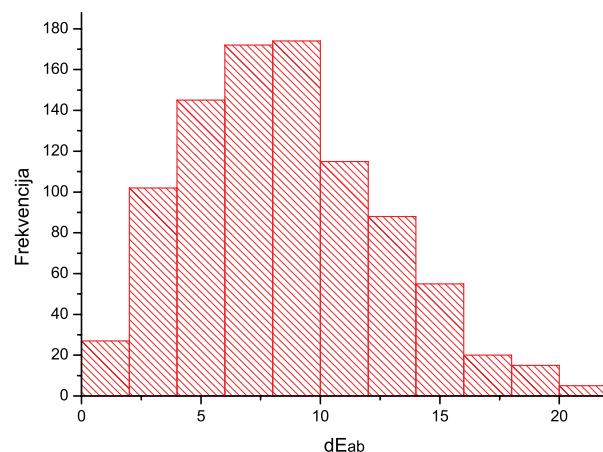
	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	8,45	0,48	8,15	20,94	0,53

Model trećega reda s 14 članova

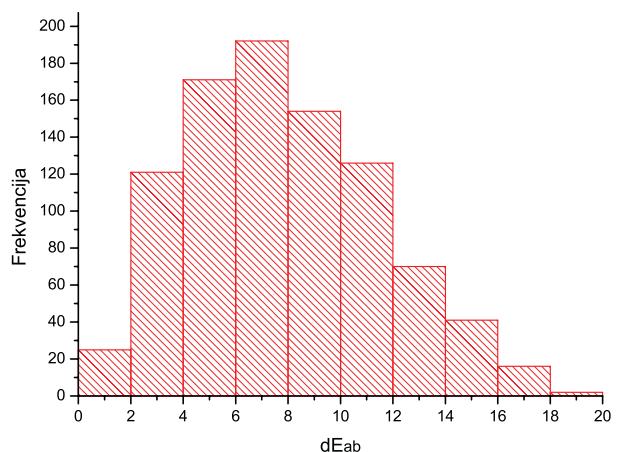
[1 R G B RG GB RB R² G² B² RGB R³ G³ B³]

Tabela 6.17, Odstupanja modela 14-3 od empirijskih podataka

	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	7,86	0,50	7,57	18,70	0,47



Slika 6.2.6, Histogram odstupanja za model 11-3 RGB->Lab



Slika 6.2.7, Histogram odstupanja za model 14-3 RGB->Lab

Usporedbom rezultata dobivenih dvama modelima na L*a*b* domeni s vrijednostima normaliziranim na skalu [0,1] s rezultatima istih modela na L*a*b* domeni s L*a*b* jedinicama dobiveni su jednaki rezultati. Distribucije odstupanja su vrlo slične. To je interesantno s obzirom da su na skupu A uočene razlike.

Usporedbom rezultata s rezultatima iste domene za skup A uočljivo je da su na nezavisnom skupu (skup B) postignuti bolji rezultati.

Model trećega reda sa 17 članova

[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R³ G³ B³]

Tabela 6.18, Odstupanja modela 17-3 od empirijskih podataka

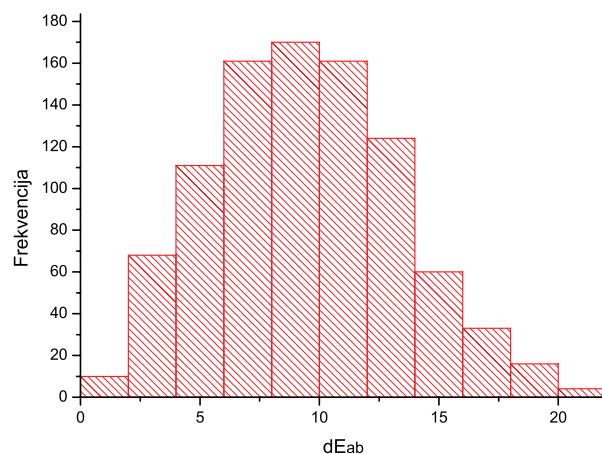
	N – broj polja	$\bar{\Delta}Eab$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	9,44	0,59	9,37	21,56	0,51

Model trećega reda s 20 članova

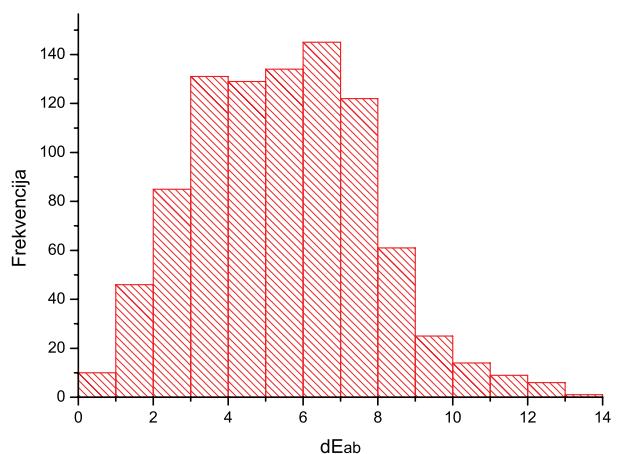
[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³]

Tabela 6.19, Odstupanja modela 20-3 od empirijskih podataka

	N – broj polja	$\bar{\Delta}Eab$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	5,46	0,32	5,43	13,08	0,30



Slika 6.2.8, Histogram odstupanja za model 20-3 RGB->Lab



Slika 6.2.9, Histogram odstupanja za model 20-3 RGB->Lab

Model trećega reda sa 17 članova na skaliranoj L*a*b* domeni postigao je lošije rezultate nego na izvornoj L*a*b* domeni. Taj je rezultat interesantan jer su ostali modeli na dvije promatrane domene postigli jednake rezultate, ali je i sličan slučaju koji se s tim modelom pojavio na skupu podataka A.

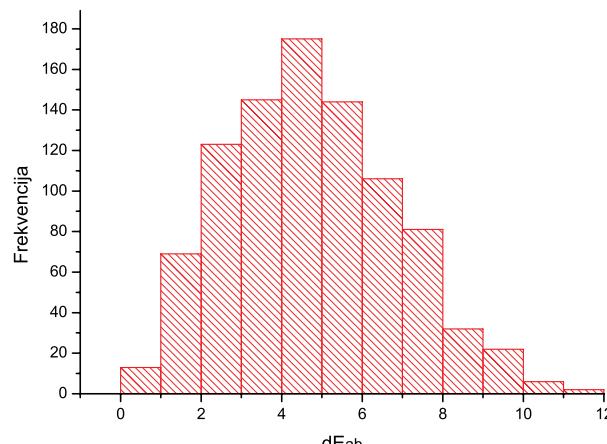
Model trećega reda sa 17 članova na skaliranoj L*a*b* domeni postigao je lošije rezultate na skupu B nego na skupu A pa se i po tome razlikuje od ostalih modela iz ovoga dijela rada.

Model četvrtoga reda s 23 člana

[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B RGB²]

Tabela 6.20, Odstupanja modela 23-4 od empirijskih podataka

	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	4,76	0,09	4,67	11,87	0,27



Slika 6.2.10, Histogram odstupanja za model 23-4 RGB->Lab

Model četvrtoga reda s 23 člana je na skaliranoj L*a*b* domeni postigao rezultate jednake onima na izvornoj L*a*b* domeni. Na skupu B rezultati evaluacije bili su bolji nego na skupu A. Ti su rezultati slični onima dobivenim ostalim modelima iz ovoga dijela rada, osim u slučaju modela trećega reda sa 17 članova.

Iz iznesenih rezultata je vidljivo da su se na skaliranoj L*a*b* domeni modeli lošije prilagođavali podacima kojima su trenirani, ali su se bolje prilagođavali nezavisnom skupu podataka, to jest bolje su opisivali generalni trend podataka. Iako ta pojava nije uobičajena niti je uočena na drugim domenama, sasvim je sigurno da se nije javio problem pretjerane prilagodbe. Rezultati dobiveni do ovoga dijela istraživanja daju naznake je skaliranje L*a*b* domene dovelo do veće raspršenosti podataka, a do sada ispitani modeli nisu bili dovoljno složeni da bi došlo do pretjerane prilagodbe. Ova naznaka biti će potvrđena ili osporena u daljem dijelu istraživanja evaluacijom složenijih modela.

Općeniti zaključci

Iz rezultata evaluacije pet osnovnih modela vidljivo je da se najpreciznijim pokazao najsloženiji model na skaliranoj L*a*b* domeni i to na oba skupa vrijednosti, A i B. Isti model na domeni kolorimetrijskih gustoća dao je neznatno lošije rezultate. Ipak, s manje složenim modelima na domeni kolorimetrijskih gustoća postignuti su znatno lošiji rezultati u odnosu na izvornu i skaliranu L*a*b* domenu.

Na skaliranoj L*a*b* domeni na skupu A postignuta su znatno manja maksimalna odstupanja u odnosu na izvornu, ali su kod jednostavnijih modela srednja vrijednost i medijan bili nešto veći, a sa složenošću modela su se približavali rezultatima izvorne L*a*b* domene. Na skupu B su dobiveni vrlo slični rezultati na skaliranoj i izvornoj L*a*b* domeni.

Na skupu A odstupanja opadaju sa složenošću modela na svim domenama. Jedina iznimka je 17-3 model na skaliranoj L*a*b* domeni. Slični su rezultati dobiveni i na skupu B.

Vrijedi uočiti da uvođenje linearnih članova nije dovelo do znatnijih poboljšanja na L*a*b* domenama, dok je na domeni kolorimetrijskih gustoća njihovo uvođenje znatno poboljšalo moć predviđanja modela, pogotovo s obzirom na maksimum odstupanja. Važno je uočiti i to da uvođenje nepotpunog bloka međuprodukata nije dovelo do znatnijeg poboljšanja moći predviđanja modela na L*a*b* domeni i da je na skaliranoj L*a*b* domeni čak dovelo i do smanjenja moći predviđanja, ali je zato na domeni kolorimetrijskih gustoća njegovim uvođenjem medijan odstupanja gotovo prepolovljen.

Iz histograma odstupanja je vidljivo da se sa složenošću modela razdioba greške ne mijenja bitno, te da je za domenu kolorimetrijskih gustoća razdioba odstupanja više simetrična u odnosu na L*a*b* domene. Vidljivo je i to da su razdiobe za nezavisni skup podataka manje simetrične u odnosu na skup A i da su na nezavisnom skupu podataka razdiobe odstupanja sličnije između tri promatrane domene u odnosu na skup A.

7. Eksperiment: Modeli s dodatnim međuproduktima

U ovome dijelu rada izneseni su rezultati evaluacija modela koji sadrže međuproekte viših redova. Njihovo uvođenje u model može povećati ili smanjiti njegovu preciznost, a učinak može biti različit na različitim domenama. Ispitani su sljedeći međuprojekti, dodani na model četvrtoga reda s 23 člana:

$$R^2G^2B^2$$

$$R^3G^3B^3$$

$$R^2G^2B^2 \quad i \quad R^3G^3B^3$$

$$R^3GB \quad RG^3B \quad RGB^3$$

$$R^3G^2B^2 \quad R^2G^3B^2 \quad R^2G^2B^3$$

$$R^3G \quad G^3B \quad B^3R \quad R^3B \quad G^3R \quad B^3G$$

$$R^3G^2B \quad R^2G^3B \quad R^2GB^3 \quad R^3GB^2 \quad RG^3B^2 \quad RG^2B^3$$

Rezultati evaluacija modela s gore navedenim dodatnim članovima izneseni su u jednakom redoslijedu.

Odabrani su različiti oblici interakcijskih članova (međuprojekti), s istim i s različitim potencijama nad kanalima kako bi se utvrdilo postoji li značajne razlike u pogledu njihovog utjecaja na moć predviđanja modela.

7.1. Domena kolorimetrijskih gustoća i L*a*b* domena

U ovome dijelu rada prikazani su rezultati evaluacija osnovnih modela na domeni kolorimetrijskih gustoća i na L*a*b* domeni u jedinicama L*a*b* sustava.

Vrijedi napomenuti da su podaci ulaznog i izlaznog prostora pri korištenju domene kolorimetrijskih gustoća uvijek skalirani na mali raspon zbog primjene logaritamske funkcije. Skaliranje podataka, kao što je spomenuto u dijelu 4.4, ima značajne učinke na pojavu pretjerane prilagodbe i time na preciznost modela. Stoga pri promatranju rezultata iznesenih u nastavku treba uzeti u obzir da je domena kolorimetrijskih gustoća skalirana na mali raspon vrijednosti, dok L*a*b* domena u jedinicama L*a*b* sustava obuhvaća razmjerno velik raspon vrijednosti. Stoga se događa da neki modeli viših redova na domeni kolorimetrijskih gustoća daju vrlo dobre rezultate, a na L*a*b* domeni u jedinicama L*a*b* sustava daju vrlo loše rezultate. Taj je efekt moguće uočiti i u prethodnom dijelu, na rezultatima evaluacije osnovnih modela. Neki modeli viših redova slabo su se prilagođavali podacima na L*a*b* domeni u jedinicama L*a*b* sustava, ali su dali dobre rezultate na skaliranoj L*a*b*domeni, odnosno na domeni kolorimetrijskih gustoća upravo zbog smanjenja raspona podataka u ulaznom i izlaznom prostoru.

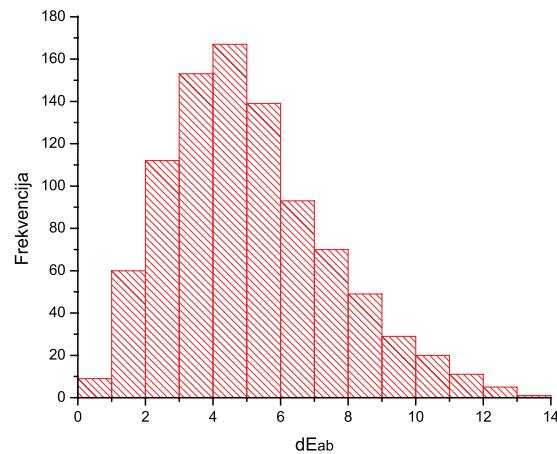
SKUP A

Model šestoga reda s 24 člana

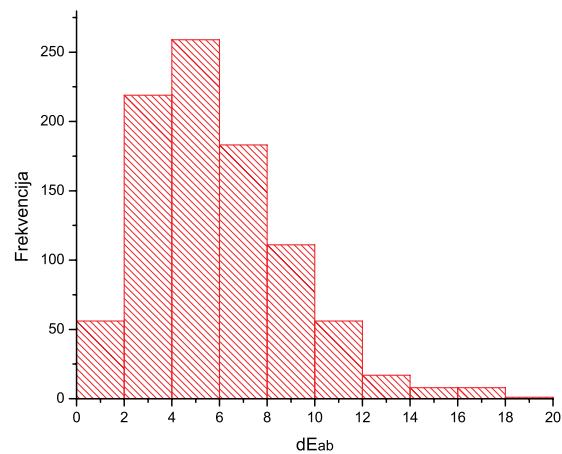
[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B RGB² R²G²B²]

Tabela 7.1, Odstupanja modela 24-6 od empirijskih podataka

	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->D	918	5,08	0,55	4,74	13,65	0,31
RGB->Lab	918	5,86	0,55	5,41	18,37	0,39



Slika 7.1.1, Histogram odstupanja za model 24-6 RGB->D



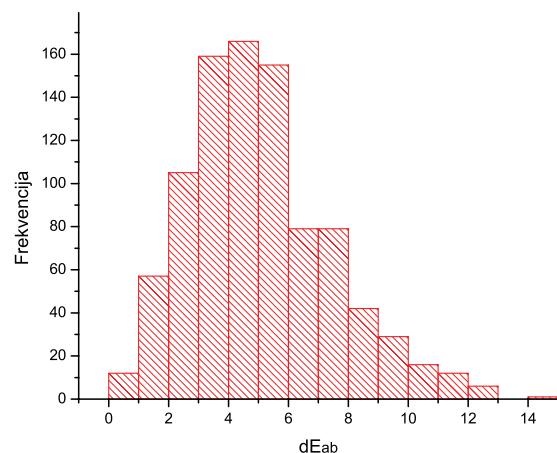
Slika 7.1.2, Histogram odstupanja za model 24-6 RGB->Lab

Model devetoga reda s 24 člana

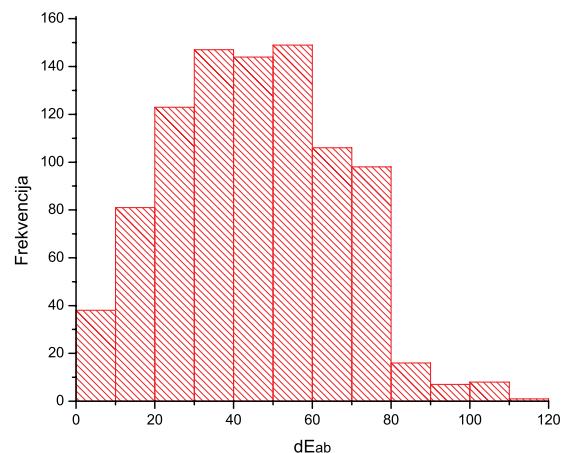
[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B RGB² R³G³B³]

Tabela 7.2, Odstupanja modela 24x3 od empirijskih podataka

	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->D	918	5,05	0,09	4,68	14,61	0,31
RGB->Lab	918	45,30	2,20	45,83	110,14	2,74



Slika 7.1.3, Histogram odstupanja za model 24-9 RGB->D



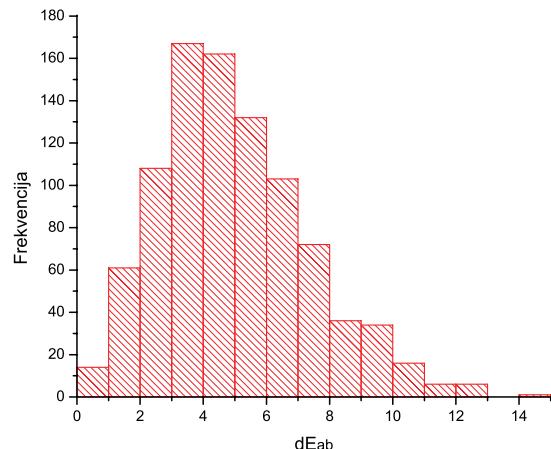
Slika 7.1.4, Histogram odstupanja za model 24-9 RGB->Lab

Model devetoga reda s 25 članova

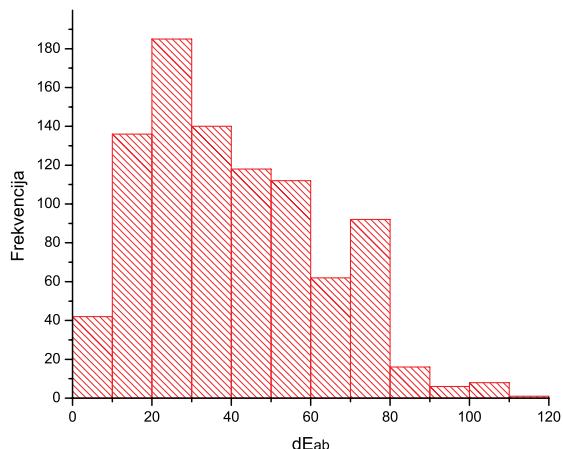
[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B RGB² R²G²B² R³G³B³]

Tabela 7.3, Odstupanja modela 25-9 od empirijskih podataka

	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->D	918	4,98	0,20	4,67	14,21	0,31
RGB->Lab	918	40,37	2,57	36,36	110,06	2,86



Slika 7.1.5, Histogram odstupanja za model 25-9 RGB->D



Slika 7.1.6, Histogram odstupanja za model 25-9 RGB->Lab

Modeli šestoga i devetoga reda s 24 člana na domeni kolorimetrijskih gustoća (Tabela 7.1, Slika 7.1.1) i (Tabela 7.2, Slika 7.1.3) nisu dali značajno različite rezultate od osnovnog modela s 23 člana. Na L*a*b* domeni u slučaju modela šestoga reda s 24 člana (Tabela 7.1, Slika 7.1.2) sva su odstupanja povećana, a u slučaju modela devetoga reda s 24 člana (Tabela 7.2, Slika 7.1.4) došlo je do ekstremnih odstupanja. U oba slučaja se može reći da je prekoračen maksimalni dozvoljeni red modela. Može se zaključiti da međuproizvodi korišteni u promatranim modelima na ispitanim domenama ne postižu poboljšanja pa ih ne bi trebalo koristiti. Isti zaključak vrijedi i za model s 25 članova (Tabela 7.3, Slika 7.1.5, Slika 7.1.6) u kojem su bila uključena oba međuproizvoda koji su pojedinačno ispitani u modelima s 24 člana.

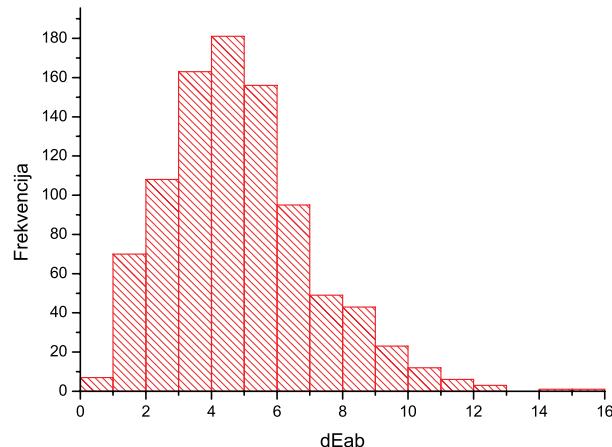
Modeli petoga i sedmoga reda s 26 članova na domeni kolorimetrijskih gustoća (Tabela 7.4, Slika 7.1.7) i (Tabela 7.5, Slika 7.1.9) nisu dali značajno različite rezultate od osnovnog modela s 23 člana. U slučaju modela petoga reda s 24 člana medijan i maksimalno odstupanje povećani su za oko $\Delta E 0,7$, a u slučaju modela sedmoga reda s 24 člana maksimalno odstupanje je smanjeno za oko $\Delta E 1$ u odnosu na osnovni model s 23 člana. Na L*a*b* domeni u slučaju modela petoga reda s 24 člana (Tabela 7.4, Slika 7.1.8) nisu zabilježena znatnija odstupanja od rezultata dobivenih osnovnim modelom s 23 člana. Srednja vrijednost i medijan odstupanja uvećani su za oko $\Delta E 0,5$, a maksimalno odstupanje uvećano je za oko $\Delta E 1$. U slučaju modela sedmoga reda s 26 članova (Tabela 7.5, Slika 7.1.10) došlo je do znatnog povećanja odstupanja u odnosu na osnovni model s 23 člana.

Model petoga reda s 26 članova

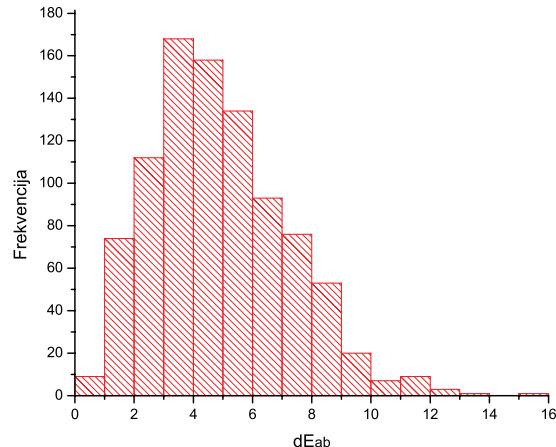
[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B
RGB² R³GB RG³B RGB³]

Tabela 7.4, Odstupanja modela 26-5 od empirijskih podataka

	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->D	918	4,85	0,25	4,67	15,40	0,29
RGB->Lab	918	4,91	0,72	4,59	15,64	0,30



Slika 7.1.7, Histogram odstupanja za model 26-5 RGB->D



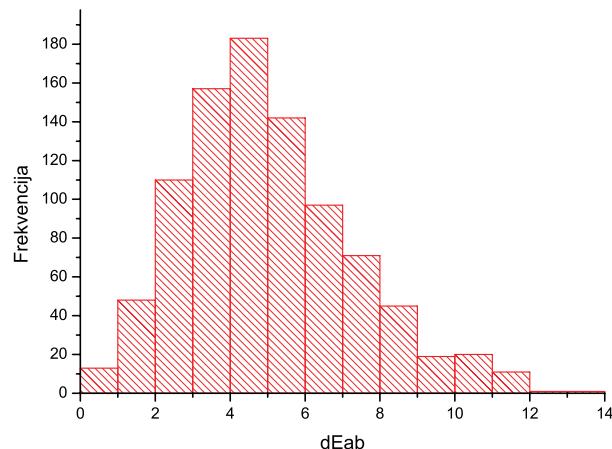
Slika 7.1.8, Histogram odstupanja za model 26-5 RGB->Lab

Model sedmoga reda s 26 članova

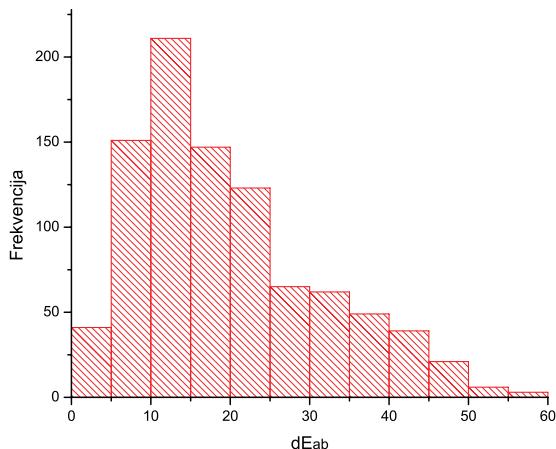
[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B
RGB² R³G²B² R²G³B² R²G²B³]

Tabela 7.5, Odstupanja modela 26-7 od empirijskih podataka

	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->D	918	5,01	0,29	4,66	13,67	0,29
RGB->Lab	918	19,63	0,97	16,77	55,56	1,49



Slika 7.1.9, Histogram odstupanja za model 26-7 RGB->D



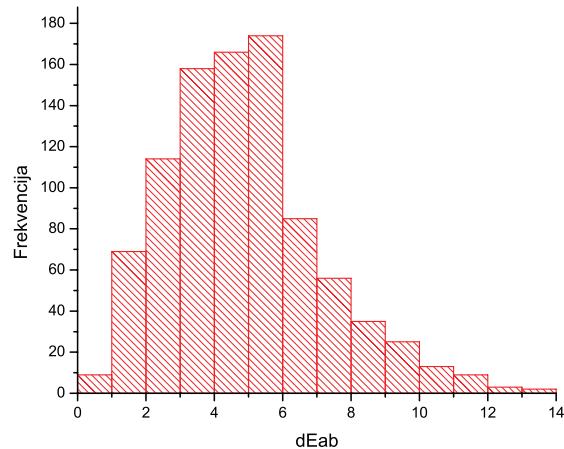
Slika 7.1.10, Histogram odstupanja za model 26-7 RGB->Lab

Model četvrtoga reda s 29 članova

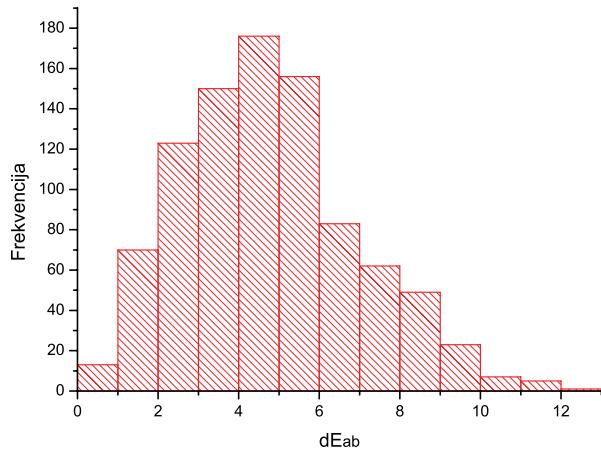
[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B
RGB² R³G G³B B³R R³B G³R B³G]

Tabela 7.6, Odstupanja modela 29-4 od empirijskih podataka

	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->D	918	4,85	0,52	4,61	13,54	0,29
RGB->Lab	918	4,76	0,34	4,51	12,88	0,28



Slika 7.1.11, Histogram odstupanja za model 29-4 RGB->D



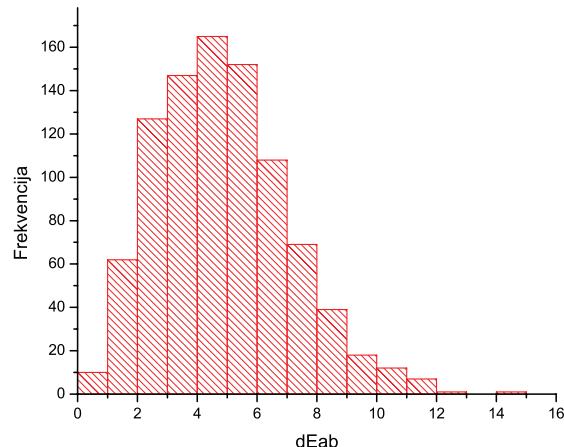
Slika 7.1.12, Histogram odstupanja za model 29-4 RGB->Lab

Model petoga reda s 29 članova

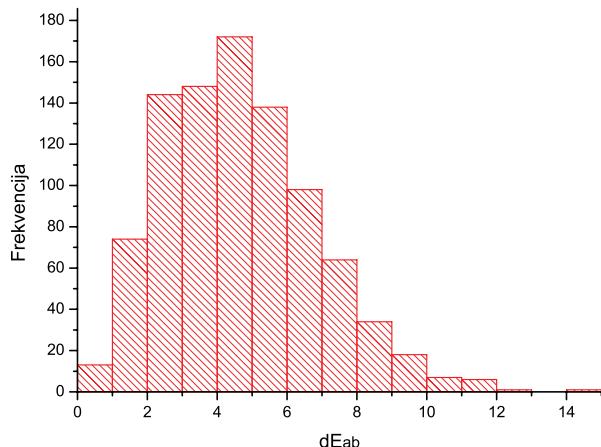
[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B
RGB² R³G² G³B² B³R² R³B² G³R² B³G²]

Tabela 7.7, Odstupanja modela 29-5 od empirijskih podataka

	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->D	918	4,87	0,47	4,72	14,89	0,28
RGB->Lab	918	4,66	0,24	4,45	14,52	0,28



Slika 7.1.13, Histogram odstupanja za model 29-5 RGB->D



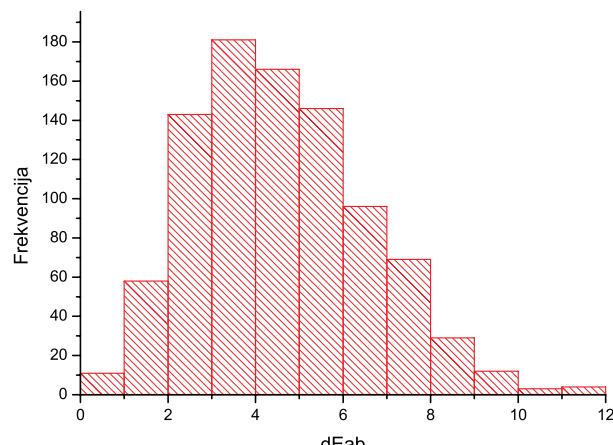
Slika 7.1.14, Histogram odstupanja za model 29-5 RGB->Lab

Model šestoga reda s 29 članova

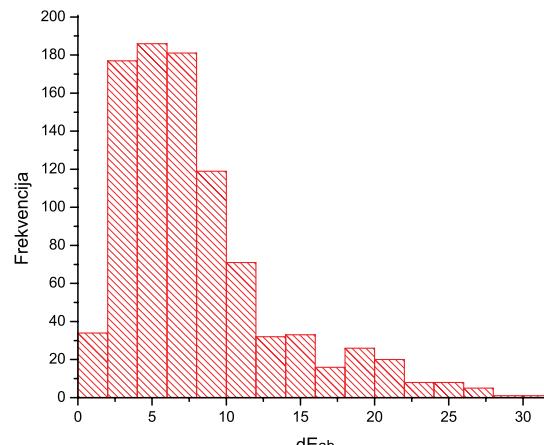
[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B RGB² R³G²B R²G³B R²GB³ R³GB² RG³B² RG²B³]

Tabela 7.8, Odstupanja modela 29-6 od empirijskih podataka

	N – broj polja	$\bar{\Delta}E_{ab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->D	918	4,59	0,54	4,39	11,58	0,26
RGB->Lab	918	7,91	0,67	6,56	30,19	0,68



Slika 7.1.15, Histogram odstupanja za model 29-6 RGB->D



Slika 7.1.16, Histogram odstupanja za model 29-6 RGB->Lab

Modelom četvrtoga reda s 29 članova na domeni kolorimetrijskih gustoća (Tabela 7.6, Slika 7.1.11) neznatno su umanjeni medijan i srednje odstupanje, a maksimalno odstupanje smanjeno je za približno ΔE 1. Na L*a*b* domeni (Slika 7.1.12) srednje odstupanje povećano je za ΔE 0,2, medijan je povećan za ΔE 0,5, a maksimalno odstupanje smanjeno je za ΔE 0,8.

Modelom petoga reda s 29 članova na domeni kolorimetrijskih gustoća (Tabela 7.7, Slika 7.1.13) nisu postignuti značajno različiti rezultati od osnovnog modela s 23 člana. Na L*a*b* domeni (Slika 7.1.14) medijan odstupanja povećan je za približno ΔE 0,5, a ostala odstupanja su povećana za neznatan iznos.

Modelom šestoga reda s 29 članova na domeni kolorimetrijskih gustoća (Tabela 7.8, Slika 7.1.15) aritmetička sredina odstupanja smanjena je za približno ΔE 0,4, medijan odstupanja smanjen je za približno ΔE 0,3, a maksimalno odstupanje je smanjeno za približno ΔE 3. Na L*a*b* domeni (Tabela 7.1, Slika 7.1.16) sva su odstupanja znatno povećana.

Iz iznesenih je rezultata vidljivo da na L*a*b* domeni uvođenjem članova viših od petoga reda dolazi do znatnijih odstupanja i to na skupu podataka A, to jest na skupu kojim su modeli trenirani. Takvi slučajevi nisu navedeni u ranijim istraživanjima pa se mogu protumačiti kao posljedica formiranja modela koji ne sadrže članove svih redova do najvišega.

Oblik razdiobe odstupanja nije se bitno mijenjao na domeni kolorimetrijsih gustoća, a na L*a*b* domeni se znatnije mijenjao u slučajevima u kojima su se javila ekstremna odstupanja.

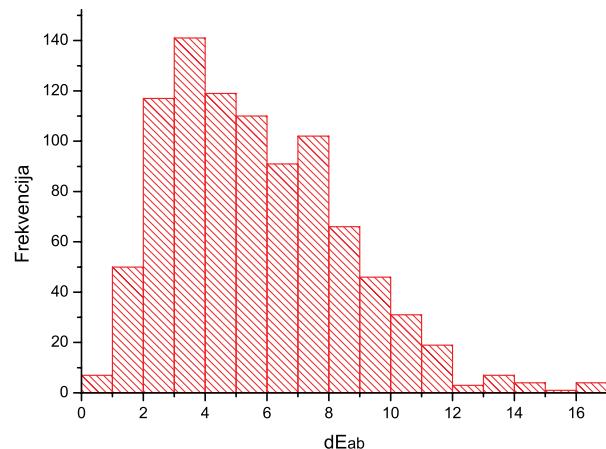
SKUP B

Model šestoga reda s 24 člana

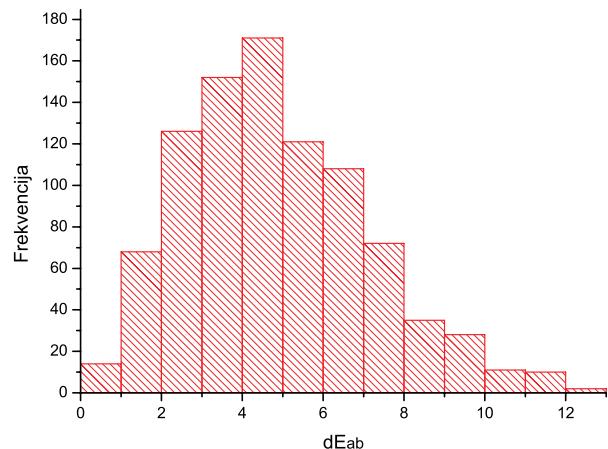
[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B RGB² R²G²B²]

Tabela 7.9, Odstupanja modela 24-6 od empirijskih podataka

	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	5,62	0,35	5,16	16,48	0,37
RGB->D	918	4,86	0,15	4,56	12,52	0,29



Slika 7.1.17, Histogram odstupanja za model 24-6 RGB->Lab



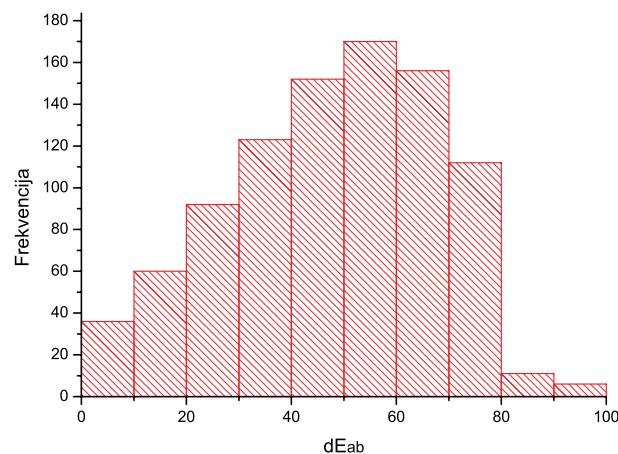
Slika 7.1.18, Histogram odstupanja za model 24-6 RGB->D

Model devetoga reda s 24 člana

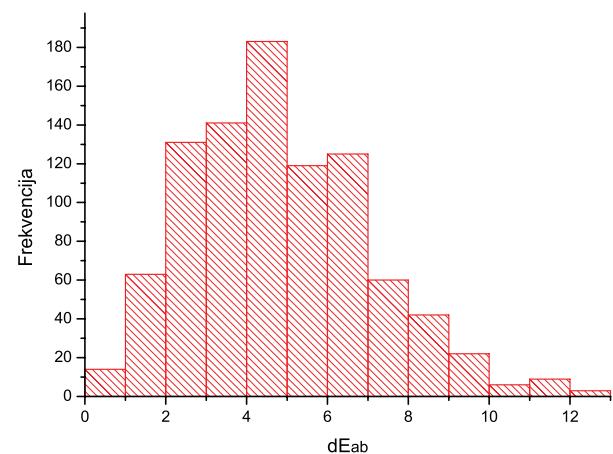
[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B RGB² R³G³B³]

Tabela 7.10, Odstupanja modela 24-9 od empirijskih podataka

	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	47,93	1,42	49,79	93,20	2,56
RGB->D	918	4,83	0,13	4,59	12,69	0,29



Slika 7.1.19, Histogram odstupanja za model 24-9 RGB->Lab



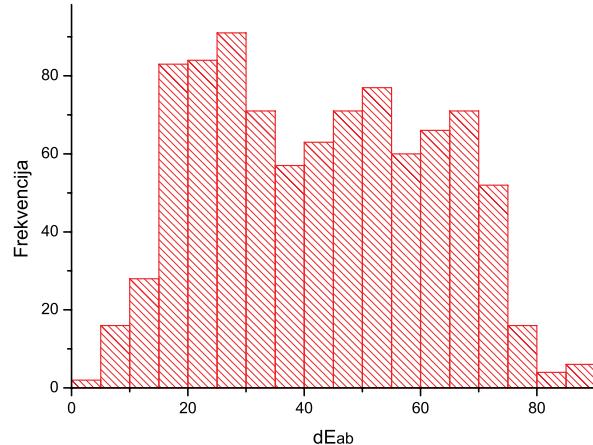
Slika 7.1.20, Histogram odstupanja za model 24-9 RGB->D

Model devetoga reda s 25 članova

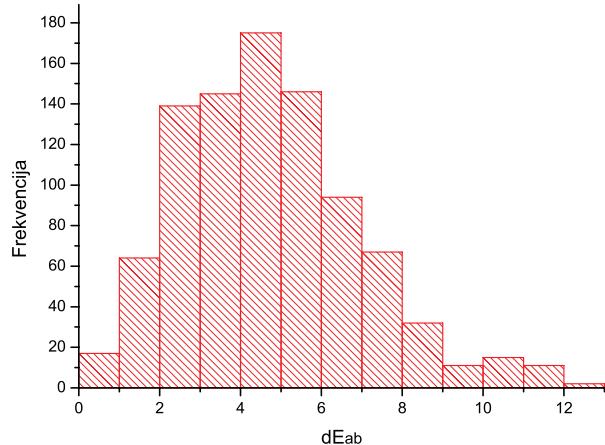
[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B RGB² R²G²B² R³G³B³]

Tabela 7.11, Odstupanja modela 25-9 od empirijskih podataka

	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	42,60	3,46	42,29	86,76	2,48
RGB->D	918	4,73	0,20	4,48	12,60	0,29



Slika 7.1.21, Histogram odstupanja za model 25-9 RGB->Lab



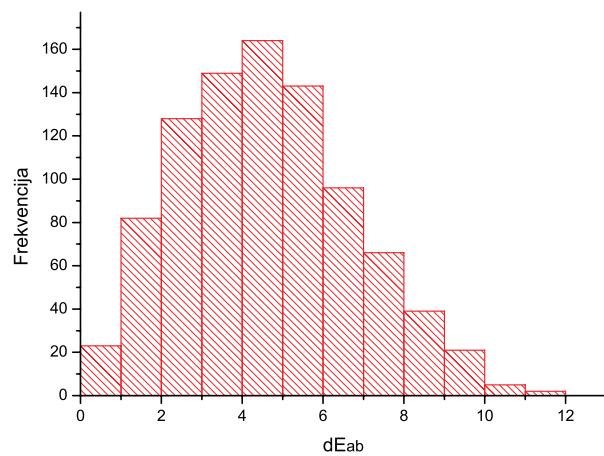
Slika 7.1.22, Histogram odstupanja za model 25-9 RGB->D

Model petoga reda s 26 članova

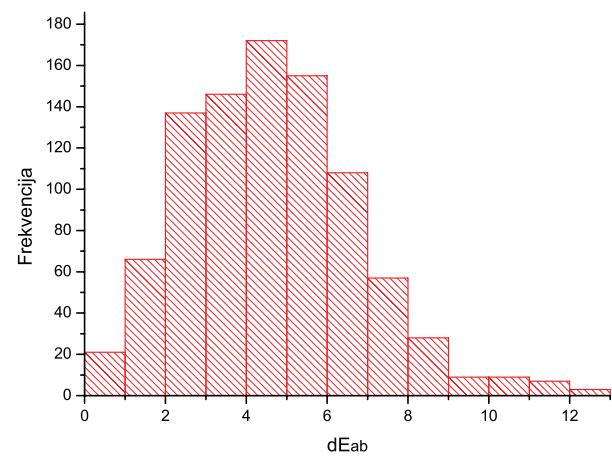
[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B RGB² R³GB RG³B RGB³]

Tabela 7.12, Odstupanja modela 26-5 od empirijskih podataka

	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	4,60	0,22	4,47	11,97	0,28
RGB->D	918	4,62	0,41	4,43	12,68	0,28



Slika 7.1.23, Histogram odstupanja za model 26-5 RGB->Lab



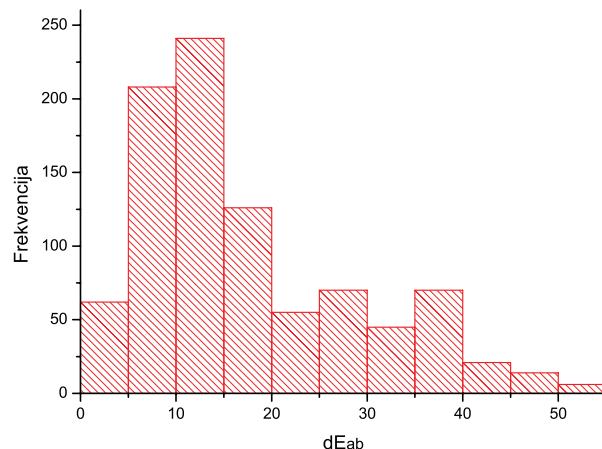
Slika 7.1.24, Histogram odstupanja za model 26-5 RGB->D

Model sedmoga reda s 26 članova

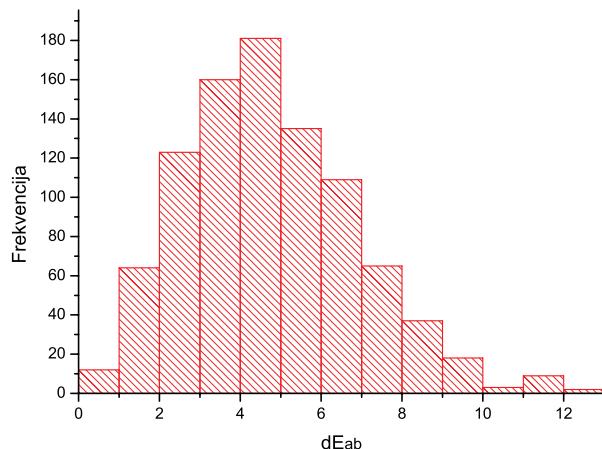
[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B
RGB² R³G²B² R²G³B² R²G²B³]

Tabela 7.13, Odstupanja modela 26-7 od empirijskih podataka

	N – broj polja	$\bar{\Delta E_{ab}}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	17,43	1,31	13,85	53,71	1,48
RGB->D	918	4,76	0,43	4,55	12,69	0,27



Slika 7.1.25, Histogram odstupanja za model 26-7 RGB->Lab



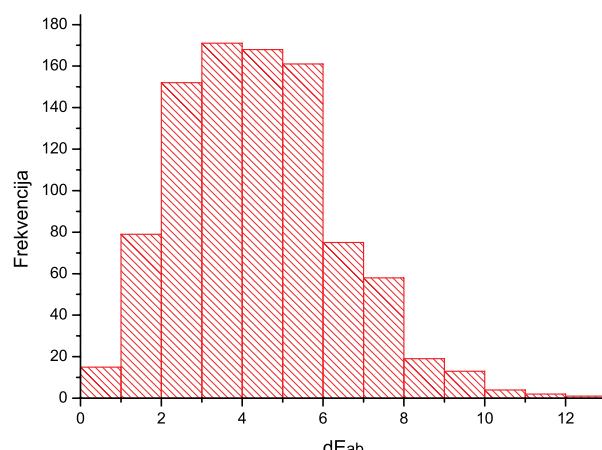
Slika 7.1.26, Histogram odstupanja za model 26-7 RGB->D

Model četvrtoga reda s 29 članova

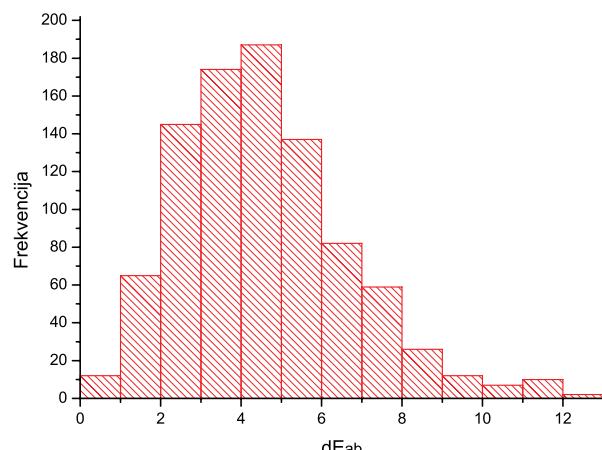
[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B
RGB² R³G G³B B³R R³B G³R B³G]

Tabela 7.14, Odstupanja modela 29-4 od empirijskih podataka

	N – broj polja	$\bar{\Delta E_{ab}}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	4,39	0,53	4,24	12,49	0,26
RGB->D	918	4,57	0,34	4,29	12,80	0,27



Slika 7.1.27, Histogram odstupanja za model 29-4 RGB->Lab



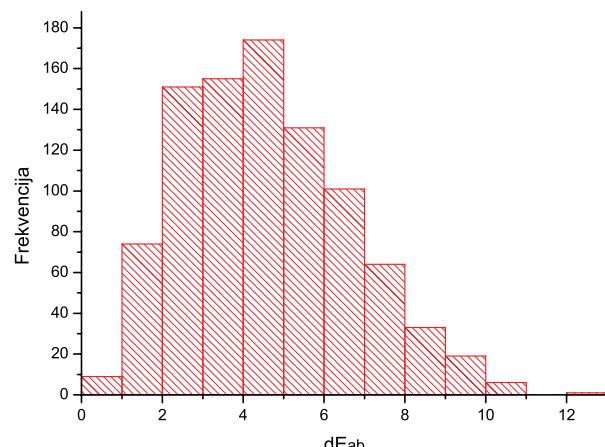
Slika 7.1.28, Histogram odstupanja za model 29-4 RGB->D

Model petoga reda s 29 članova

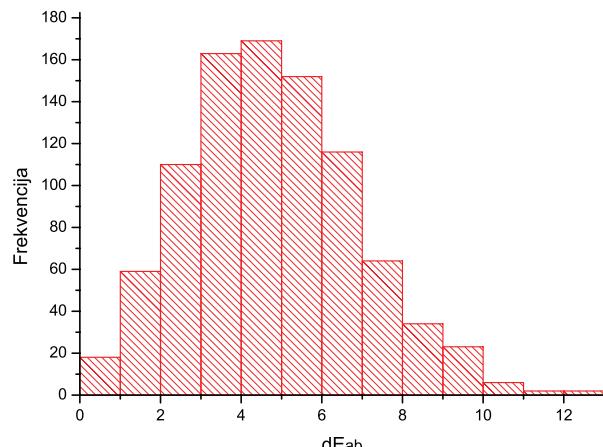
[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B RGB² R³G² G³B² B³R² R³B² G³R² B³G²]

Tabela 7.15, Odstupanja modela 29-5 od empirijskih podataka

	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	4,59	0,30	4,39	12,35	0,27
RGB->D	918	4,77	0,22	4,57	12,25	0,27



Slika 7.1.29, Histogram odstupanja za model 29-5 RGB->Lab



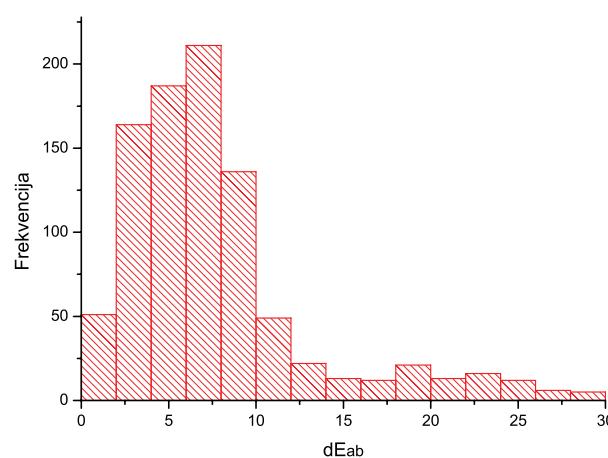
Slika 7.1.30, Histogram odstupanja za model 29-5 RGB->D

Model šestoga reda s 29 članova

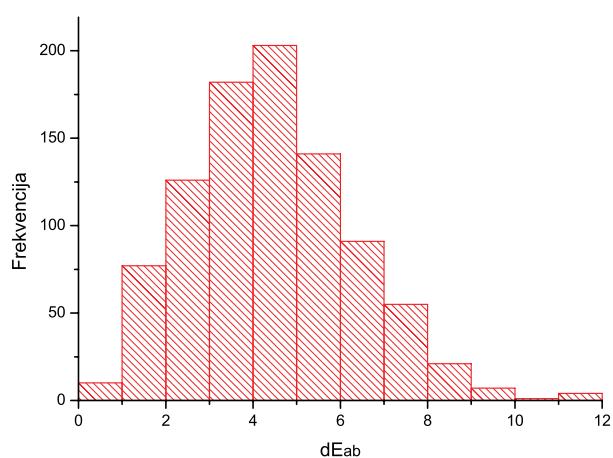
[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B RGB² R³G²B R²G³B R²GB³ R³GB² RG³B² RG²B³]

Tabela 7.16, Odstupanja modela 29-6 od empirijskih podataka

	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	7,69	0,73	6,62	29,20	0,70
RGB->D	918	4,42	0,26	4,28	11,70	0,24



Slika 7.1.31, Histogram odstupanja za model 29-6 RGB->Lab



Slika 7.1.32, Histogram odstupanja za model 29-6 RGB->D

U ovome dijelu rada neće se komentirati performanse svakoga pojedinog modela jer nije uočena nikakva pravilnost u kretanju moći predviđanja s obzirom na odabir članova modela. Kako bi se ispitala signifikantnost pojedinih članova i uočila eventualna pravilnost i mogućnost odabira odgovarajućih članova potrebna je sustavnija analiza i njeni su rezultati izneseni u drugome dijelu ovoga rada.

Ipak, iz rezultata iznesenih u ovome dijelu rada (Tabela 7.9 do Tabela 7.16) moguće je uočiti neke bitne pojave. Za razliku od osnovnih modela kod kojih je uočeno kako se razdioba odstupanja vrijednosti predviđenih modelom od empirijskih u nekim slučajevima ne mijenja, a u nekim se mijenja, kod modela s dodatnim međuproductima na $L^*a^*b^*$ dolazi do znatnih većih promjena u razdiobi odstupanja vrijednosti predviđenih modelom od empirijskih. Pri tome nisu uočena pravila s obzirom na smjer razdiobe. Kod ekstremnih slučaja pretjerane prilagodbe modela pojavile su se lijevo asimetrična razdioba (Tabela 7.10 i Slika 7.1.19), simetrična razdioba (Tabela 7.11 i Slika 7.1.21) i desno asimetrična razdioba (Tabela 7.13 i Slika 7.1.25). Ta se pojava može objasniti time što jednostavniji modeli, iako ne opisuju podatke dovoljno precizno, prate njihov generalni trend i uravnoteženo odstupaju od svake pojedine točke. Dođe li kod modela višega reda do pretjerane prilagodbe, model će se bolje prilagoditi vrijednostima kojima je treniran, ali će za ostale vrijednosti jako odstupati pa je lako zamislivo da pri tome dolazi do promjena u razdiobi odstupanja modela od empirijskih vrijednosti. Ovdje je potrebno dodatno naglasiti da se pod boljom prilagodbom vrijednostima kojima je model treniran misli u odnosu na ostale vrijednosti jer su, kao što je gore izneseno, neki modeli visokih redova ekstremno odstupali i od onih vrijednosti kojima su trenirani, ali bez drastičnih promjena u obliku razdiobe odstupanja.

7.2. Domena skaliranih L*a*b* vrijednosti

U ovome dijelu prikazani su rezultati evaluacija modela na L*a*b* domeni normaliziranoj na raspon vrijednosti [0,1], pri čemu 1 odgovara L = 100, odnosno a,b = 127.

SKUP A

Model šestoga reda s 24 člana

[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B RGB² R²G²B²]

Tabela 7.17, Odstupanja modela 24-6 od empirijskih podataka

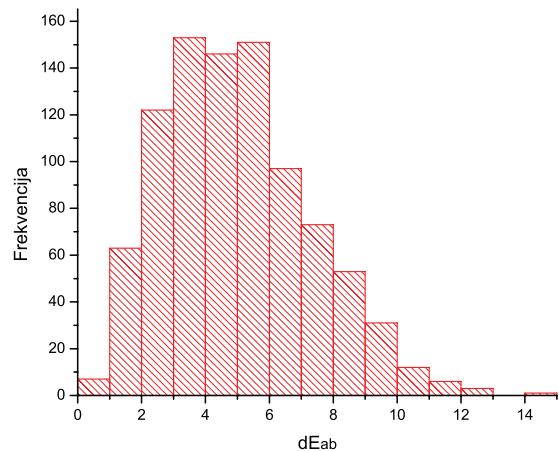
	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	5,03	0,20	4,79	14,57	0,30

Model devetoga reda s 24 člana

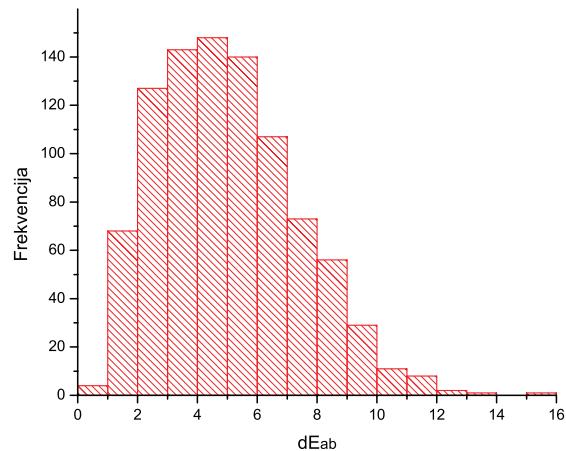
[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B RGB² R³G³B³]

Tabela 7.18, Odstupanja modela 24-9 od empirijskih podataka

	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	5,04	0,19	4,78	15,07	0,30



Slika 7.2.1, Histogram odstupanja za model 24-6 RGB->Lab



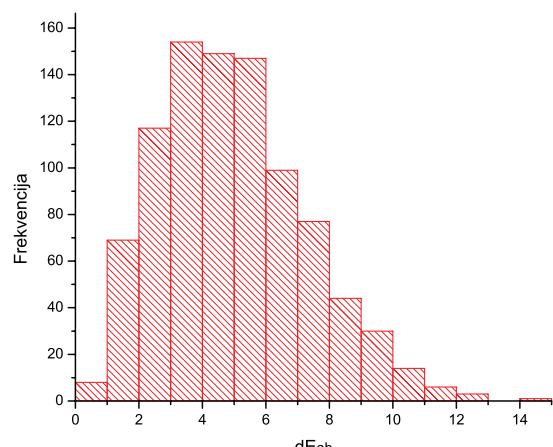
Slika 7.2.2, Histogram odstupanja za model 24-9 RGB->Lab

Model devetoga reda s 25 članova

[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B RGB² R²G²B² R³G³B³]

Tabela 7.19, Odstupanja modela 25-9 od empirijskih podataka

	N – broj polja	$\bar{\Delta E_{ab}}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	4,97	0,36	4,75	14,60	0,30



Slika 7.2.3, Histogram odstupanja za model 25-9 RGB->Lab

Modelom šestoga reda s 24 člana (Tabela 7.17, Slika 7.2.1) aritmetička sredina odstupanja povećana je za približno ΔE 0,5, medijan odstupanja povećan je za približno ΔE 0,7, a maksimalno odstupanje neznatno je smanjeno u odnosu na osnovni model četvrtoga reda s 23 člana.

Modelom devetoga reda s 24 člana (Tabela 7.17, Slika 7.2.1) aritmetička sredina odstupanja povećana je za približno ΔE 0,5, medijan odstupanja povećan je za približno ΔE 0,7, a maksimalno odstupanje povećano je za približno ΔE 0,5 u odnosu na osnovni model četvrtoga reda s 23 člana.

Modelom devetoga reda s 25 članova (Tabela 7.17, Slika 7.2.1) aritmetička sredina odstupanja povećana je za približno ΔE 0,5, medijan odstupanja povećan je za približno ΔE 0,8, a maksimalno odstupanje neznatno je smanjeno u odnosu na osnovni model četvrtoga reda s 23 člana.

Uočljivo je da niti u jednom od tri gore navedenih slučajeva nije došlo do ekstremnih odstupanja kao što je to bio slučaj na izvornoj L*a*b* domeni. Iako su mjere centralne tendencije odstupanja povećane za iznose koji se na prvi pogled ne čine velikima, iznos povećanja je izvan granica intervala pouzdanosti pa se može reći da su razlike u odnosu na osnovni model četvrtoga reda s 23 člana statistički signifikantne i da su svi ispitani članovi smanjili sposobnost prilagodbe modela. Ipak, kako su iznosi povećanja odstupanja znatno manji u odnosu na izvornu L*a*b* domenu, uočljiva je važnost skaliranja podataka na prikladne raspone.

Model petoga reda s 26 članova

[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B RGB² R³GB RG³B RGB³]

Tabela 7.20, Odstupanja modela 26-5 od empirijskih podataka

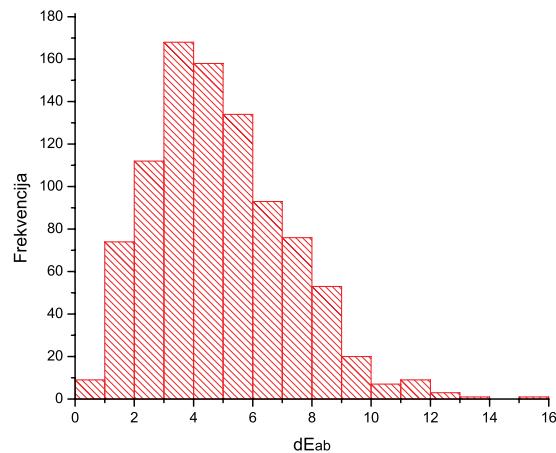
	N – broj polja	$\bar{\Delta}E_{ab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	4,91	0,72	4,59	15,64	0,30

Model sedmoga reda s 26 članova

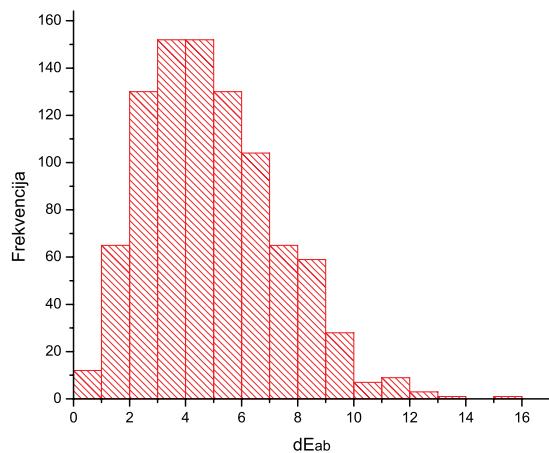
[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B RGB² R³G²B² R²G³B² R²G²B³]

Tabela 7.21, Odstupanja modela 26-7 od empirijskih podataka

	N – broj polja	$\bar{\Delta}E_{ab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	4,94	0,31	4,68	15,88	0,30



Slika 7.2.4, Histogram odstupanja za model 26-5 RGB->Lab



Slika 7.2.5, Histogram odstupanja za model 26-7 RGB->Lab

Modelom petoga reda s 26 članova (Tabela 7.20, Slika 7.2.4) aritmetička sredina odstupanja povećana je za približno ΔE 0,4, medijan odstupanja povećan je za približno ΔE 0,6, a maksimalno odstupanje povećano je za približno ΔE 1.

Modelom sedmoga reda s 26 članova (Tabela 7.20, Slika 7.2.4) aritmetička sredina odstupanja povećana je za približno ΔE 0,4, medijan odstupanja povećan je za približno ΔE 0,7, a maksimalno odstupanje povećano je za približno ΔE 1,3.

Iznosi povećanja odstupanja kod gore navedena dva modela slični su onima kod prethodna tri modela. Razlika u mjerama centralne tendencije u odnosu na osnovni model četvrtoga reda s 23 člana je signifikantna i može se zaključiti da u odnosu na osnovni model daju lošije rezultate.

Model četvrtoga reda s 29 članova

[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B RGB² R³G G³B B³R R³B G³R B³G]

Tabela 7.22, Odstupanja modela 29-4 od empirijskih podataka

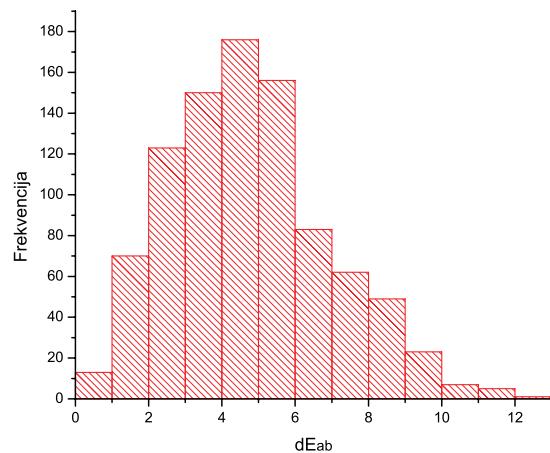
	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	4,76	0,34	4,51	12,88	0,28

Model petoga reda s 29 članova

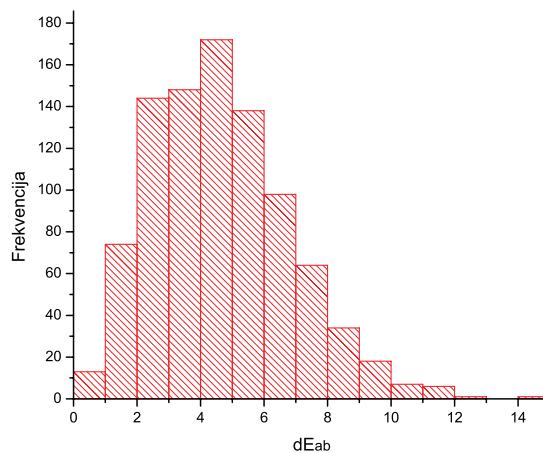
[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B RGB² R³G² G³B² B³R² R³B² G³R² B³G²]

Tabela 7.23, Odstupanja modela 29-5 od empirijskih podataka

	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	4,66	0,24	4,45	14,51	0,28



Slika 7.2.6, Histogram odstupanja za model 29-4 RGB->Lab



Slika 7.2.7, Histogram odstupanja za model 29-5 RGB->Lab

Modelom četvrtoga reda s 29 članova (Tabela 7.20, Slika 7.2.4) aritmetička sredina odstupanja povećana je za približno ΔE 0,3, medijan odstupanja je povećan za približno ΔE 0,5, a maksimalno odstupanje smanjeno je za približno ΔE 1,7.

Modelom petoga reda s 29 članova (Tabela 7.20, Slika 7.2.4) aritmetička sredina odstupanja povećana je za približno ΔE 0,2, medijan odstupanja je povećan za približno ΔE 0,5, a maksimalno odstupanje je smanjeno za neznatan iznos.

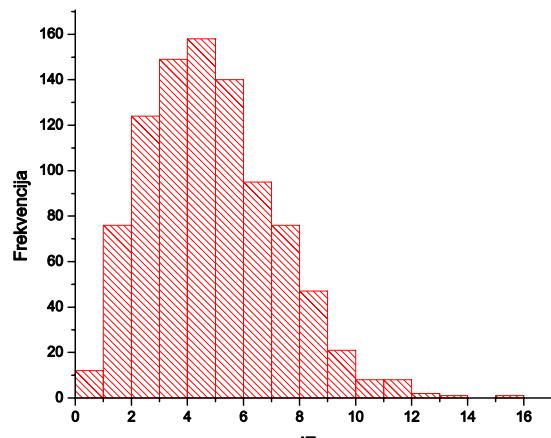
Iako su i dva gore navedena slučaja zabilježena povećanja odstupanja, iznos srednje vrijednosti odstupanja je manji u odnosu na prethodne slučajevе i unutar je granica intervala pouzdanosti. Za razliku od prethodnih, modeli su nižih redova i sadrže veći broj članova koji opisuju interakcije među dva kanala. Sličan rezultat dobiven je modelom šestoga reda s 29 članova pa je uočljivo da je na rezultate najviše utjecao upravo broj članova modela.

Model šestoga reda s 29 članova

[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B RGB² R³G²B R²G³B R²GB³ R³GB² RG³B² RG²B³]

Tabela 7.24, Odstupanja modela 29-6 od empirijskih podataka

	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	4,85	0,36	4,54	15,97	0,30



Slika 7.2.8, Histogram odstupanja za model 29-6 RGB->Lab

Modelom šestoga reda s 29 članova (Tabela 7.20, Slika 7.2.4) aritmetička sredina odstupanja smanjena je za približno ΔE 0,2, medijan odstupanja je smanjen za približno ΔE 0,3, a maksimalno odstupanje je povećano za približno ΔE 1.

Tabela 7.25, Usporedba modela s dodatni međuproductima u odnosu na model 23-4 na skupu A

Model	D			Lab			Lab skaliran		
	$\bar{\Delta Eab}$	Medijan	Maks	$\bar{\Delta Eab}$	Medijan	Maks	$\bar{\Delta Eab}$	Medijan	Maks
24-6	-0,06	-0,06	1,03	-1,35	-1,43	-3,72	0,02	0,01	0,36
24-9	-0,03	0	0,07	-40,79	-41,85	-95,49	0,01	0,02	-0,14
25-9	0,04	0,01	0,47	-35,86	-32,38	-95,41	0,08	0,05	0,33
26-5	0,17	0,01	-0,72	-0,4	-0,61	-0,99	0,14	0,21	-0,71
26-7	0,01	0,02	1,01	-15,12	-12,79	-40,91	0,11	0,12	-0,95
29-4	0,17	0,07	1,14	-0,25	-0,53	1,77	0,29	0,29	2,05
29-5	0,15	-0,04	-0,21	-0,15	-0,47	0,13	0,39	0,35	0,42
29-6	0,43	0,29	3,1	-3,4	-2,58	-15,54	0,2	0,26	-1,04

Tabela 7.25 sumarno prikazuje odstupanja ispitanih modela s dodatnim međuproductima od modela 23-4 na skupu A. Vidljivo je da do ekstremnih odstupanja dolazi samo na L*a*b* domeni u slučajevima modela vrlo visokih redova.

SKUP B

Model šestoga reda s 24 člana

[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B RGB² R²G²B²]

Tabela 7.26, Odstupanja modela 24-6 od empirijskih podataka

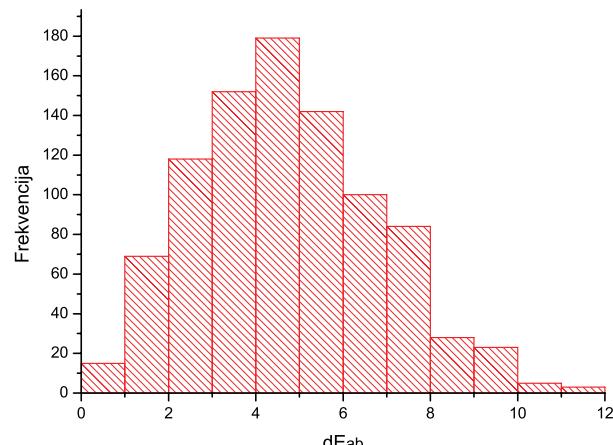
	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	4,74	0,15	4,68	11,81	0,27

Model devetoga reda s 24 člana

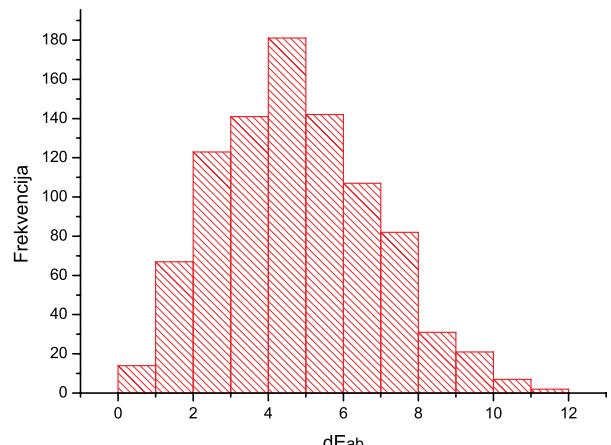
[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B RGB² R³G³B³]

Tabela 7.27, Odstupanja modela 24-9 od empirijskih podataka

	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	4,76	0,09	4,65	11,93	0,27



Slika 7.2.9, Histogram odstupanja za model 24-6 RGB->Lab



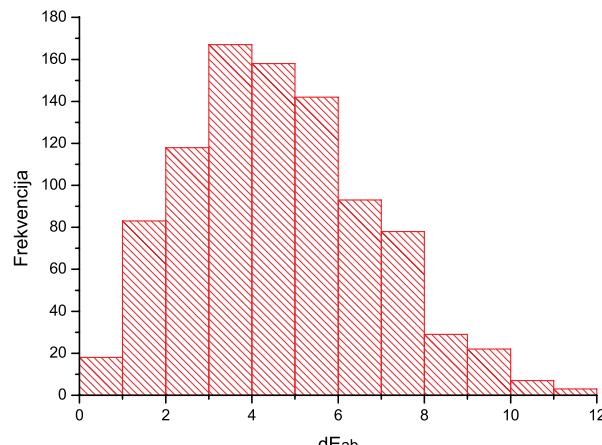
Slika 7.2.10, Histogram odstupanja za model 24-9 RGB->Lab

Model devetoga reda s 25 članova

[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B RGB² R²G²B² R³G³B³]

Tabela 7.28, Odstupanja modela 25-9 od empirijskih podataka

	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	4,64	0,16	4,48	11,62	0,28



Slika 7.2.11, Histogram odstupanja za model 25-9 RGB->Lab

Modelom šestoga reda s 24 člana (Tabela 7.26, Slika 7.2.9) aritmetička sredina, medijan i maksimalno odstupanje zanemarivo su promijenjeni u odnosu na osnovni model četvrtoga reda s 23 člana.

Modelom devetoga reda s 24 člana (Tabela 7.27, Slika 7.2.10) ritmetička sredina, medijan i maksimalno odstupanje zanemarivo su promijenjeni u odnosu na osnovni model četvrtoga reda s 23 člana.

Nešto veća promjena zabilježena je kod modela devetoga reda s 25 članova (Tabela 7.28, Slika 7.2.11) kod kojega je iznos srednjeg, medijana i maksimuma odstupanja smanjen za oko $\Delta E 0,2$. Taj iznos ne prelazi granice intervala pouzdanosti i nije signifikantan.

Iz rezultata iznesenih u ovome dijelu rada vidljivo može se uočiti da se na skaliranoj L*a*b* domeni, za razliku od izvorne L*a*b* domene, ne javlja problem pretjerane prilagodbe čak niti modela devetoga reda s 24 člana koji je na izvornoj L*a*b* domeni postigao vrlo loše rezultate, čak i na skupu A podataka. Tri gore navedena modela manje su se mijenjala u odnosu na osnovni model četvrtoga reda s 23 člana na nezavisnom skupu podataka B nego na skupu A čime se potvrđuje ranije iznesena tvrdnja da se ne javlja pretjerana prilagodba. Iako se modeli slabije prilagođavaju podacima kojima su trenirani, dobro prate generalni trend podataka pa su bolje prilagođeni drugim dijelovima domene.

Model petoga reda s 26 članova

[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B RGB² R³GB RG³B RGB³]

Tabela 7.29, Odstupanja modela 26-5 od empirijskih podataka

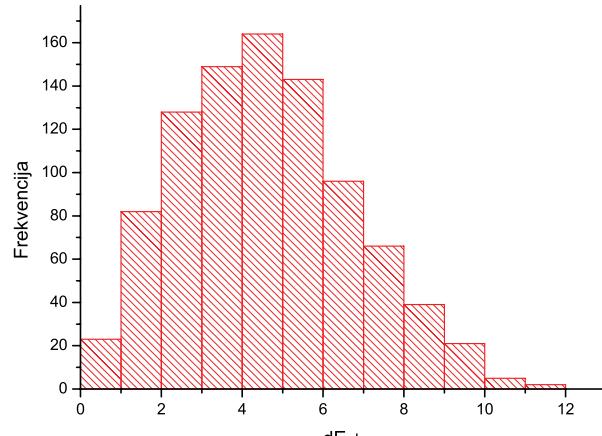
	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	4,60	0,22	4,47	11,97	0,28

Model sedmoga reda s 26 članova

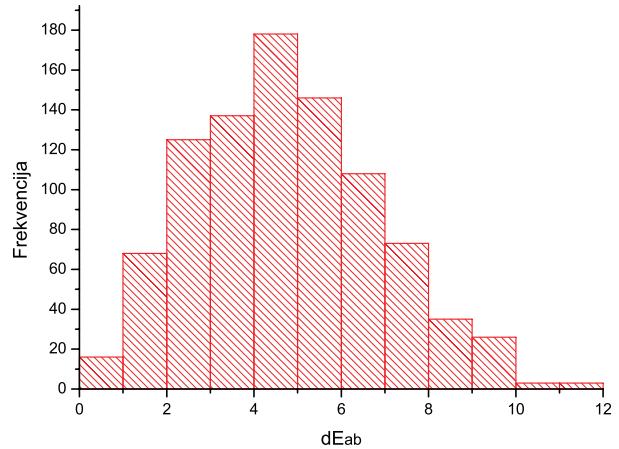
[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B RGB² R³G²B² R²G³B² R²G²B³]

Tabela 7.30, Odstupanja modela 26-7 od empirijskih podataka

	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	4,77	0,41	4,69	11,71	0,27



Slika 7.2.12, Histogram odstupanja za model 26-5 RGB->Lab



Slika 7.2.13, Histogram odstupanja za model 26-7 RGB->Lab

Modelom petoga reda s 26 članova (Tabela 7.29, Slika 7.2.12) aritmetička sredina odstupanja smanjena je za približno ΔE 0,15, medijan odstupanja smanjen je za približno ΔE 0,2, a maksimalno odstupanje povećano je za približno ΔE 0,1.

Modelom sedmoga reda s 26 članova (Tabela 7.20, Slika 7.2.13) aritmetička sredina i medijan odstupanja povećani su za zanemarive iznose, a maksimalno odstupanje smanjeno je za približno ΔE 0,15.

Iznosi smanjenja odstupanja kod gore navedena dva modela nisu signifikantni u odnosu na osnovni model četvrtoga reda s 23 člana.

Model četvrtoga reda s 29 članova

[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B
RGB² R³G G³B B³R R³B G³R B³G]

Tabela 7.31, Odstupanja modela 29-4 od empirijskih podataka

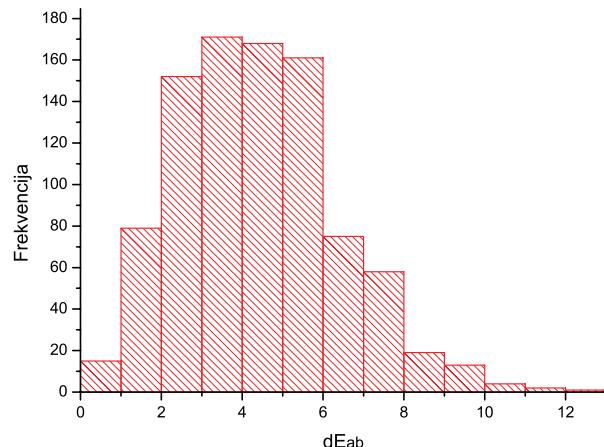
	N – broj polja	$\bar{\Delta}Eab$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	4,39	0,53	4,24	12,49	0,26

Model petoga reda s 29 članova

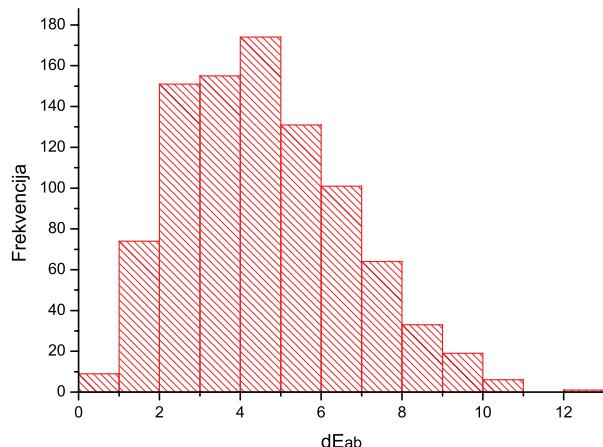
[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B
RGB² R³G G³B B³R R³B² G³R² B³G²]

Tabela 7.32, Odstupanja modela 29-5 od empirijskih podataka

	N – broj polja	$\bar{\Delta}Eab$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	4,59	0,30	4,39	12,35	0,27



Slika 7.2.14, Histogram odstupanja za model 29-4 RGB->Lab



Slika 7.2.15, Histogram odstupanja za model 29-5 RGB->Lab

Modelom četvrtoga reda s 29 članova (Tabela 7.20, Slika 7.2.14) aritmetička sredina odstupanja smanjena je za približno ΔE 0,4, medijan odstupanja je smanjen za približno ΔE 0,4, a maksimalno odstupanje povećano je za približno ΔE 0,7.

Modelom petoga reda s 29 članova (Tabela 7.32, Slika 7.2.4) aritmetička sredina odstupanja smanjena je za približno ΔE 0,2, medijan odstupanja je smanjen za približno ΔE 0,3, a maksimalno odstupanje je povećano za približno ΔE 0,5.

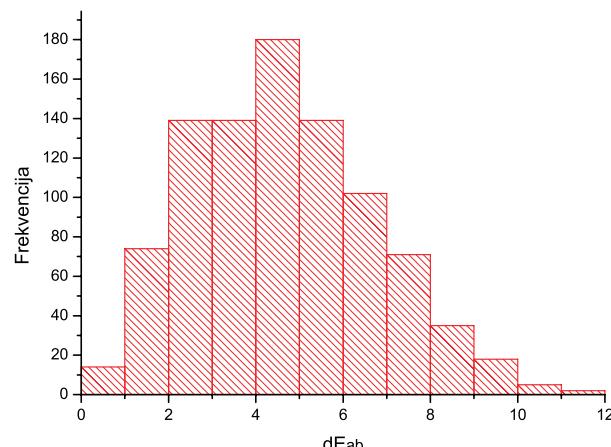
Iznosi smanjenja odstupanja kod gore navedena dva modela nisu signifikantni u odnosu na osnovni model četvrtoga reda s 23 člana. Ipak, poboljšanje je nešto veće nego kod prethodnih modела, kao što je to bio slučaj na skupu A. Stoga je i ovdje uočljivo da su veću moć predviđanja postigli modeli s većim brojem članova.

Model šestoga reda s 29 članova

[1 R G B RG GB RB R² G² B² RGB R²G G²B B²R R²B G²R B²G R³ G³ B³ R²GB RG²B RGB² R³G²B R²G³B R²GB³ R³GB² RG³B² RG²B³]

Tabela 7.33, Odstupanja modela 29-6 od empirijskih podataka

	N – broj polja	$\bar{\Delta Eab}$	Min	Medijan	Maks	Int. pouz. 95%
RGB->Lab	918	4,65	0,44	4,49	11,79	0,27



Slika 7.2.16, Histogram odstupanja za model 29-6 RGB->Lab

Modelom šestoga reda s 29 članova (Tabela 7.33, Slika 7.2.16) postignuti su rezultati slični ostalim modelima s jednakim brojem članova, ali je uočljivo da su mjere centralne tendencije povećane za male iznose, to jest da rastu povećanjem reda modela od četvrtog do šestog. Maksimalno odstupanje je smanjeno za približno ΔE 0,7.

Prema rezultatima svih modela za skup B skalirane L*a*b* domene može se reći da je ona prikladna za karakterizaciju uređaja za koji su modeli na njoj bili testirani. Niti jedan od ispitanih modela na skaliranoj L*a*b* domeni nije se istaknuo znatnim poboljšanjem moći predviđanja, ali nije došlo ni do znatnih smanjenja moći predviđanja, niti do promjena razdiobe odstupanja predviđenih vrijednosti od empirijskih.

8. Eksperiment: Optimizacija modela eliminacijom članova

U ovome dijelu rada izneseni su rezultati evaluacija modela formiranih postupkom eliminacije članova, to jest skupina članova. Ispitano je osam procesa prema planu opisanom u dijelu 5.2. Tabela 8.1 sadrži popis tehnologija i materijala korištenih u istraživanju, te njima pripadajuće oznake procesa.

Tabela 8.1, Ispitivane tehnologije i materijali

Naziv procesa	Tehnologija	Broj boja	Vrsta podloge
Proces A	Ink-jet piezo	6	Naravni papir
Proces B	Ink-jet piezo	6	Satinirani papir
Proces C	Ink-jet termalni	4	Naravni papir
Proces D	Ink-jet termalni	4	Satinirani papir
Proces E	Ink-jet termalni	6	Naravni papir
Proces F	Ink-jet termalni	6	Satinirani papir
Proces G	Laserska elektrofotografija	4	Naravni papir
Proces H	Laserska elektrofotografija	4	Satinirani papir

Tabele 8.2 do 8.9 sadrže rezultate evaluacije maksimalnih modela različitih redova na nezavisnom skupu podataka. Žutom bojom označeni su najbolji rezultati evaluacije. No, poznato je i u ovome radu već spomenuto da iako rezultati evaluacije na nekom skupu podataka mogu biti prihvatljivi, model može biti neprikladan u pogledu problema pretjerane prilagodbe koja ne mora biti vidljiva na rezultatima evaluacije, već je vidljiva primjenom modela na transformiranoj slici. Kako je cilj odrediti maksimalni model koji daje prihvatljive rezultate za određeni proces, modeli su posebno ispitani transformacijom slika. Najbolji modeli koji nisu doveli do pretjerane prilagodbe i pojave vidljivih pogrešaka na slici označeni su zelenom bojom. U slučajevima gdje su najbolji numerički rezultati evaluacije ujedno bili i najbolji dobiveni vizualnim ispitivanjem, označeni su žutom bojom.

Tabela 8.2, Proces A

RGB->D	N - broj polja	dEab	Min	Medijan	Maks	Int. pouz. 95%
2	918	6,13	0,77	5,08	18,70	0,48
3	918	4,12	0,35	3,70	11,20	0,29
4	918	3,23	0,22	2,82	11,50	0,24
5	918	2,33	0,05	2,11	7,44	0,18
6	918	1,95	0,11	1,76	7,02	0,14
7	918	1,67	0,16	1,49	5,95	0,12
8	918	1,49	0,16	1,31	6,18	0,11
9	918	1,80	0,11	1,51	7,02	0,14
10	918	1,96	0,05	1,74	6,08	0,15

Tabela 8.3, Proces B

RGB->D	N - broj polja	dEab	Min	Medijan	Maks	Int. pouz. 95%
2	918	7,95	0,62	6,84	24,92	0,56
3	918	4,85	0,41	4,34	15,71	0,36
4	918	4,09	0,19	3,71	15,71	0,30
5	918	2,98	0,12	2,79	9,53	0,22
6	918	2,32	0,15	2,01	8,89	0,18
7	918	1,84	0,08	1,63	6,71	0,14
8	918	1,71	0,12	1,51	5,66	0,12
9	918	1,80	0,09	1,53	5,74	0,14
10	918	2,32	0,08	1,88	9,75	0,23

Tabela 8.4, Proces C

RGB->D	N - broj polja	dEab	Min	Medijan	Maks	Int. pouz. 95%
2	918	8,87	0,57	8,28	21,13	0,51
3	918	5,91	0,34	5,87	14,01	0,33
4	918	4,30	0,47	3,98	12,15	0,26
5	918	3,18	0,28	2,95	11,44	0,21
6	918	2,55	0,12	2,36	10,21	0,17
7	918	2,24	0,14	1,96	9,37	0,16
8	918	2,19	0,22	1,96	8,41	0,14
9	918	2,14	0,19	1,94	8,19	0,15
10	918	2,39	0,15	2,07	8,11	0,17
11	918	4,27	0,10	3,42	15,38	0,37

Tabela 8.5, Proces D

RGB->D	N - broj polja	dEab	Min	Medijan	Maks	Int. pouz. 95%
2	918	6,89	0,38	6,70	15,29	0,37
3	918	4,77	0,58	4,52	13,81	0,28
4	918	3,38	0,16	3,13	9,59	0,21
5	918	2,44	0,08	2,20	9,20	0,18
6	918	2,19	0,03	1,89	8,87	0,16
7	918	1,97	0,16	1,73	8,12	0,15
8	918	1,77	0,06	1,61	7,39	0,13
9	918	1,82	0,09	1,60	7,12	0,13

10	918	1,81	0,09	1,65	6,63	0,13
11	918	3,06	0,23	2,54	12,01	0,27

Tabela 8.6, Proces E

RGB->D	N - broj polja	dEab	Min	Medijan	Maks	Int. pouz. 95%
2	918	4,61	0,48	4,48	12,34	0,26
3	918	2,88	0,29	2,53	8,41	0,19
4	918	2,21	0,06	2,03	6,58	0,14
5	918	1,91	0,16	1,73	7,26	0,12
6	918	1,63	0,05	1,41	6,45	0,11
7	918	1,53	0,16	1,46	5,45	0,10
8	918	1,63	0,09	1,55	5,17	0,10
9	918	1,75	0,14	1,63	5,09	0,11
10	918	1,81	0,14	1,71	5,96	0,11

Tabela 8.7, Proces F

RGB->D	N - broj polja	dEab	Min	Medijan	Maks	Int. pouz. 95%
2	918	4,20	0,30	3,93	14,25	0,29
3	918	2,81	0,25	2,65	8,78	0,18
4	918	2,22	0,06	1,94	6,77	0,16
5	918	1,83	0,13	1,63	6,31	0,12
6	918	1,48	0,11	1,34	5,19	0,10
7	918	1,36	0,10	1,24	4,53	0,09
8	918	1,35	0,04	1,28	3,81	0,08
9	918	1,38	0,06	1,27	4,01	0,09
10	918	1,37	0,12	1,26	3,95	0,09
11	918	2,89	0,09	2,34	10,41	0,25

Tabela 8.8, Proces G

RGB->D	N - broj polja	dEab	Min	Medijan	Maks	Int. pouz. 95%
2	918	3,73	0,36	3,49	14,37	0,24
3	918	2,80	0,14	2,68	8,37	0,16
4	918	2,17	0,25	2,06	7,58	0,13
5	918	2,00	0,09	1,82	7,59	0,13

6	918	1,96	0,13	1,80	7,98	0,13
7	918	1,90	0,09	1,70	7,96	0,13
8	918	1,96	0,11	1,75	8,39	0,15
9	918	2,18	0,18	1,93	8,66	0,17
10	918	2,55	0,19	2,30	11,32	0,19

Tabela 8.9, Proces H

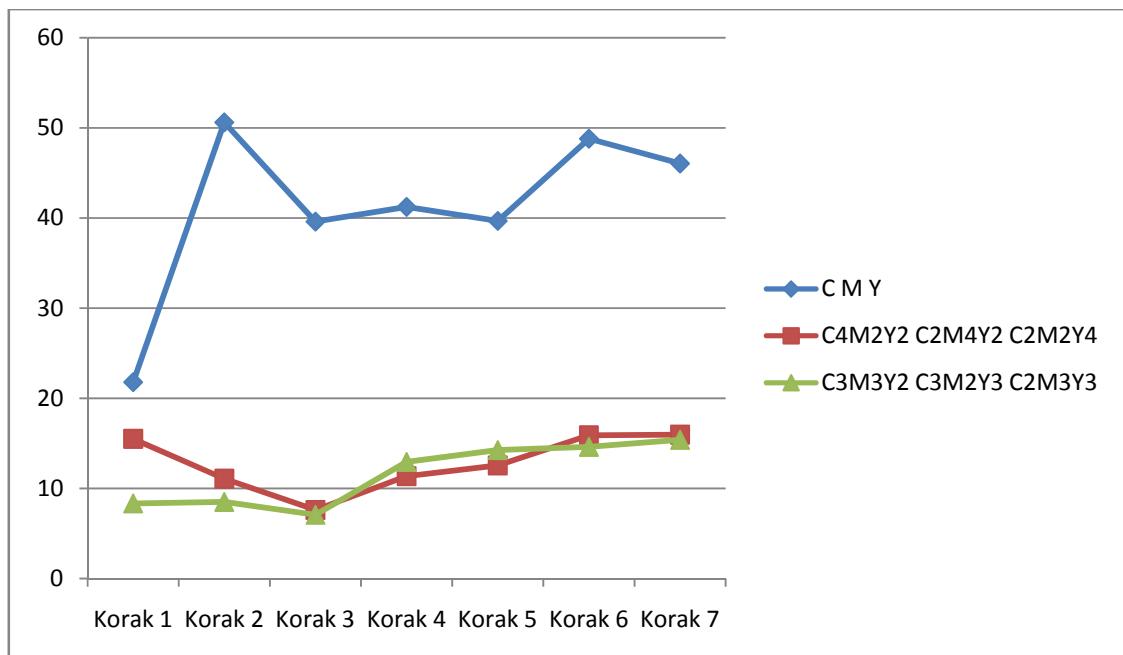
RGB->D	N - broj polja	dEab	Min	Medijan	Maks	Int. pouz. 95%
2	918	4,12	0,46	3,79	14,93	0,26
3	918	3,27	0,21	3,03	11,89	0,22
4	918	2,67	0,27	2,32	11,04	0,20
5	918	2,54	0,25	2,14	11,15	0,21
6	918	2,45	0,21	1,96	11,58	0,21
7	918	2,46	0,13	2,00	11,65	0,22
8	918	2,56	0,15	2,09	11,84	0,22
9	918	2,88	0,20	2,44	11,81	0,24
10	918	3,23	0,16	2,80	12,75	0,25
11	918	4,63	0,13	3,94	17,35	0,39

Iako su neki modeli previsokog reda da bi bili praktično primjenjivi, korišteni su kako bi se lakše utvrdili signifikantni članovi za pojedine procese. Nakon utvrđivanja signifikantnih članova ne moraju biti korišteni modeli viših redova kako bi se formirao optimalan model, već je moguće odabrati članove do najvišeg reda dopuštenog u konkretnom procesu.

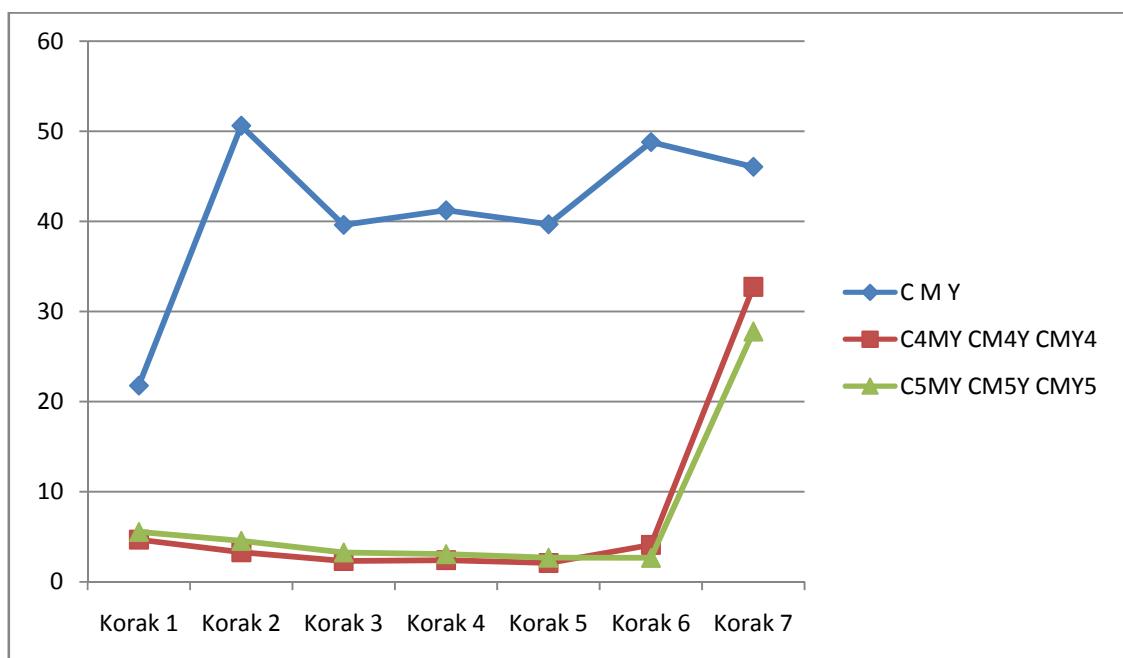
U nastavku su izneseni grafički prikazi trenda signifikantnosti, to jest F vrijednosti za najsignifikantnije skupine članova s početka i najsignifikantnije skupine članova s kraja postupka eliminacije za svaki od osam procesa. Iz njih je vidljiva promjena signifikantnosti skupina članova, to jest ovisnost njihove signifikantnosti o ostalim skupinama članovima modela. Prikazane su i relativne signifikantnosti koje jasnije prikazuju odnose među skupinama članova, ali i daju dodatnu informaciju o tome je li u nekom koraku najsignifikantnjom postala neka druga skupina članova, različita od tri prikazane. Prilog A sadrži cijeli postupak eliminacije skupina članova za procese A i B.

Nakon komentara rezultata za svaki od procesa, izneseni su slični rezultati dobiveni eliminacijom pojedinih članova. Svrha toga ispitivanja bilo je utvrđivanje različitih složenosti kanala i interakcija među njima. Prilog B sadrži cijeli postupak eliminacije članova za procese C i D.

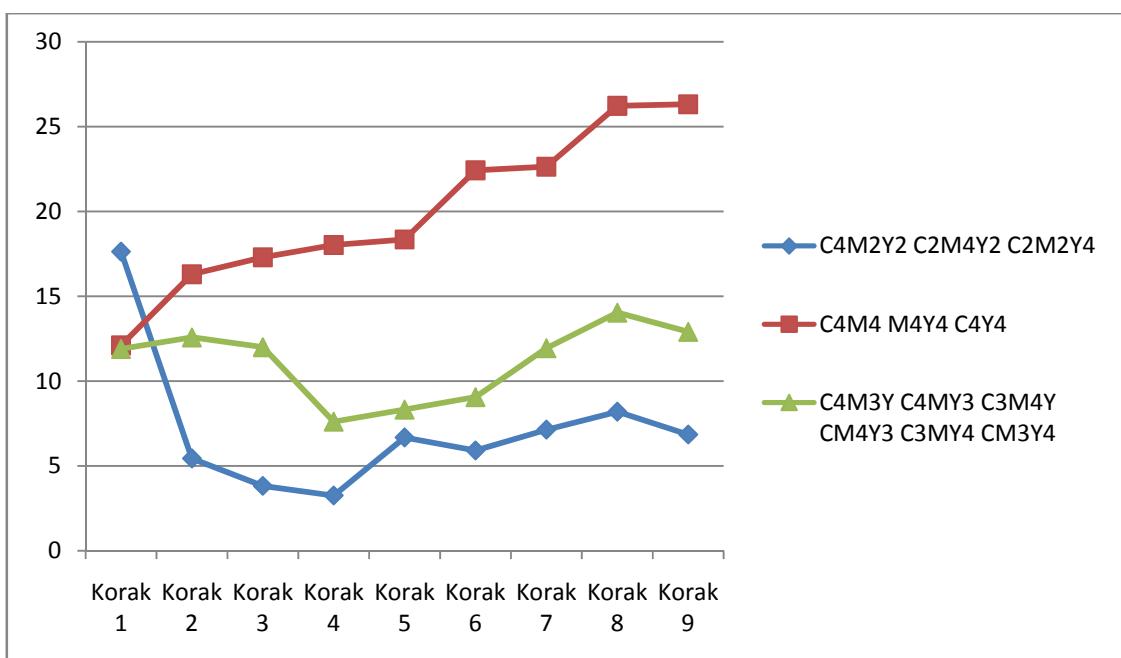
Apsolutne signifikantnosti



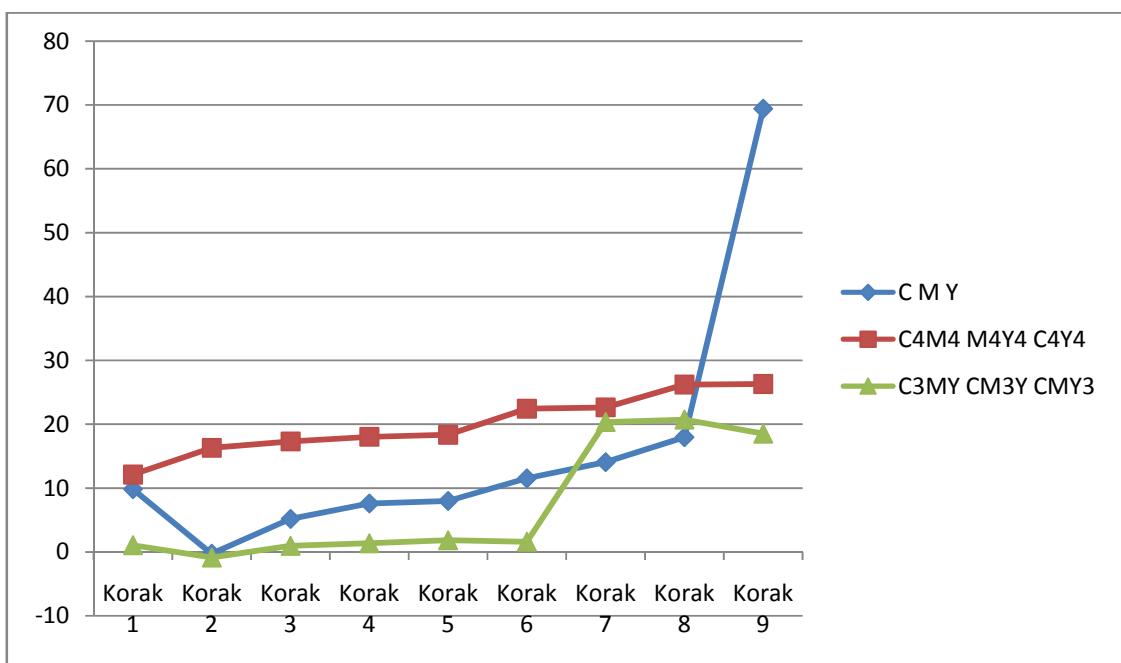
Slika 8.1, F vrijednosti za tri najsigifikantnije skupine članova s početka postupka eliminacije za proces A



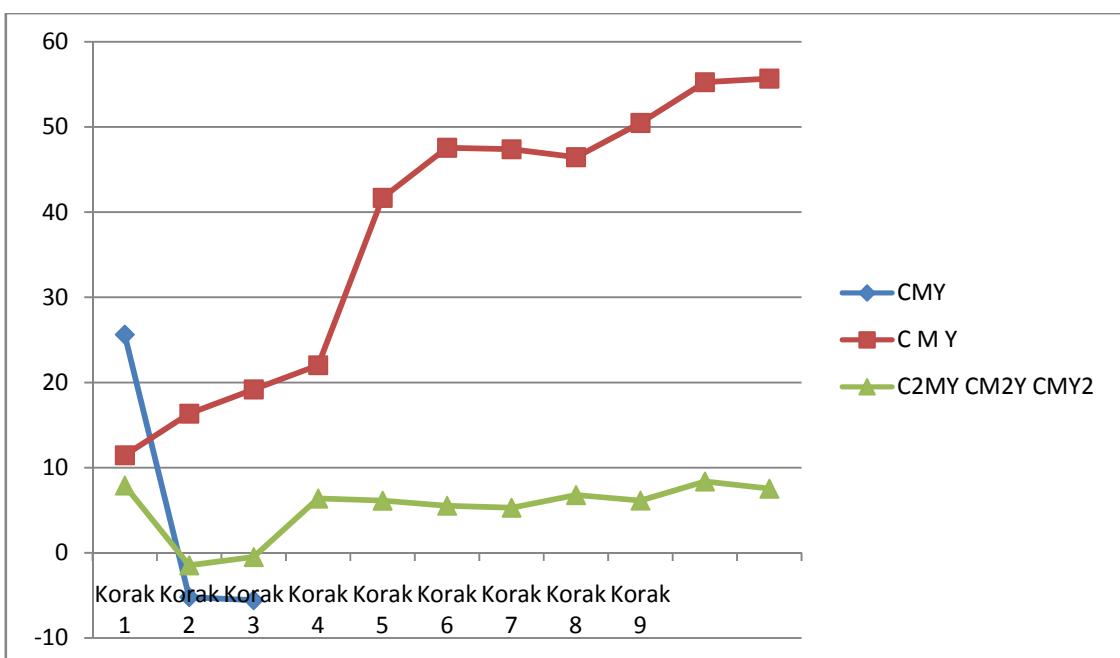
Slika 8.2, F vrijednosti za tri najsigifikantnije skupine članova s kraja postupka eliminacije za proces A



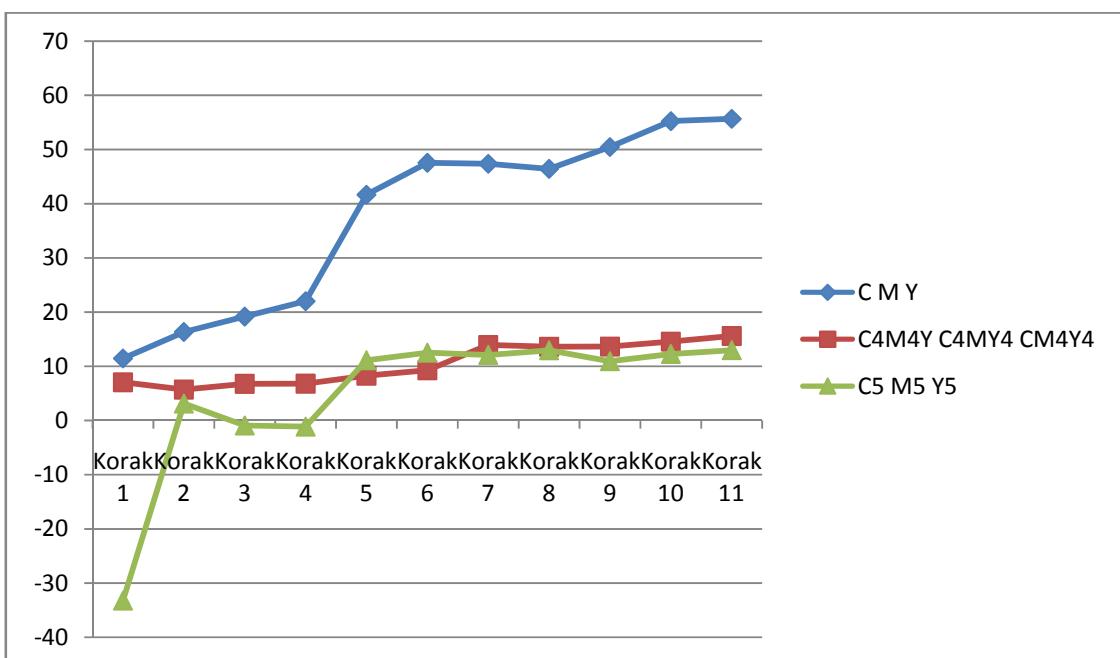
Slika 8.3, F vrijednosti za tri najsigifikantnije skupine članova s početka postupka eliminacije za proces B



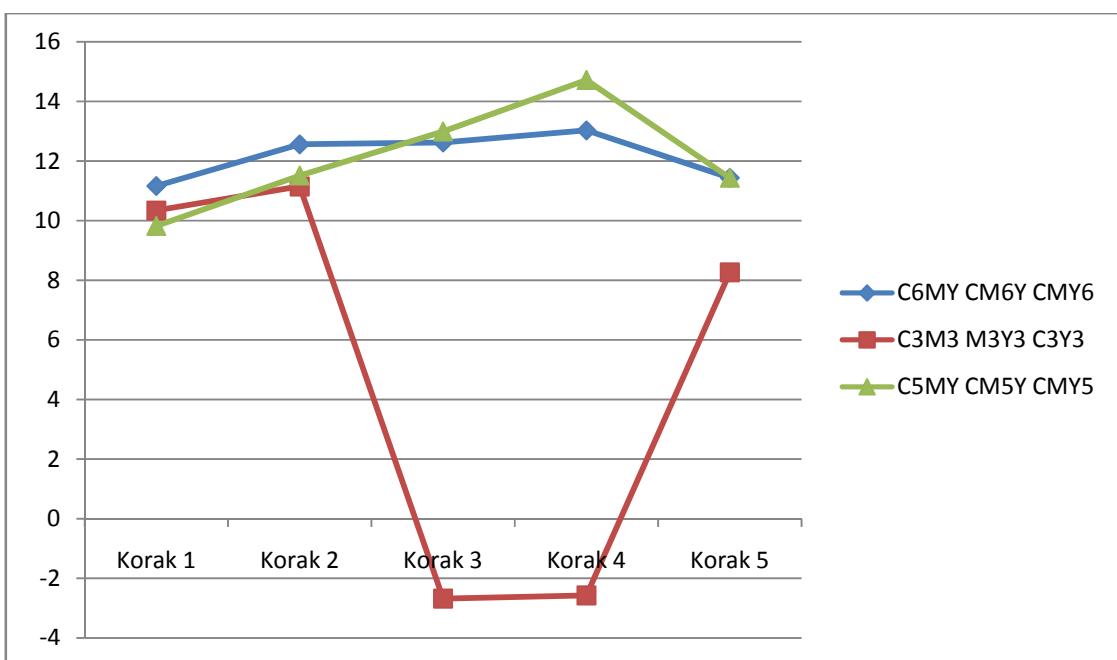
Slika 8.4, F vrijednosti za tri najsigifikantnije skupine članova s kraja postupka eliminacije za proces B



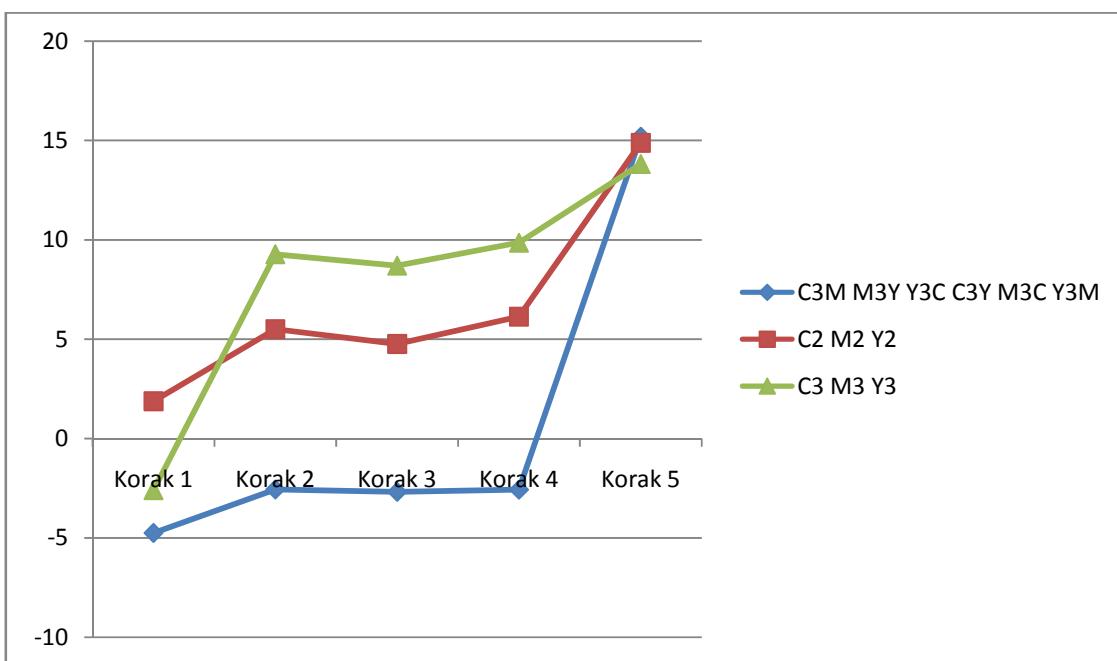
Slika 8.5, F vrijednosti za tri najsigifikantnije skupine članova s početka postupka eliminacije za proces C



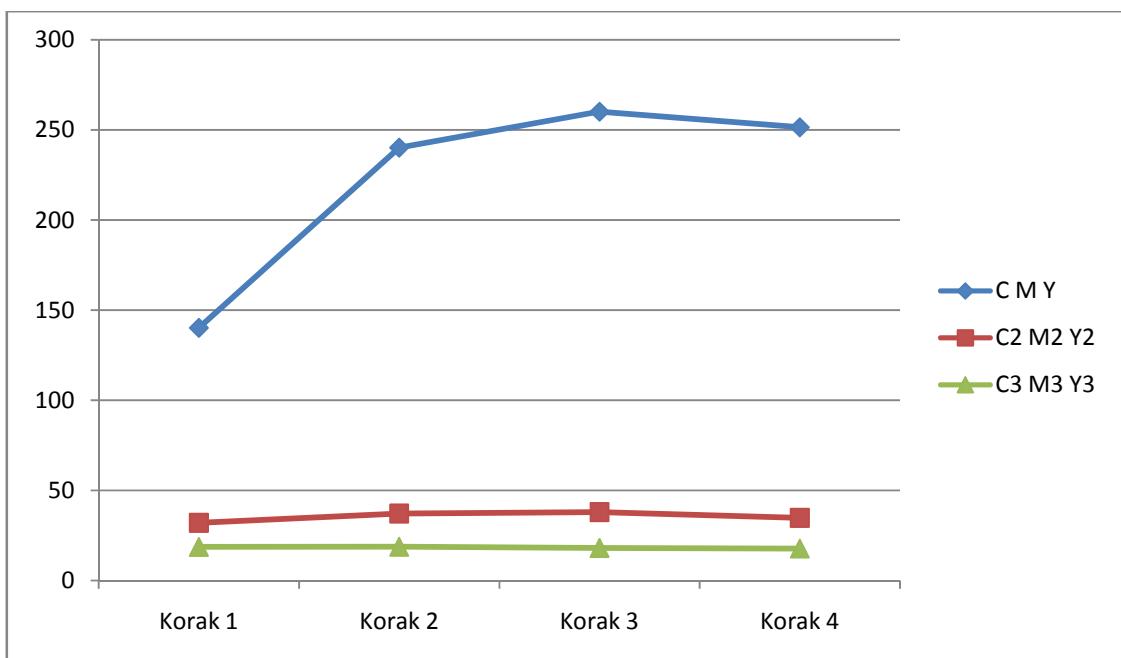
Slika 8.6, F vrijednosti za tri najsigifikantnije skupine članova s kraja postupka eliminacije za proces C



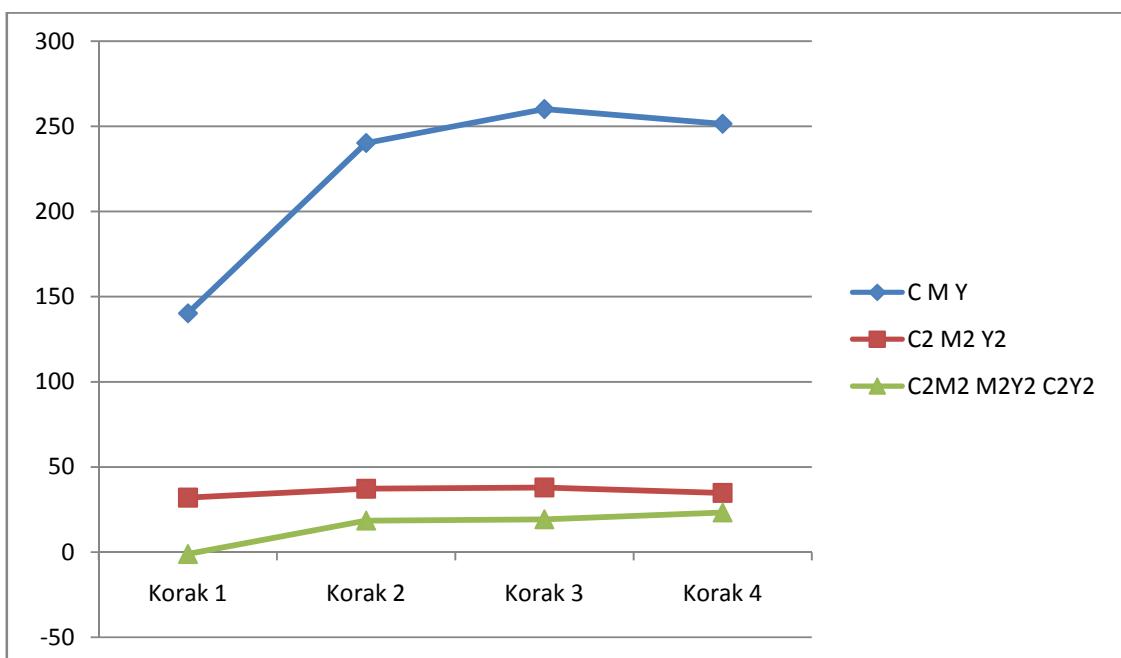
Slika 8.7, F vrijednosti za tri najsigifikantnije skupine članova s početka postupka eliminacije za proces D



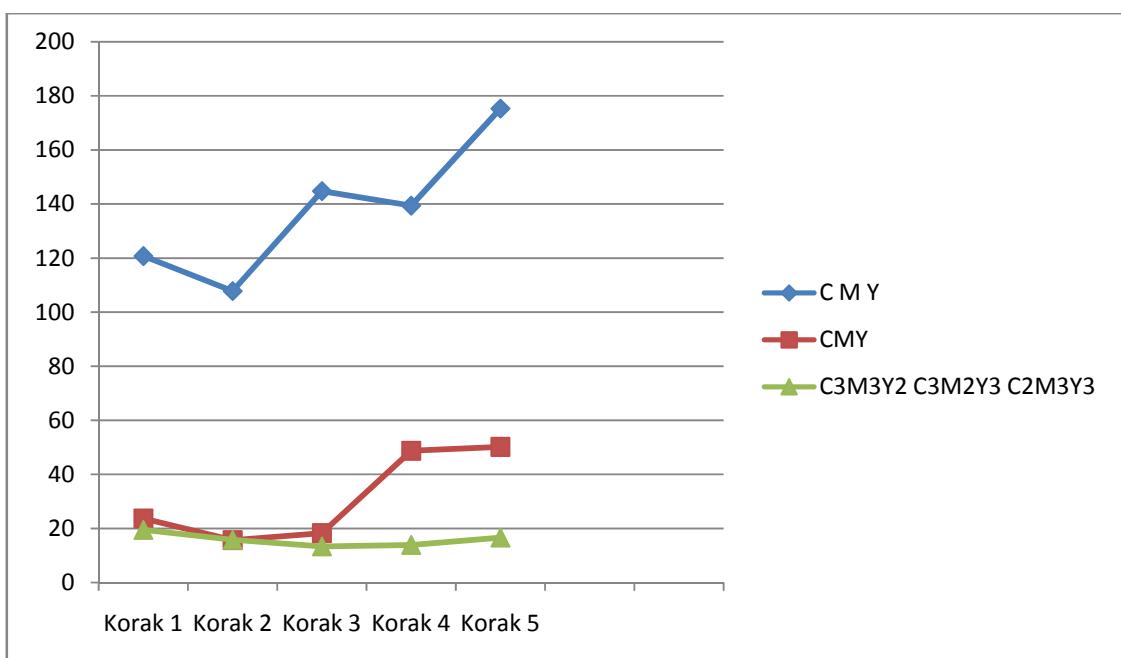
Slika 8.8, F vrijednosti za tri najsigifikantnije skupine članova s kraja postupka eliminacije za proces D



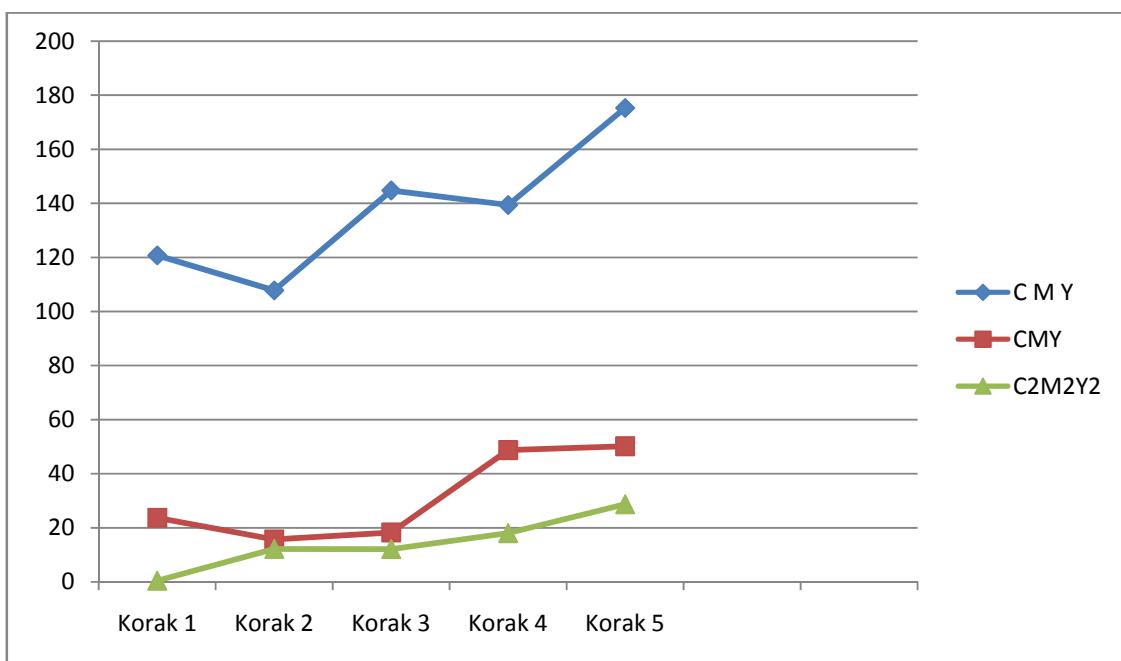
Slika 8.9, F vrijednosti za tri najsigifikantnije skupine članova s početka postupka eliminacije za proces E



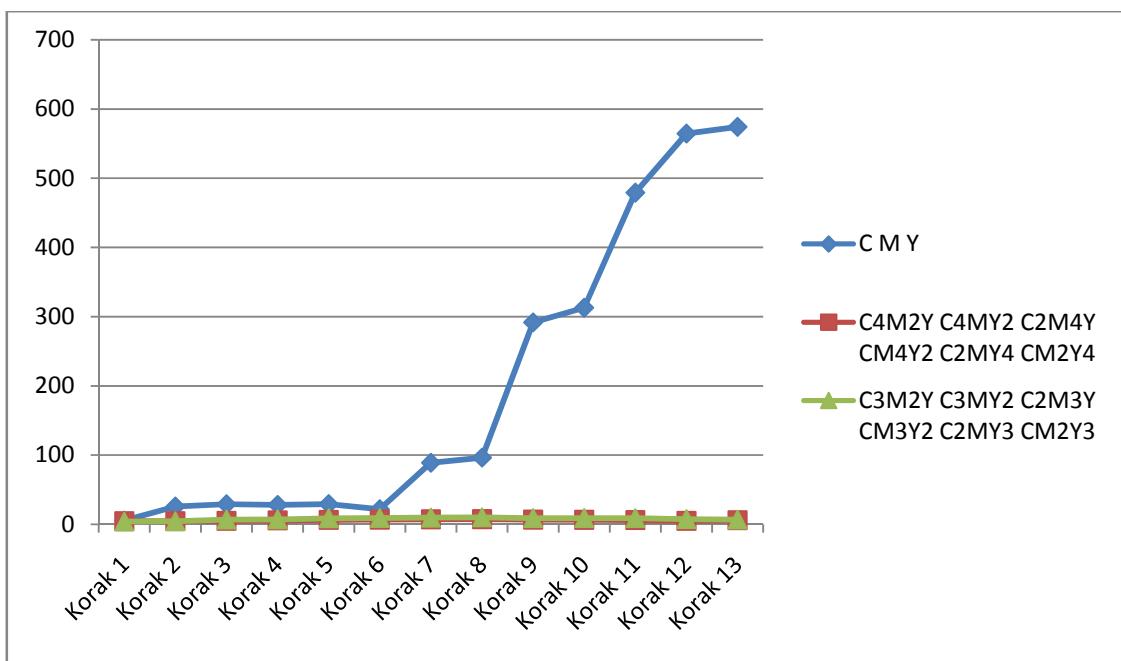
Slika 8.10, F vrijednosti za tri najsigifikantnije skupine članova s kraja postupka eliminacije za proces E



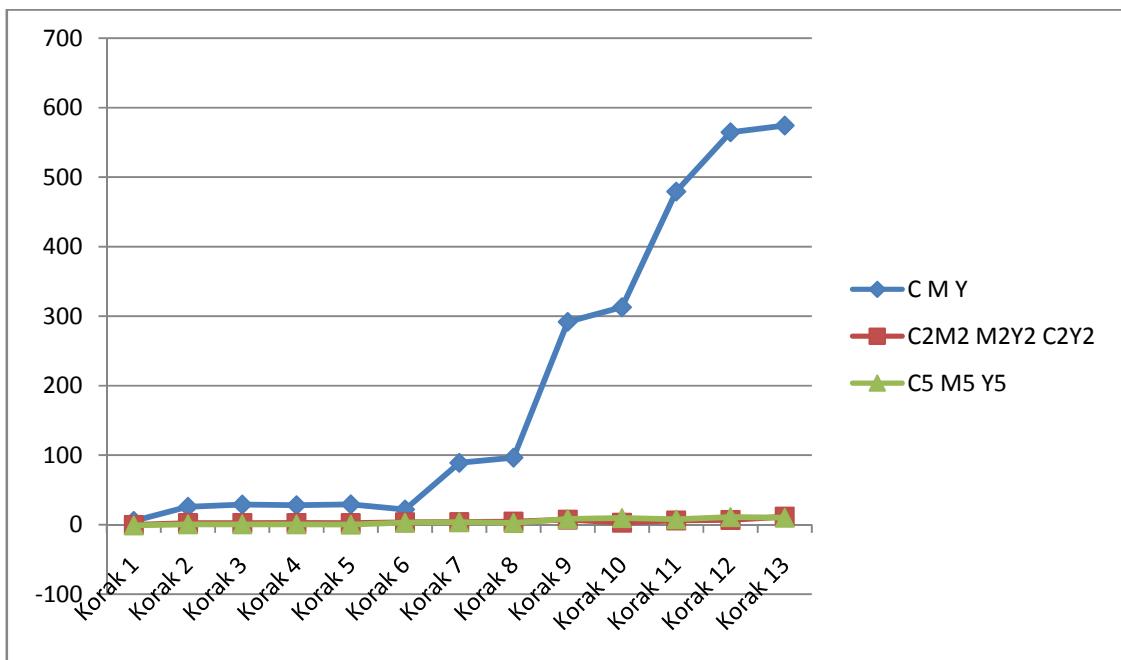
Slika 8.11, F vrijednosti za tri najsigifikantnije skupine članova s početka postupka eliminacije za proces F



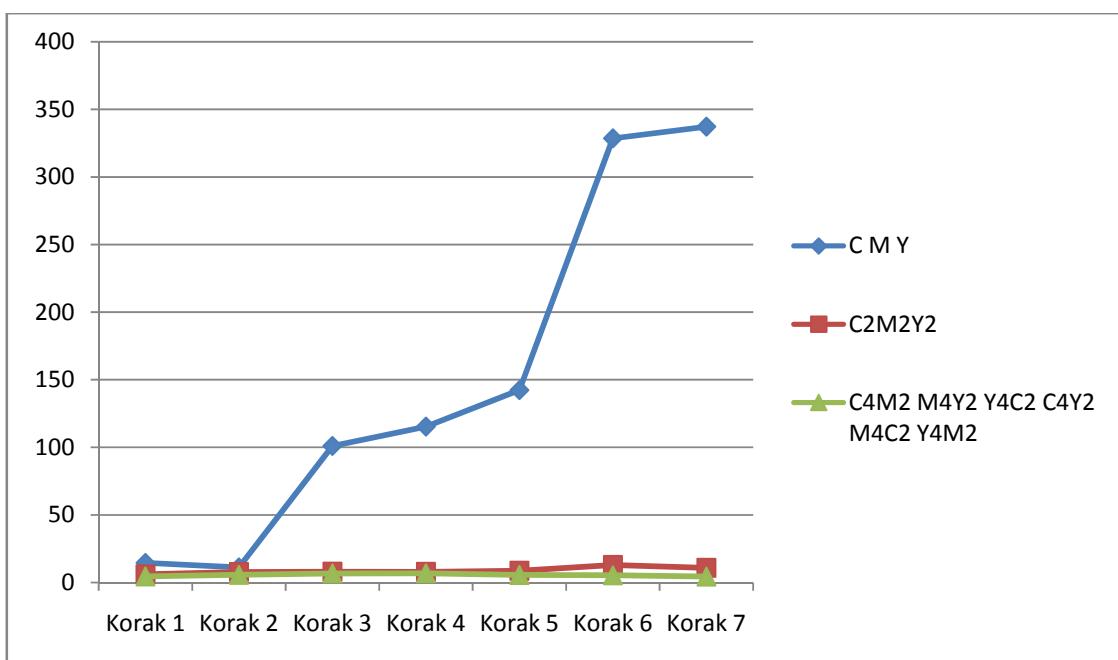
Slika 8.12, F vrijednosti za tri najsigifikantnije skupine članova s kraja postupka eliminacije za proces F



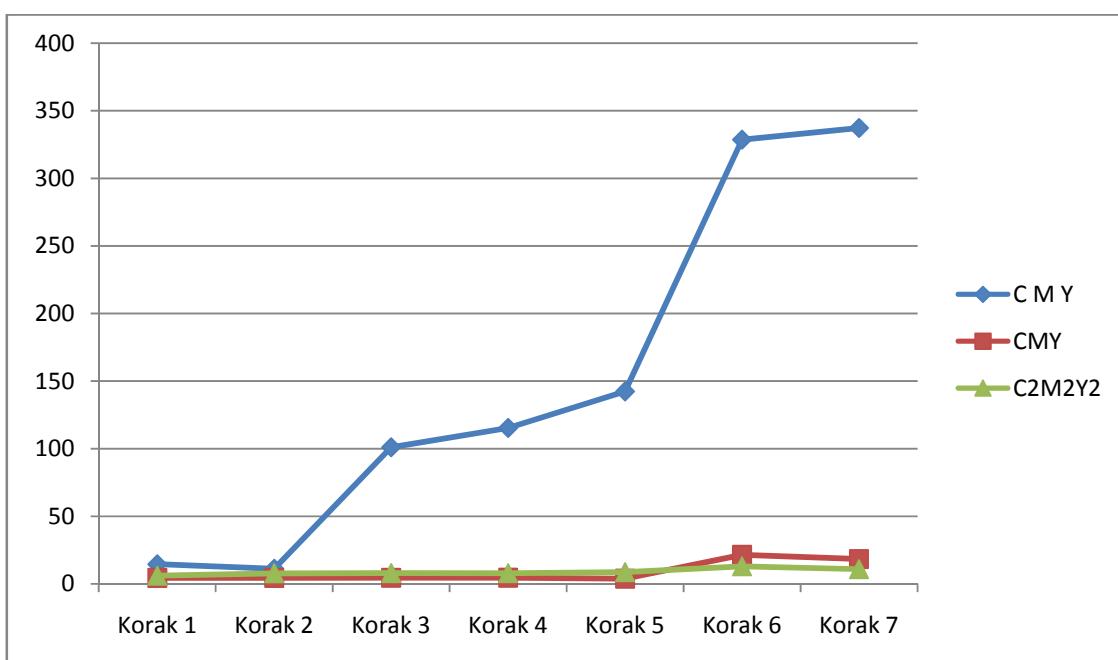
Slika 8.13, F vrijednosti za tri najsigifikantnije skupine članova s početka postupka eliminacije za proces G



Slika 8.14, F vrijednosti za tri najsigifikantnije skupine članova s kraja postupka eliminacije za proces G

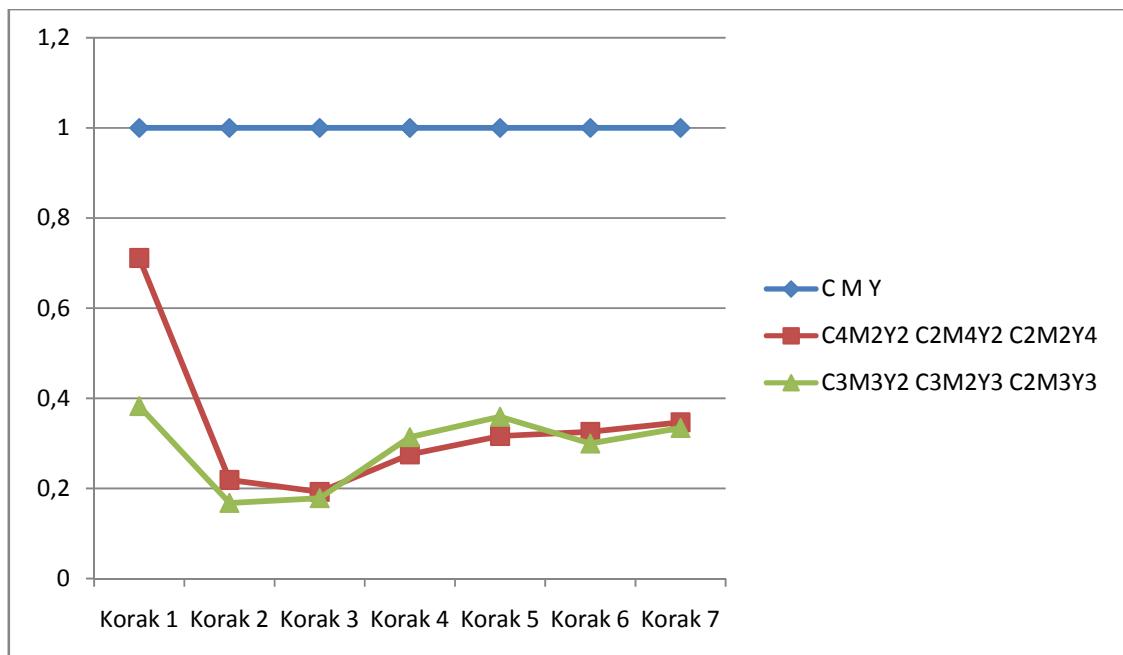


Slika 8.15, F vrijednosti za tri najsigifikantnije skupine članova s početka postupka eliminacije za proces H

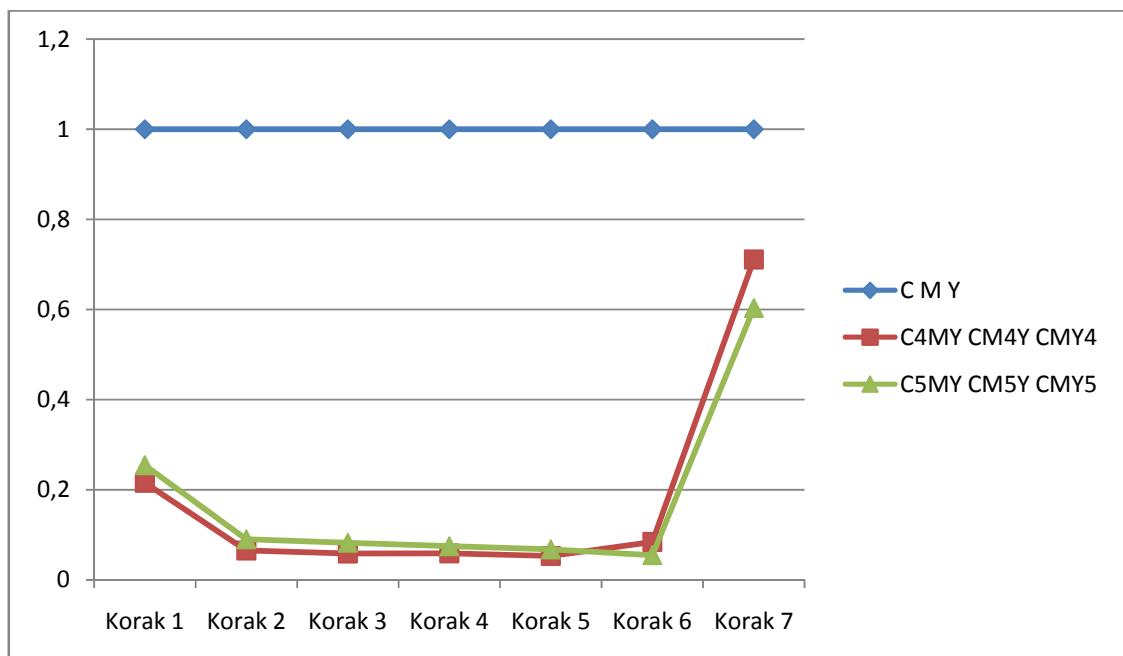


Slika 8.16, F vrijednosti za tri najsigifikantnije skupine članova s početka postupka eliminacije za proces H

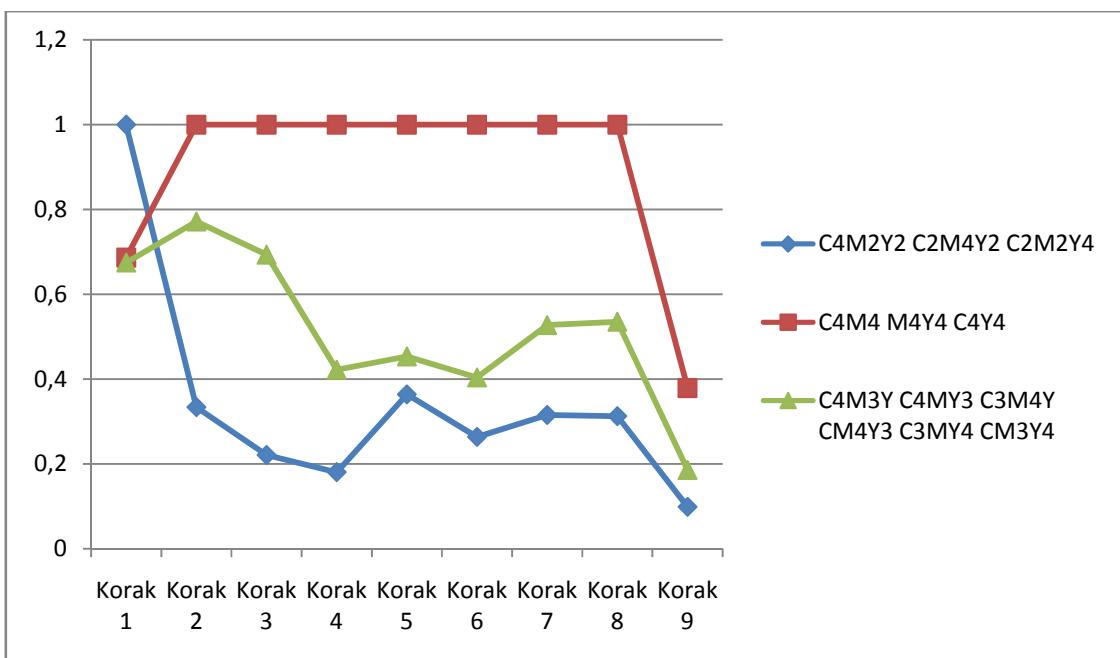
Relativna signifikantnost



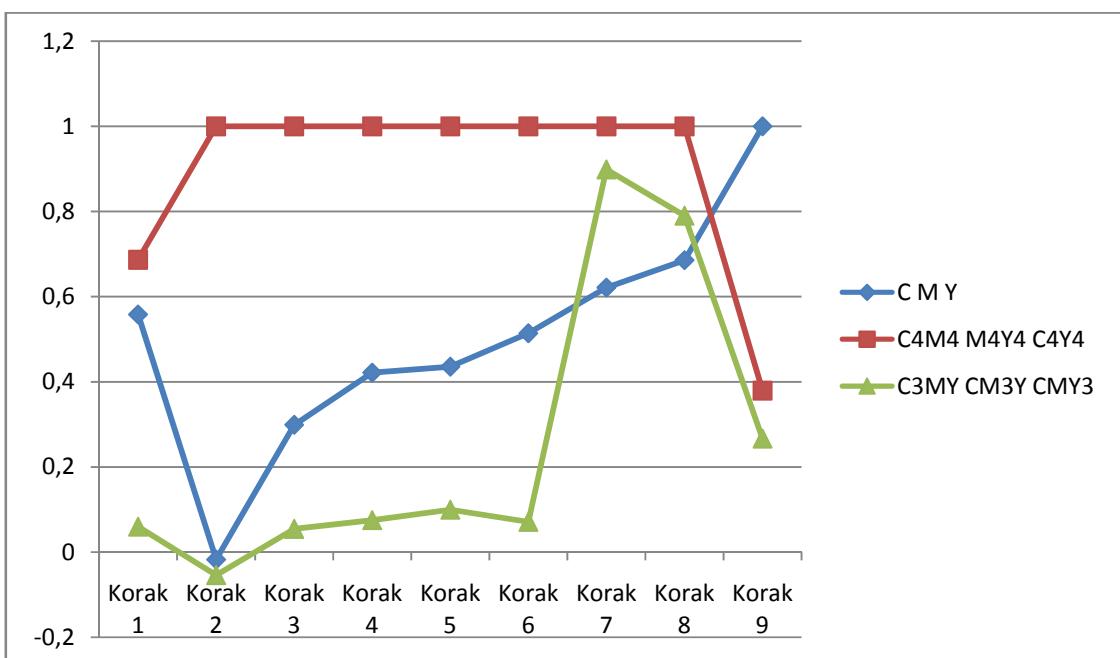
Slika 8.17, relativne F vrijednosti za tri najsigifikantnije skupine članova s početka postupka eliminacije za proces A



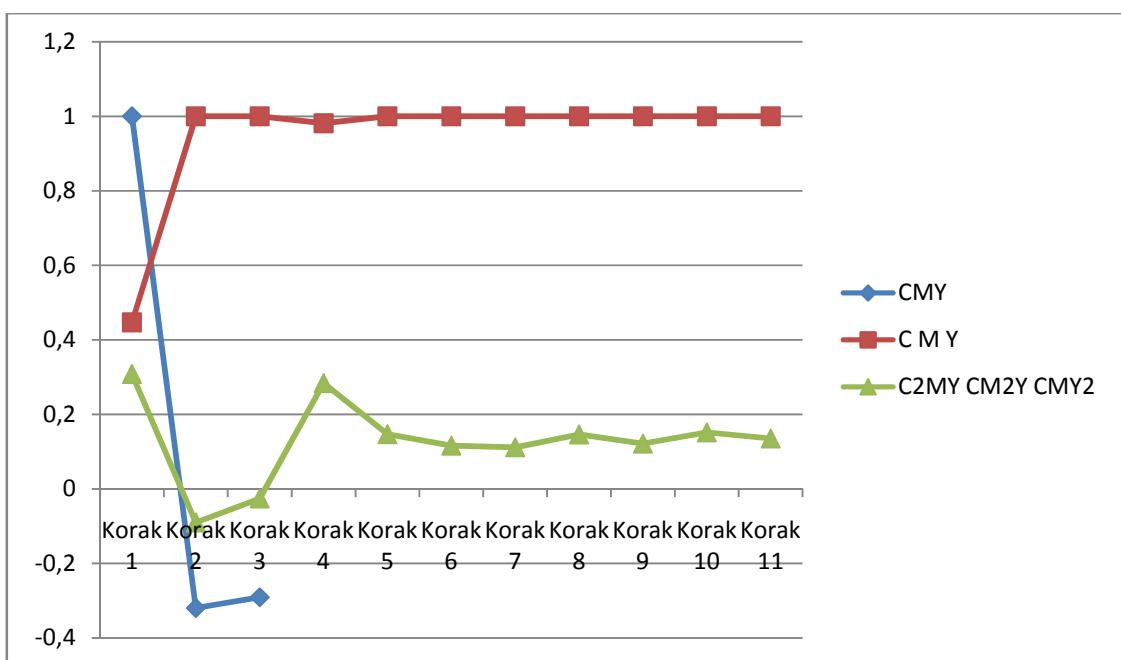
Slika 8.18, relativne F vrijednosti za tri najsigifikantnije skupine članova s kraja postupka eliminacije za proces A



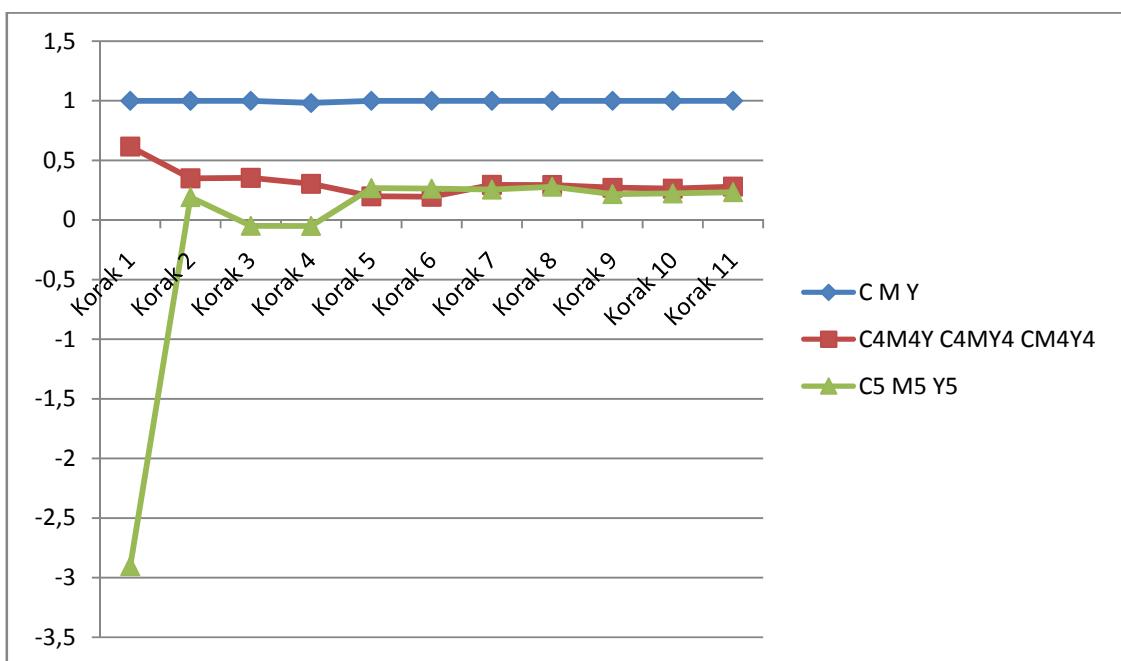
Slika 8.19, relativne F vrijednosti za tri najsignifikantnije skupine članova s početka postupka eliminacije za proces B



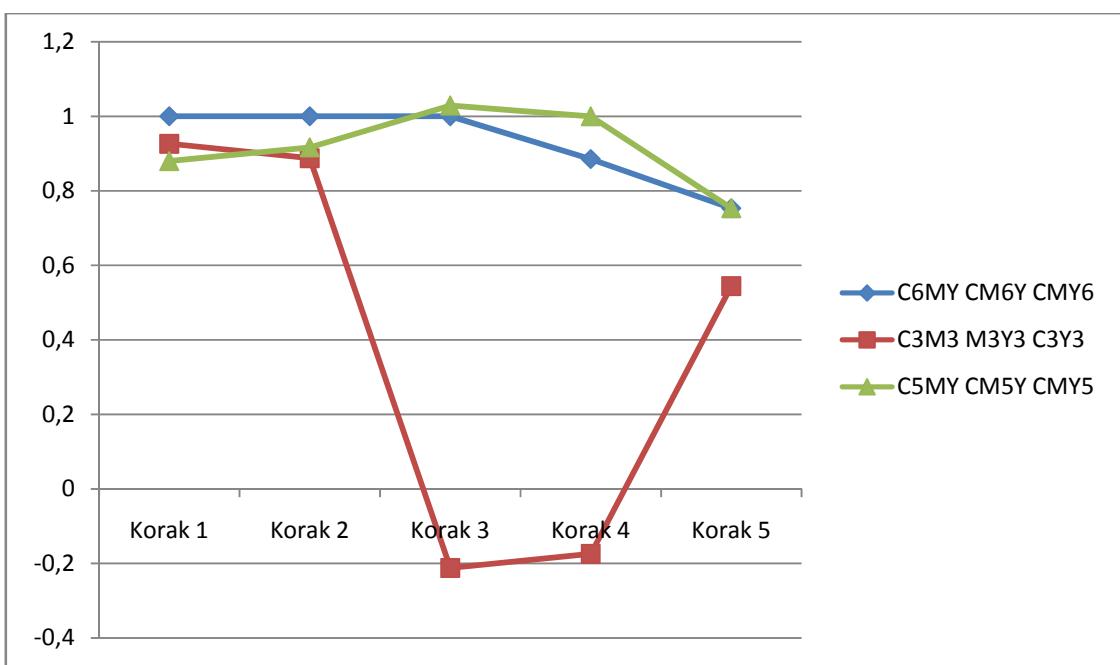
Slika 8.20, relativne F vrijednosti za tri najsignifikantnije skupine članova s kraja postupka eliminacije za proces B



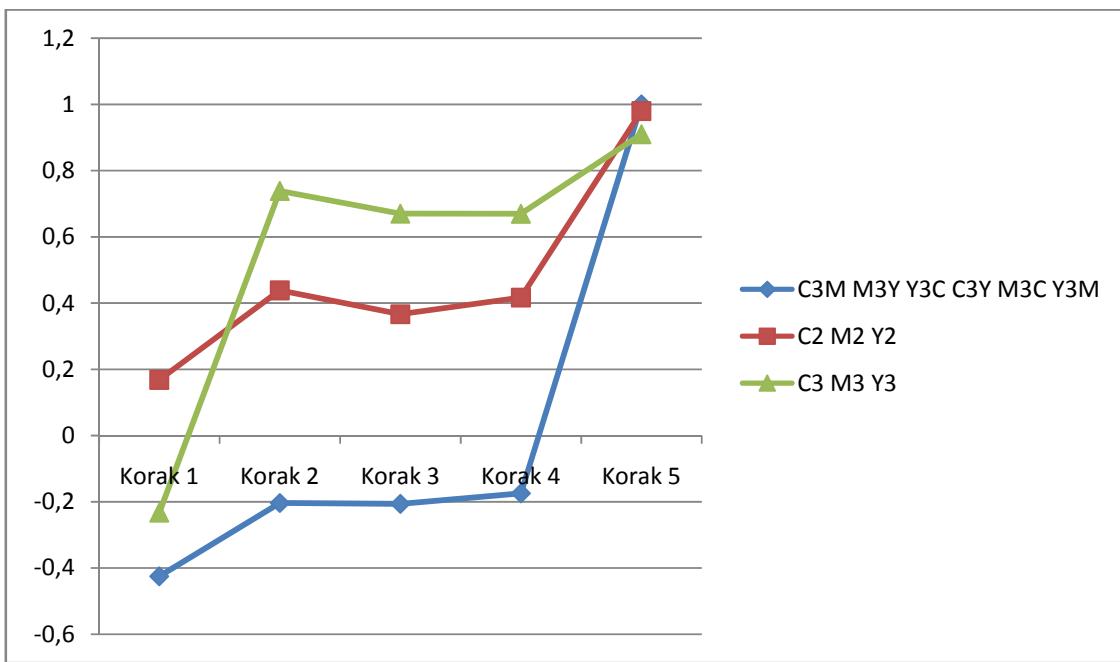
Slika 8.21, relativne F vrijednosti za tri najsignifikantnije skupine članova s početka postupka eliminacije za proces C



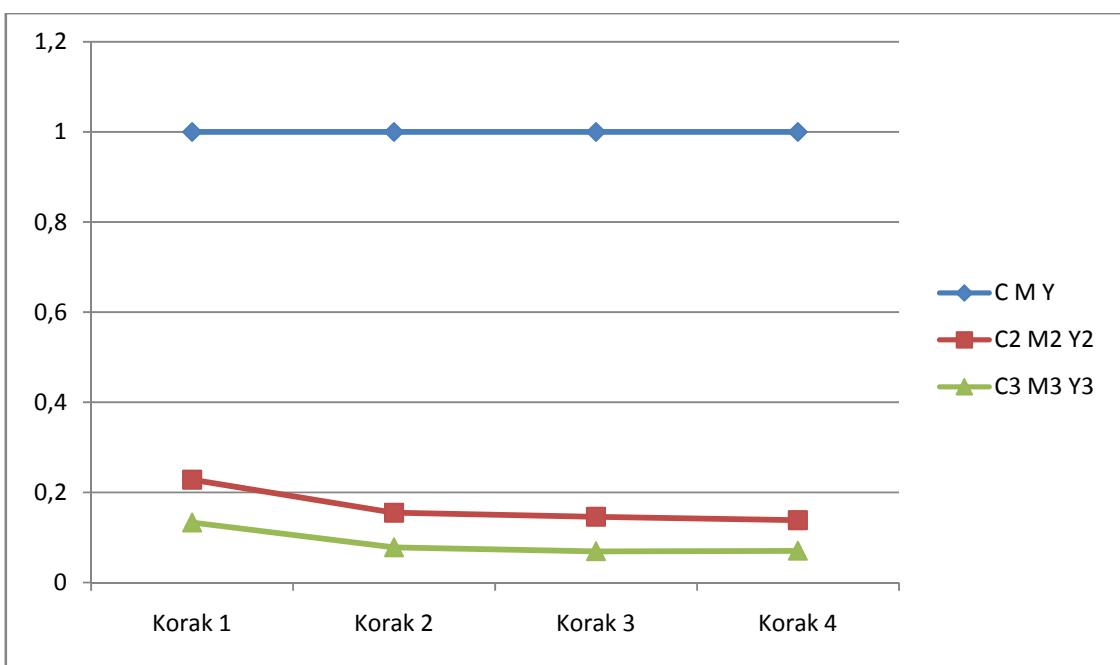
Slika 8.22, relativne F vrijednosti za tri najsignifikantnije skupine članova s kraja postupka eliminacije za proces C



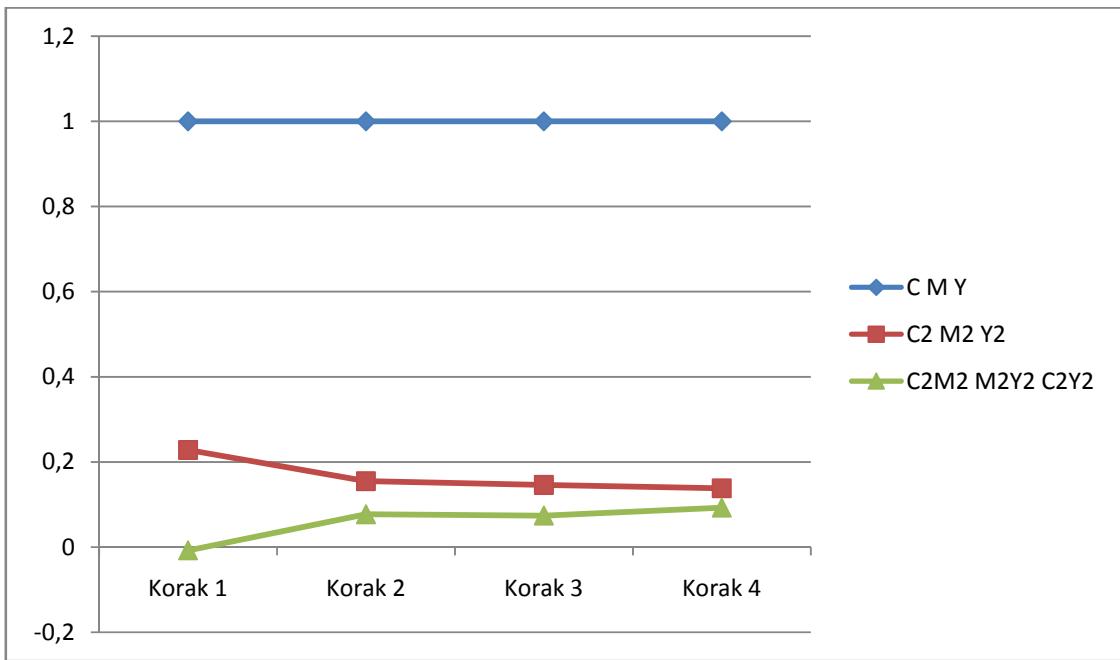
Slika 8.23, relativne F vrijednosti za tri najsigifikantnije skupine članova s početka postupka eliminacije za proces D



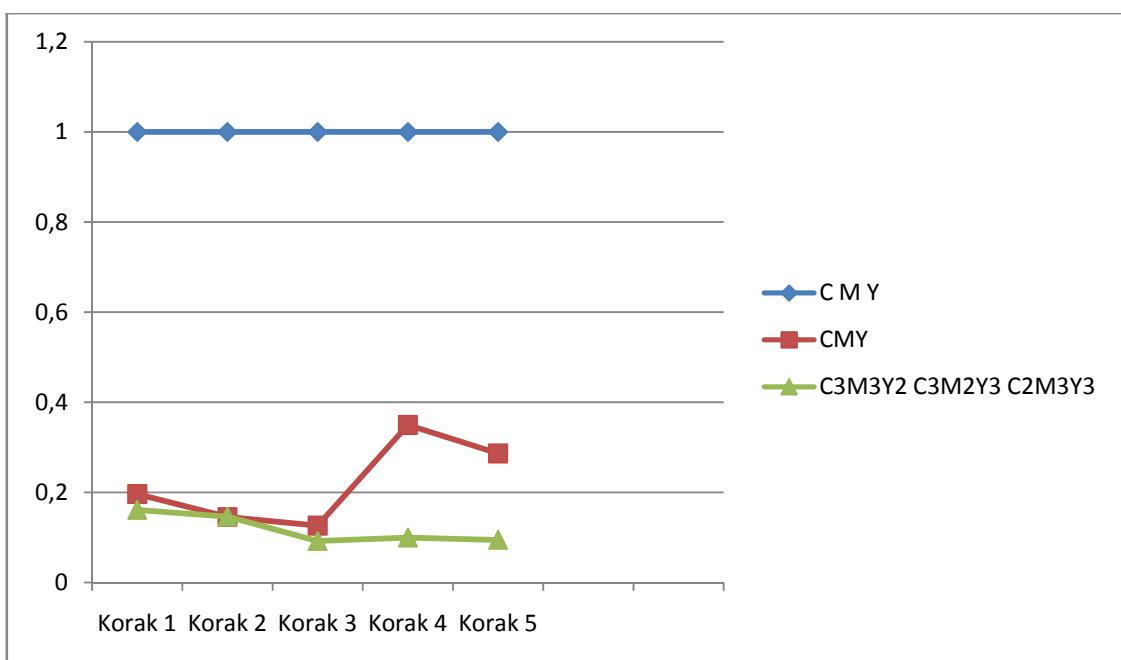
Slika 8.24, relativne F vrijednosti za tri najsigifikantnije skupine članova s kraja postupka eliminacije za proces D



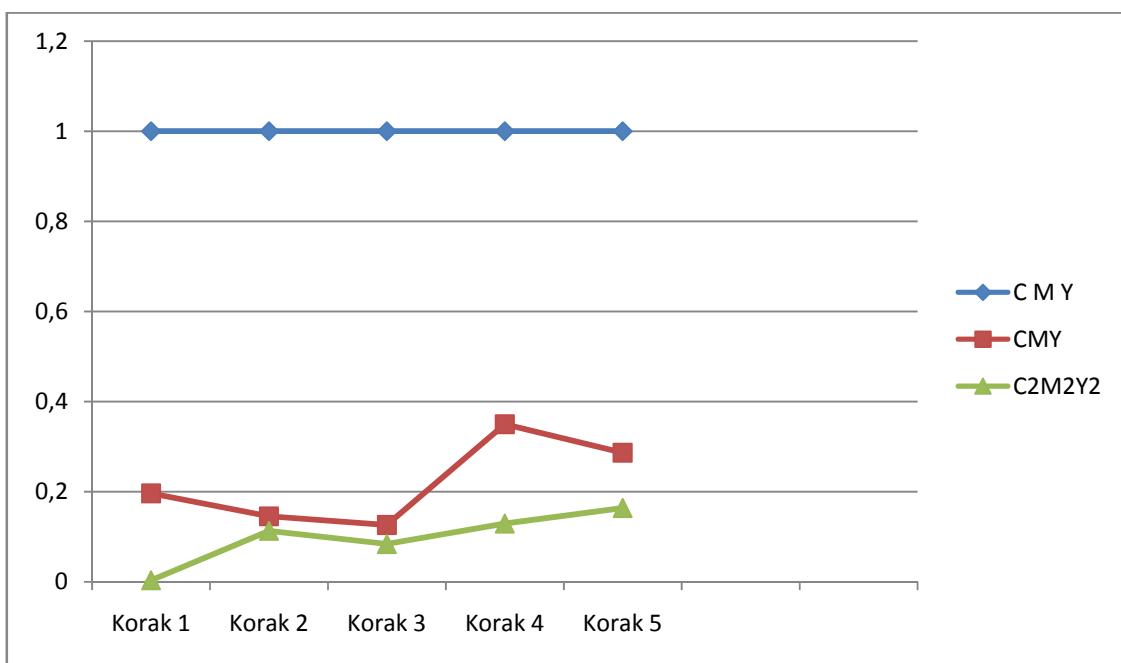
Slika 8.25, relativne F vrijednosti za tri najsignifikantnije skupine članova s početka postupka eliminacije za proces E



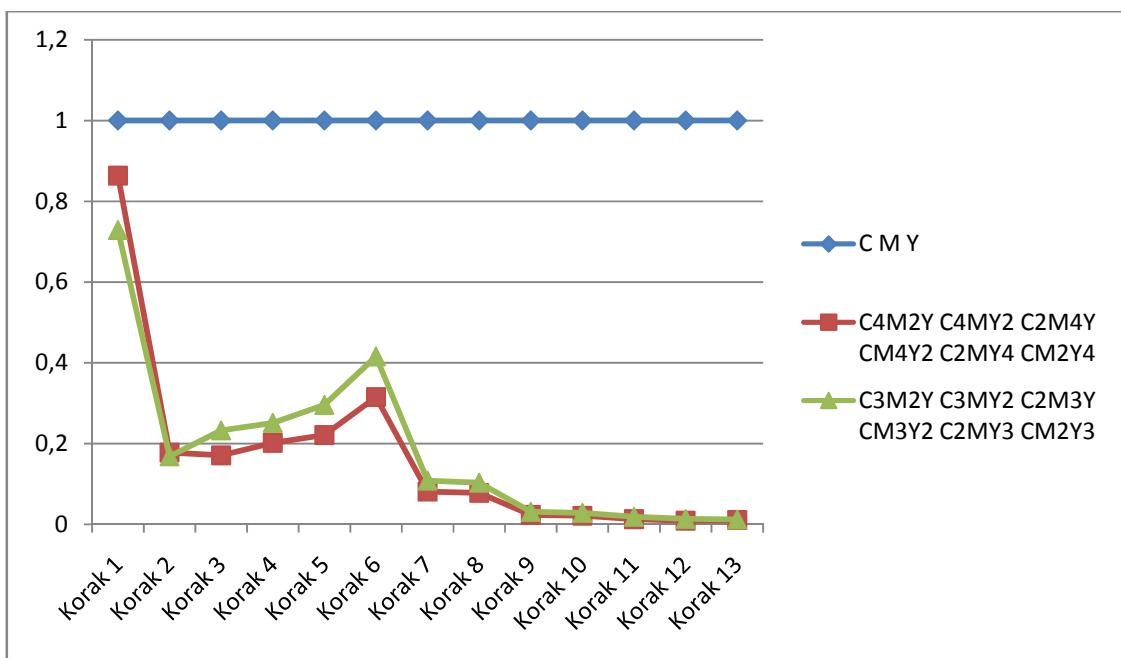
Slika 8.26, relativne F vrijednosti za tri najsignifikantnije skupine članova s kraja postupka eliminacije za proces E



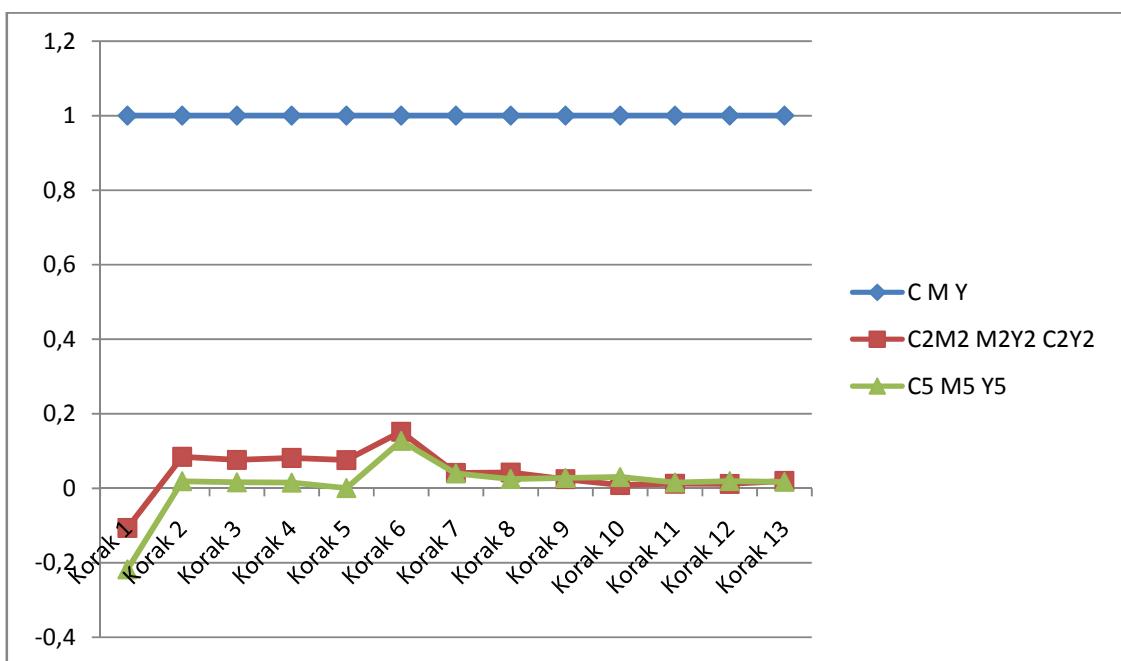
Slika 8.27, relativne F vrijednosti za tri najsigifikantnije skupine članova s početka postupka eliminacije za proces F



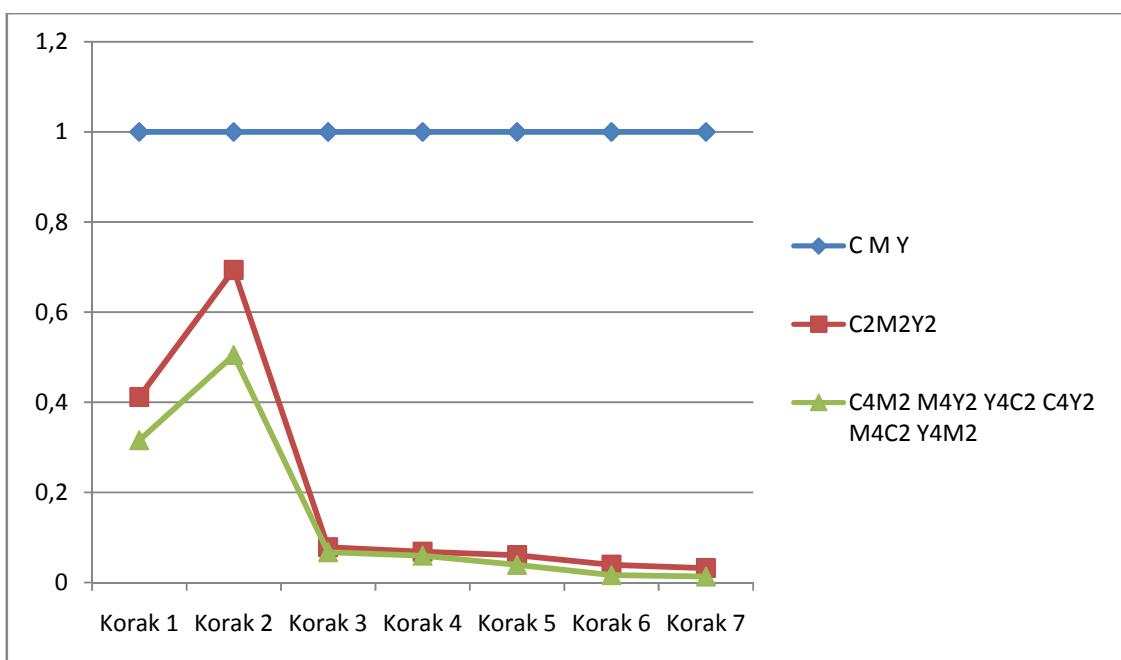
Slika 8.28, relativne F vrijednosti za tri najsigifikantnije skupine članova s kraja postupka eliminacije za proces F



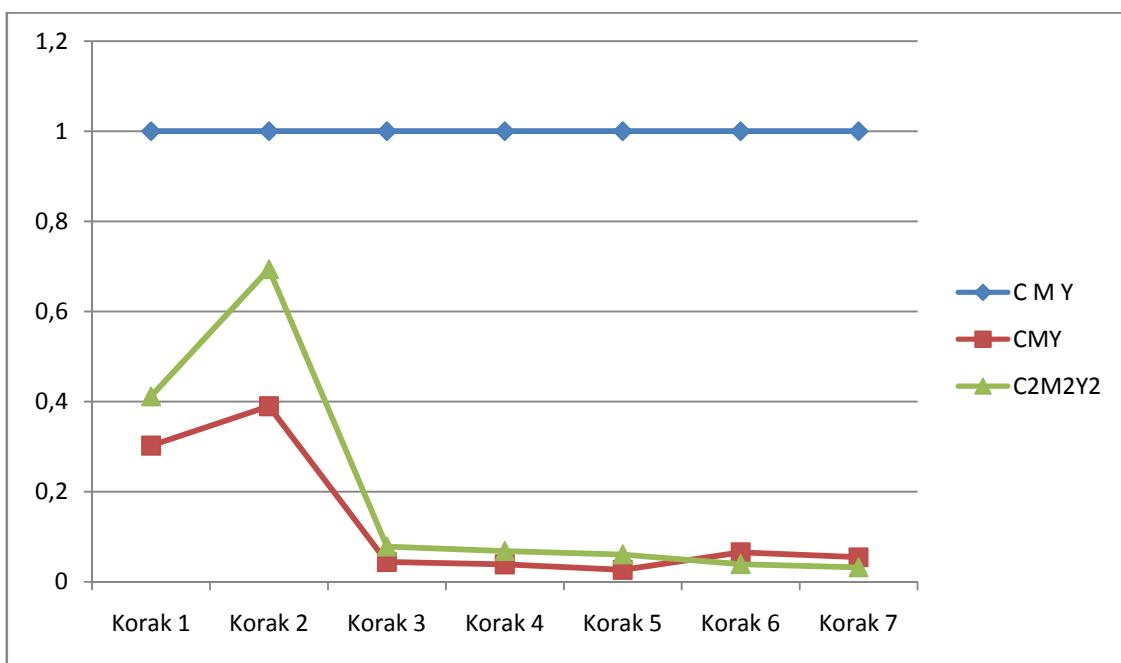
Slika 8.29, relativne F vrijednosti za tri najsignifikantnije skupine članova s početka postupka eliminacije za proces G



Slika 8.30, relativne F vrijednosti za tri najsignifikantnije skupine članova s kraja postupka eliminacije za proces G



Slika 8.31, relativne F vrijednosti za tri najsigifikantnije skupine članova s početka postupka eliminacije za proces H



Slika 8.32, relativne F vrijednosti za tri najsigifikantnije skupine članova s kraja postupka eliminacije za proces H

PROCES A

Tabela 8.10, Eliminirane skupine članova u procesu A

Eliminacijski korak	Skupina članova
2	$C^2 M^2 Y^2$
3	$C^4 M M^4 Y Y^4 C C^4 Y M^4 C Y^4 M$
4	CMY
5	$C^5 M^3 M^5 Y^3 Y^5 C^3 C^5 Y^3 M^5 C^3 Y^5 M^3$
6	$C^4 M^2 Y C^4 M Y^2 C^2 M^4 Y C M^4 Y^2 C^2 M Y^4 C M^2 Y^4$
7	$C^6 M Y C M^6 Y C M Y^6$

Slika 8.1 prikazuje kretanje signifikantnosti tri skupine članova koje su prvome koraku bile najsignifikantnije s obzirom na vrijednost F. Najsignifikantnija skupina članova, C M Y već su u drugome koraku postigli vrlo visoku signifikantnost u odnosu na druge dvije skupine članova, $C^4 M^2 Y^2$ $C^2 M^4 Y$ $C^2 M^2 Y^4$ i $C^3 M^3 Y^2$ $C^3 M^2 Y^3$ $C^2 M^3 Y^3$. Navedene skupine manje signifikantnih članova nisu bitno mijenjale signifikantnost po koracima eliminacije. Slika 8.17 prikazuje relativne signifikantnosti članova. Najsignifikantnija skupina članova, C M Y ostala je najsignifikantnija kroz sve korake eliminacije. Relativna signifikantnost skupina članova $C^4 M^2 Y^2$ $C^2 M^4 Y$ $C^2 M^2 Y^4$ i $C^3 M^3 Y^2$ $C^3 M^2 Y^3$ $C^2 M^3 Y^3$ u drugome je koraku smanjena i do kraja se nije bitno mijenjala. Do toga je smanjenja došlo zbog naglog rasta signifikantnosti skupine članova C M Y.

Slika 8.2 prikazuje kretanje signifikantnosti tri skupine članova koje su u zadnjem koraku eliminacije bile najsignifikantnije s obzirom na vrijednost F. Vidljivo je kako je skupina članova C M Y koja je bila najsignifikantnija skupina na početku postupka eliminacije ostala najsignifikantnija do kraja postupka. No, skupine članova $C^4 M^2 Y^2$ $C^2 M^4 Y$ $C^2 M^2 Y^4$ i $C^3 M^3 Y^2$ $C^3 M^2 Y^3$ $C^2 M^3 Y^3$ koje su na početku po signifikantnosti bile na drugome i trećem mjestu, na kraju postupka nisu bile toliko značajne. Njihove su pozicije preuzele članovi $C^4 M Y$ $C M^4 Y$ $C M Y^4$ i $C^5 M Y$ $C M^5 Y$ $C M Y^5$. Zanimljivo je uočiti kako njihova signifikantnost, kao ni relativna signifikantnost (Slika 8.18) nije rasla postupno tijekom eliminacije, već su te skupine članova naglo dobile na značaju u zadnjem koraku eliminacije.

Nagli rast signifikantnosti skupine članova u zadnjem koraku eliminacije vrlo je sličan naglom rastu signifikantnosti skupine članova C M Y u drugome koraku postupka. Stoga je interesantno provjeriti koja je skupina članova bila eliminirana kada je došlo do nagle promjene. U drugome koraku eliminacije došlo je do nagloga rasta signifikantnosti skupine članova C M Y nakon eliminacije skupine članova $C^2 M^2 Y^2$. U sedmome koraku eliminacije došlo je do nagloga rasta signifikantnosti skupine članova $C^4 M Y$ $C M^4 Y$ $C M Y^4$ i $C^5 M Y$ $C M^5 Y$ $C M Y^5$ nakon eliminacije skupine članova $C^6 M Y$ $C M^6 Y$ $C M Y^6$.

Proces B

Tabela 8.11, Eliminirane skupine članova u procesu B

Eliminacijski korak	Skupina članova
2	C ⁸ M ⁸ Y ⁸
3	C ⁴ M ⁴ Y ⁴
4	C ⁶ M M ⁶ Y Y ⁶ C C ⁶ Y M ⁶ C Y ⁶ M
5	C ² M ² Y C ² MY ² CM ² Y ²
6	CM MY CY
7	C ² MY CM ² Y CMY ²
8	C ³ M ² M ³ Y ² Y ³ C ² C ³ Y ² M ³ C ² Y ³ M ²
9	C ² M ² Y ²
10	C ⁷ M M ⁷ Y Y ⁷ C C ⁷ Y M ⁷ C Y ⁷ M

Slika 8.3 prikazuje kretanje signifikantnosti tri skupine članova koje su prve koraku bile najsignifikantnije s obzirom na vrijednost F. Skupina članova C⁴M²Y² C²M⁴Y² C²M²Y⁴ u prve je koraku bila najsignifikantnija, da bi već u drugome koraku postala najmanje signifikantna. Signifikantnost skupine članova C⁴M³Y C⁴MY³ C³M⁴Y CM⁴Y³ C³MY⁴ CM³Y⁴ nije se bitno mijenjala, a signifikantnost skupine članova C⁴M⁴ M⁴Y⁴ C⁴Y⁴ je tijekom postupka eliminacije rasla. Slika 8.19 prikazuje relativne signifikantnosti triju skupina članova. Vidljivo je kako se skupina članova C⁴M⁴ M⁴Y⁴ C⁴Y⁴ od drugoga do osmoga koraka zadržala kao najsignifikantnija, ali je u devetom koraku smanjena zbog naglog rasta signifikantnosti skupine članova C M Y.

Slika 8.4 prikazuje kretanje signifikantnosti tri skupine članova koje su u zadnjem koraku eliminacije bile najsignifikantnije s obzirom na vrijednost F. Uočljivo je da je od tri skupine članova koje su bile najsignifikantnije na početku postupka eliminacije, među tri najsignifikantnije na kraju ostala samo skupina C⁴M⁴ M⁴Y⁴ C⁴Y⁴ i to na drugome mjestu. Prvo i treće mjesto zauzele su skupine članova C M Y i C³MY CM³Y CMY³. Interesantna je činjenica da su te dvije skupine članova u drugome koraku eliminacije imale čak negativnu F vrijednost, da bi u posljednjim koracima postigle relativno visoku značajnost. U šestome je koraku eliminacije došlo do naglog rasta signifikantnosti skupine članova C³MY CM³Y CMY³ nakon eliminacije skupine CM MY CY. Slika 8.20 prikazuje relativne signifikantnosti triju skupina članova koji su bili najsignifikantniji na kraju postupka eliminacije. Vidljivo je da je relativna signifikantnost skupine članova C M Y naglo smanjena nakon eliminacije skupine C⁸ M⁸ Y⁸ te da je kasnije postupno rasla. Relativna signifikantnost skupine članova C³MY CM³Y CMY³ u sedmome se koraku naglo povećala eliminacijom skupine članova C²MY CM²Y CMY². Ovdje je potrebno naglasiti da se one same nisu bitno mijenjale u apsolutnom iznosu, već je došlo do naglog rasta signifikantnosti skupine članova C M Y.

Proces C

Tabela 8.12, Eliminirane skupine članova u procesu C

Eliminacijski korak	Skupina članova
2	$C^4 M^4 Y^4$
3	$C^3 M M^3 Y Y^3 C C^3 Y M^3 C Y^3 M$
4	CMY
5	$C^3 M^3 Y^3$
6	$C^4 M^2 Y^2 C^2 M^4 Y^2 C^2 M^2 Y^4$
7	$C^3 M^3 Y^2 C^3 M^2 Y^3 C^2 M^3 Y^3$
8	$C^2 M^2 Y^2$
9	$C^6 M^2 M^6 Y^2 Y^6 C^2 C^6 Y^2 M^6 C^2 Y^6 M^2$
10	$C^4 M^4 M^4 Y^4 C^4 Y^4$
11	$C^3 M^2 Y^2 C^2 M^3 Y^2 C^2 M^2 Y^3$

Slika 8.5 prikazuje kretanje signifikantnosti tri skupine članova koje su prvo u prvome koraku bile najsignifikantnije s obzirom na vrijednost F. Skupina članova CMY u prvome je koraku bila najsignifikantnija ali je već u drugome koraku, nakon eliminacije skupine članova $C^4 M^4 Y^4$ dobila negativnu F vrijednost te je u četvrtom koraku eliminirana. Skupina članova C M Y u prvome je koraku bila vrlo signifikantna, a postupkom eliminacije signifikantnost joj je rasla i postigla vrlo visoke vrijednosti. Skupina članova $C^2 M^2 Y^2 C^2 M^2 Y^2 C^2 M^2 Y^2$ u prvome je koraku imala relativno visoku vrijednost, ali je već u drugome koraku nakon eliminacije skupine $C^4 M^4 Y^4$ poprimila negativnu F vrijednost. Nakon eliminacije skupine članova CMY signifikantnost skupine $C^2 M^2 Y^2 C^2 M^2 Y^2 C^2 M^2 Y^2$ je porasla i u dalnjim koracima zadržala vrijednost blisku onoj iz prvog koraka. Slika 8.21 prikazuje relativne signifikantnosti triju skupina članova. Vidljivo je da je skupina članova C M Y tijekom gotovo cijelog postupka eliminacije bila najsignifikantnija, a signifikantnost skupine članova $C^2 M^2 Y^2 C^2 M^2 Y^2 C^2 M^2 Y^2$ nije se bitno mijenjala nakon petoga koraka.

Slika 8.6 prikazuje kretanje signifikantnosti tri skupine članova koje su u zadnjem koraku eliminacije bile najsignifikantnije s obzirom na vrijednost F. U slučaju ovoga procesa od tri skupine članova koje su bile najsignifikantnije na početku postupka eliminacije, među tri najsignifikantnije na kraju nije ostala niti jedna od njih. Signifikantnost skupina članova C M Y i $C^4 M^4 Y C^4 M Y^4 C M^4 Y^4$ postupno je rasla tijekom postupka eliminacije. Uočljivo je da je skupina članova $C^5 M^5 Y^5$ u prvome koraku eliminacije imala vrlo nisku negativnu F vrijednost te je postala pozitivna eliminacijom skupine članova $C^4 M^4 Y^4$ u drugome koraku. Znatniju porast signifikantnosti ostvarila je u petome koraku, nakon eliminacije člana $C^3 M^3 Y^3$. Slika 8.22 otkriva da je tijekom cijelog postupka eliminacije najsignifikantnija skupina članova bila C M Y. Osim toga, zornje prikazuje da su skupine članova $C^4 M^4 Y C^4 M Y^4 C M^4 Y^4$ i $C^5 M^5 Y^5$ bile podjednako signifikantne od petoga koraka nadalje, to jest nakon eliminacije člana $C^3 M^3 Y^3$.

Proces D

Tabela 8.13, Eliminirane skupine članova u procesu D

Eliminacijski korak	Skupina članova
2	$C^6 M^6 Y^6$
3	CMY
4	$C^2M^2Y C^2MY^2 CM^2Y^2$
5	CM MY CY
6	$C^3M^3Y^2 C^3M^2Y^3 C^2M^3Y^3$

Slika 8.7 prikazuje kretanje signifikantnosti tri skupine članova koje su prve koraku bile najsignifikantnije s obzirom na vrijednost F. Skupine članova $C^6MY CM^6Y CMY^6$; $C^3M^3 M^3Y^3 C^3Y^3$ i $C^5MY CM^5Y CMY^5$ u prve su koraku bile podjednako signifikantne. U trećem koraku, nakon eliminacije skupine članova CMY, skupina članova $C^3M^3 M^3Y^3 C^3Y^3$ poprimila je negativnu F vrijednost, a u petom je koraku, nakon eliminacije skupine članova CM MY CY, opet postala vrlo signifikantna. Slika 8.23 prikazuje relativne signifikantnosti triju skupina članova i na njih je uočljivo da su na kraju postupka eliminacije sve tri skupine članova zadržale visoke vrijednosti relativne signifikantnosti, ali niti jedna od njih nije bila najsignifikantnija skupina.

Slika 8.8 prikazuje kretanje signifikantnosti tri skupine članova koje su u zadnjem koraku eliminacije bile najsignifikantnije s obzirom na vrijednost F. U slučaju ovoga procesa od tri skupine članova koje su bile najsignifikantnije na početku postupka eliminacije, među tri najsignifikantnije na kraju nije ostala niti jedna od njih. Signifikantnost skupina članova $C^2 M^2 Y^2$ i $C^3 M^3 Y^3$ tijekom procesa eliminacije članova rasla je postupno. Skupina članova $C^3 M^3 Y^3$ u prve je koraku imala negativnu vrijednost te je u drugome koraku njena signifikantnost naglo porasla nakon eliminacije skupine članova $C^6 M^6 Y^6$. Skupina članova $C^3M M^3Y Y^3C C^3Y M^3C Y^3M$ tijekom postupka eliminacija zadržavala je negativnu F vrijednost, ali je u petome koraku, nakon eliminacije skupine članova $C^3M^3Y^2 C^3M^2Y^3 C^2M^3Y^3$ postala najsignifikantnija skupina. Slika 8.24 prikazuje relativne signifikantnosti triju skupina članova, ali u slučaju ovoga procesa ne daje dodatne informacije jer do petoga koraka eliminacije niti jedan od triju skupina članova nije bila najsignifikantnija, već je to tek u petome koraku postala skupina članova $C^3M M^3Y Y^3C C^3Y M^3C Y^3M$.

Proces E

Tabela 8.14, Eliminirane skupine članova u procesu E

Eliminacijski korak	Skupina članova
2	CM MY CY
3	C ⁵ MY CM ⁵ Y CMY ⁵
4	C ⁴ M ² Y C ⁴ MY ² C ² M ⁴ Y CM ⁴ Y ² C ² MY ⁴ CM ² Y ⁴
5	C ³ M M ³ Y Y ³ C C ³ Y M ³ C Y ³ M

Slika 8.9 prikazuje kretanje signifikantnosti tri skupine članova koje su prve koraku bile najsignifikantnije s obzirom na vrijednost F. Tijekom cijelog postupka eliminacije najsignifikantnija skupina članova bila je C M Y. Do većega rasta signifikantnosti te skupine članova došlo je u drugome koraku nakon eliminacije skupine članova CM MY CY. Signifikantnost skupina članova C² M² Y² i C³ M³ Y³ nije se bitno mijenjala tijekom postupka eliminacije. Slika 8.25 prikazuje relativne signifikantnosti triju skupina članova. Vidljivo je da je skupina članova C M Y od početka postupka mnogo signifikantnija u odnosu na druge dvije skupine i da je njezina relativna signifikantnost malo rasla tijekom procesa eliminacije.

Slika 8.10 prikazuje kretanje signifikantnosti tri skupine članova koje su u zadnjem koraku eliminacije bile najsignifikantnije s obzirom na vrijednost F. U ovome su se procesu od tri skupine članova koje su bile najsignifikantnije na početku postupka eliminacije, na kraju kao najsignifikantnije održale čak dvije skupine članova. Treća i ujedno najmanje signifikantna postala je skupina članova C²M² M²Y² C²Y². Ta je skupina članova u prve koraku imala negativnu F vrijednost, a signifikantnom je postala u drugome koraku nakon odbacivanja skupine članova CM MY CY. Vrijedi se prisjetiti da je tada došlo i do nagloga rasta signifikantnosti skupine članova C M Y. Slika 8.26 prikazuje relativne signifikantnosti triju skupina članova. Vidljivo je da je skupina C M Y tijekom cijelog postupka eliminacije bila najsignifikantnija skupina članova.

Proces F

Tabela 8.15, Eliminirane skupine članova u procesu F

Eliminacijski korak	Skupina članova
2	$C^7 M^7 Y^7$
3	$C^5M^2 M^5Y^2 Y^5C^2 C^5Y^2 M^5C^2 Y^5M^2$
4	$C^3M^2Y C^3MY^2 C^2M^3Y CM^3Y^2 C^2MY^3 CM^2Y^3$
5	$C^3MY CM^3Y CMY^3$
6	$C^5M^3 M^5Y^3 Y^5C^3 C^5Y^3 M^5C^3 Y^5M^3$

Slika 8.11 prikazuje kretanje signifikantnosti tri skupine članova koje su prve koraku bile najsignifikantnije s obzirom na vrijednost F. Tijekom postupka eliminacije signifikantnost skupine članova C M Y je oscilirala, ali je u generalnom trendu rasla. Skupina članova CMY nakon blažega pada u prva tri koraka znatno je porasla u četvrtome koraku nakon eliminacije skupine članova $C^3M^2Y C^3MY^2 C^2M^3Y CM^3Y^2 C^2MY^3 CM^2Y^3$. Treba uočiti da je u istome koraku došlo do blažega pada signifikantnosti najsignifikantnije skupine članova, C M Y . Signifikantnost treće skupine članova, $C^3M^3Y^2 C^3M^2Y^3 C^2M^3Y^3$, je blago opadala tijekom postupka eliminacije, a u petome je koraku blago porasla, kao i druge dvije skupine, nakon eliminacije skupine članova $C^3MY CM^3Y CMY^3$. Slika 8.25 prikazuje relativne signifikantnosti triju skupina članova. Skupina članova C M Y od početka postupka je mnogo signifikantnija u odnosu na druge dvije skupine i njezina je relativna signifikantnost tijekom procesa eliminacije malo rasla, a u četvrtome koraku eliminacije je smanjena.

Slika 8.12 prikazuje kretanje signifikantnosti tri skupine članova koje su u zadnjem koraku eliminacije bile najsignifikantnije s obzirom na vrijednost F. U ovome su se procesu od tri skupine članova koje su bile najsignifikantnije na početku postupka eliminacije, na kraju kao najsignifikantnije održale dvije skupine članova. Treća i ujedno najmanje signifikantna postala je skupina članova $C^2M^2Y^2$. Ta je skupina članova u prve koraku imala vrlo nisku F vrijednost, a u dalnjim je koracima eliminacije rasla postupno. Slika 8.28 prikazuje relativne signifikantnosti triju skupina članova. Vidljivo je da je skupina C M Y tijekom cijelog postupka eliminacije bila najsignifikantnija skupina članova. Relativna signifikantnost skupine članova $C^2M^2Y^2$ tijekom postupka eliminacije je rasla u generalnom trendu. Niti u jednome koraku nije došlo do većih promjena.

Proces G

Tabela 8.16, Eliminirane skupine članova u procesu G

Eliminacijski korak	Skupina članova
2	C ³ M M ³ Y Y ³ C C ³ Y M ³ C Y ³ M
3	CMY
4	C ² M ² Y ²
5	C ³ MY CM ³ Y CMY ³
6	C ⁴ M ⁴ Y ⁴
7	C ² M ² Y ²
8	C ⁴ M ³ M ⁴ Y ³ Y ⁴ C ³ C ⁴ Y ³ M ⁴ C ³ Y ⁴ M ³
9	C ³ M ³ Y ³
10	C ³ M ³ M ³ Y ³ C ³ Y ³
11	C ⁵ M M ⁵ Y Y ⁵ C C ⁵ Y M ⁵ C Y ⁵ M
12	C ⁵ M ² M ⁵ Y ² Y ⁵ C ² C ⁵ Y ² M ⁵ C ² Y ⁵ M ²
13	C ⁴ M ² M ⁴ Y ² Y ⁴ C ² C ⁴ Y ² M ⁴ C ² Y ⁴ M ²
14	C ⁴ M M ⁴ Y Y ⁴ C C ⁴ Y M ⁴ C Y ⁴ M

Slika 8.13 prikazuje kretanje signifikantnosti tri skupine članova koje su prвome koraku bile najsignifikantnije s obzirom na vrijednost F. I u ovome je slučaju tijekom cijelog postupka eliminacije najsignifikantnija od tri skupine članova bila C M Y. Druge dvije skupine članova, C⁴M²Y C⁴MY² C²M⁴Y CM⁴Y² C²MY⁴ CM²Y⁴ i C³M²Y C³MY² C²M³Y CM³Y² C²MY³ CM²Y³ nisu bitno mijenjale signifikantnost tijekom postupka eliminacije. Najsignifikantnija skupina članova, C M Y, počela je naglje rasti nakon šestoga koraka eliminacije, to jest nakon odbacivanja skupine članova C⁴ M⁴ Y⁴. Slika 8.29 prikazuje relativne signifikantnosti tri skupine članova koje su bile najsignifikantnije u prвome koraku postupka eliminacije. Uočljivo je da je i u slučaju ovoga procesa skupina članova C M Y bila najsignifikantnija od svih skupina tijekom cijelog postupka eliminacije. Druge dvije skupine članova, C⁴M²Y C⁴MY² C²M⁴Y CM⁴Y² C²MY⁴ CM²Y⁴ i C³M²Y C³MY² C²M³Y CM³Y² C²MY³ CM²Y³, slijedile su sličan trend kroz sve korake postupka eliminacije. Za razliku od prethodnog prikaza, na ovome je uočljivo da je u drugome koraku eliminacije zbog naglog rasta signifikantnosti skupine članova C M Y došlo do naglog smanjenja relativne signifikantnosti skupine članova C⁴M²Y C⁴MY² C²M⁴Y CM⁴Y² C²MY⁴ CM²Y⁴ i C³M²Y C³MY² C²M³Y CM³Y² C²MY³ CM²Y³. U tom je koraku odbačena skupina članova C³M M³Y Y³C C³Y M³C Y³M.

Slika 8.14 prikazuje kretanje signifikantnosti tri skupine članova koje su u zadnjem koraku eliminacije bile najsignifikantnije s obzirom na vrijednost F. U ovome se procesu od tri skupine članova koje su bile najsignifikantnije na početku postupka eliminacije, na kraju kao najsignifikantnija održala samo jedna skupina članova, C M Y. Druge dvije skupine članova, C²M² M²Y² C²Y² i C⁵ M⁵ Y⁵ tijekom cijelog postupka eliminacije imale su malu signifikantnost i u absolutnom i u relativnom iznosu, a u prвome koraku čak i negativnu F vrijednost.

Proces H

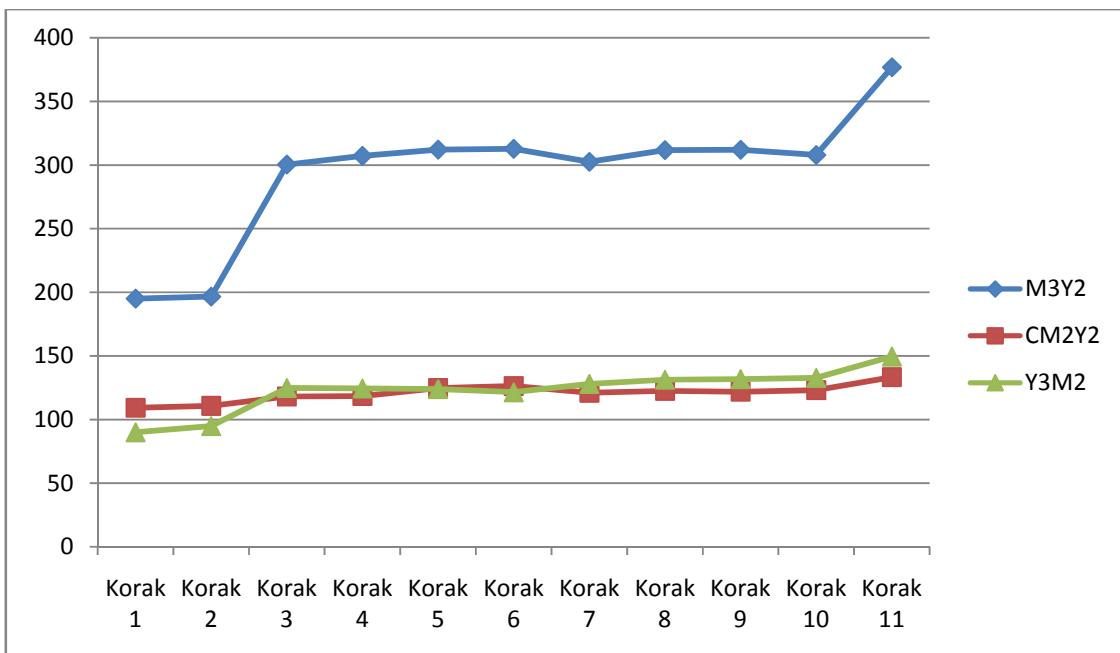
Tabela 8.17, Eliminirane skupine članova u procesu H

Eliminacijski korak	Skupina članova
2	$C^4 M^4 Y^4$
3	$C^2 M^2 Y^2$
4	$C^3 M^3 M^3 Y^3 C^3 Y^3$
5	$C^4 M M^4 Y Y^4 C C^4 Y M^4 C Y^4 M$
6	$CM MY CY$
7	$C^4 MY CM^4 Y CMY^4$
8	$C^3 M^2 Y C^3 M Y^2 C^2 M^3 Y CM^3 Y^2 C^2 M Y^3 CM^2 Y^3$

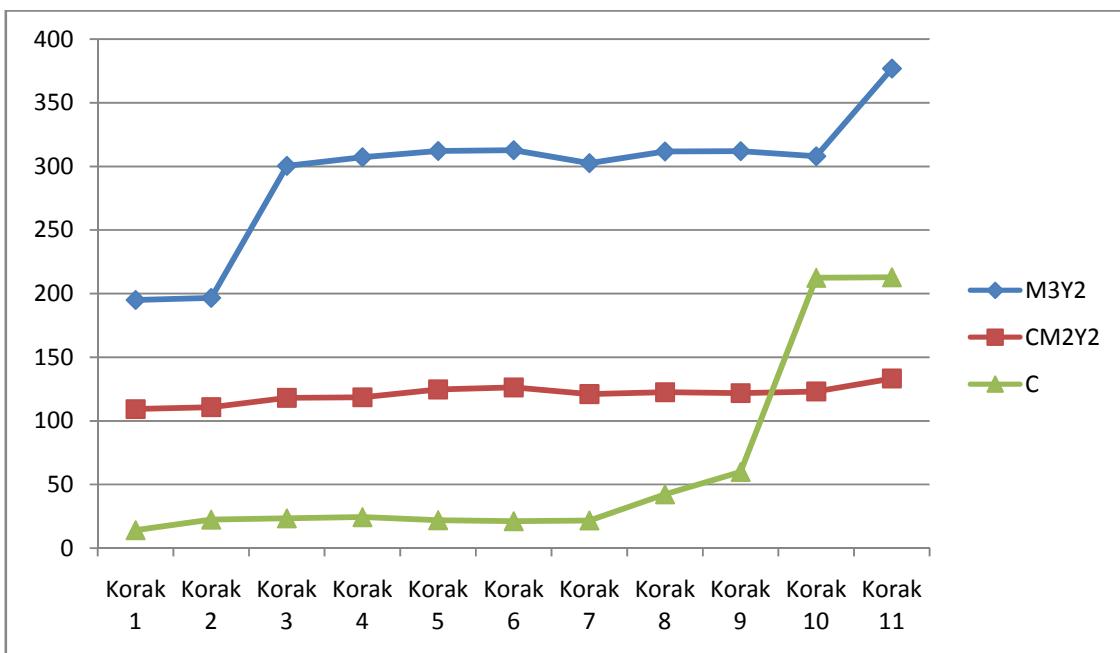
Slika 8.15 prikazuje kretanje signifikantnosti tri skupine članova koje su prve koraku bile najsignifikantnije s obzirom na vrijednost F. Tijekom cijelog postupka eliminacije najsignifikantnija od tri skupine članova bila je $C M Y$. Druge dvije skupine članova, $C^2 M^2 Y^2$ i $C^4 M^2 M^4 Y^2 Y^4 C^2 C^4 Y^2 M^4 C^2 Y^4 M^2$ nisu bitno mijenjale signifikantnost tijekom postupka eliminacije. Slika 8.31 prikazuje relativne signifikantnosti tri skupine članova koje su bile najsignifikantnije u prve koraku postupka eliminacije. Uočljivo je da je skupina članova $C M Y$ bila najsignifikantnija od svih skupina tijekom cijelog postupka eliminacije. U trećem koraku eliminacije, nakon izbacivanja skupine članova $C^2 M^2 Y^2$ došlo je do znatnog pada signifikantnosti skupina članova $C^2 M^2 Y^2$ i $C^4 M^2 M^4 Y^2 Y^4 C^2 C^4 Y^2 M^4 C^2$. Iz oba je prikaza vidljivo da su skupine članova $C^2 M^2 Y^2$ i $C^4 M^2 M^4 Y^2 Y^4 C^2 C^4 Y^2 M^4 C^2$ slijedile sličan trend tijekom postupka eliminacije.

Slika 8.16 prikazuje kretanje signifikantnosti tri skupine članova koje su u zadnjem koraku eliminacije bile najsignifikantnije s obzirom na vrijednost F. U ovome su se procesu od tri skupine članova koje su bile najsignifikantnije na početku postupka eliminacije, na kraju kao najsignifikantnije održale dvije skupine članova. Treća skupina članova postala je CMY . Iz prikaza trenda absolutne signifikantnosti, a i iz prikaza trenda relativne signifikantnosti (Slika 8.32) uočljivo je da skupina članova CMY slijedi sličan trend kao i skupina članova $C^2 M^2 Y^2$.

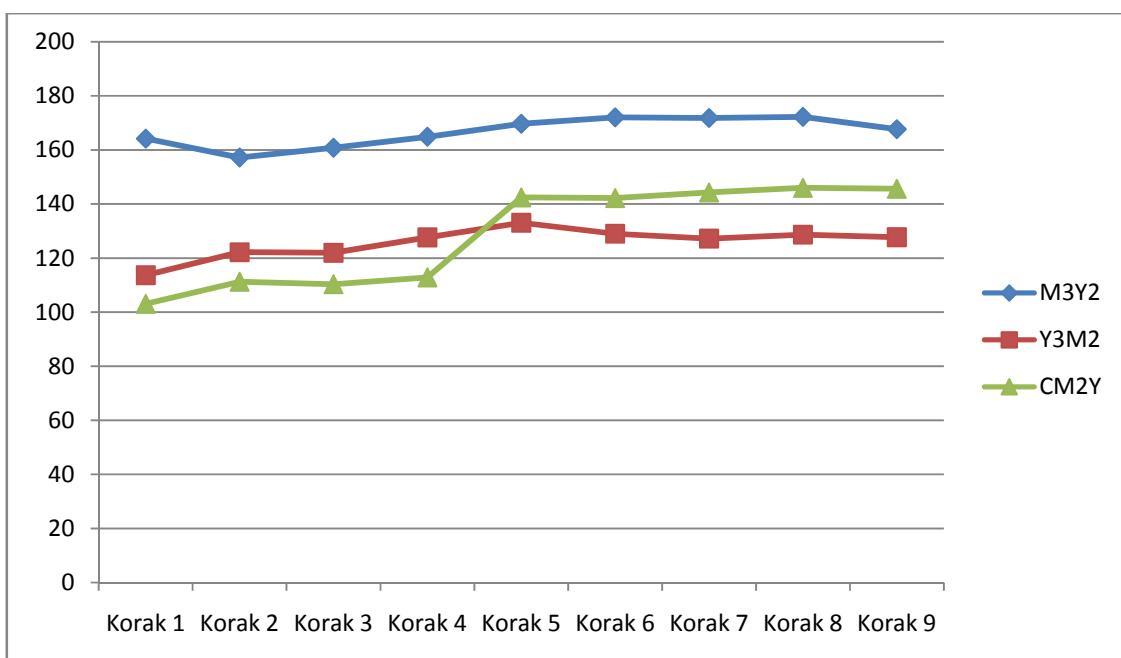
Apsolutne signifikantnosti



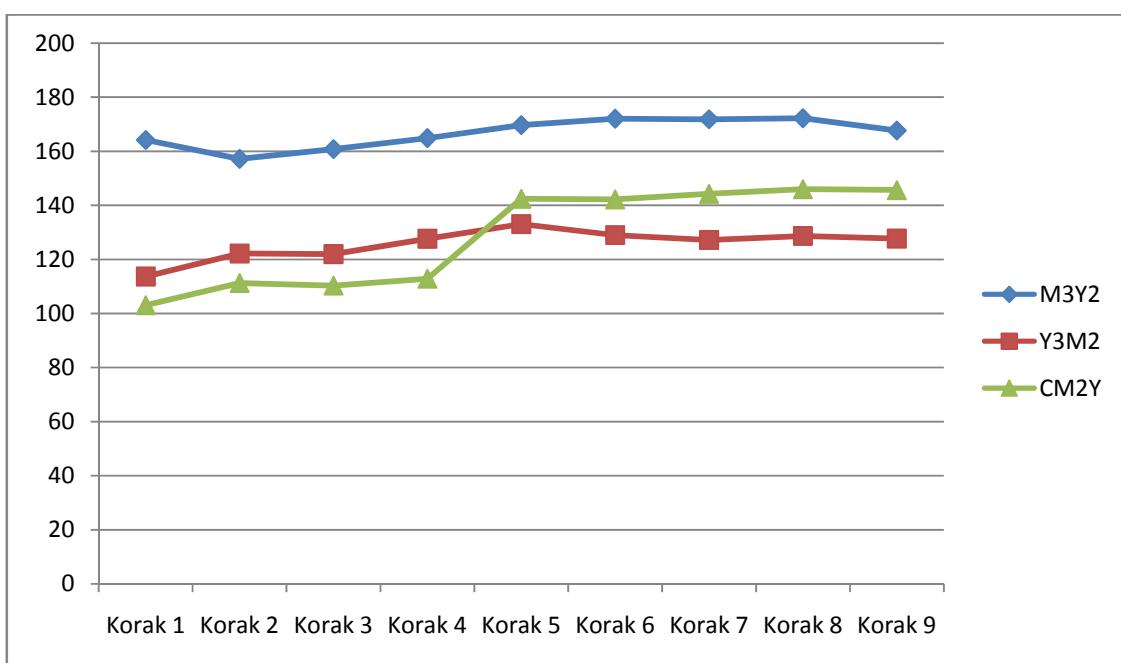
Slika 8.33, F vrijednosti za tri najsigifikantnija člana s početka postupka eliminacije za proces A



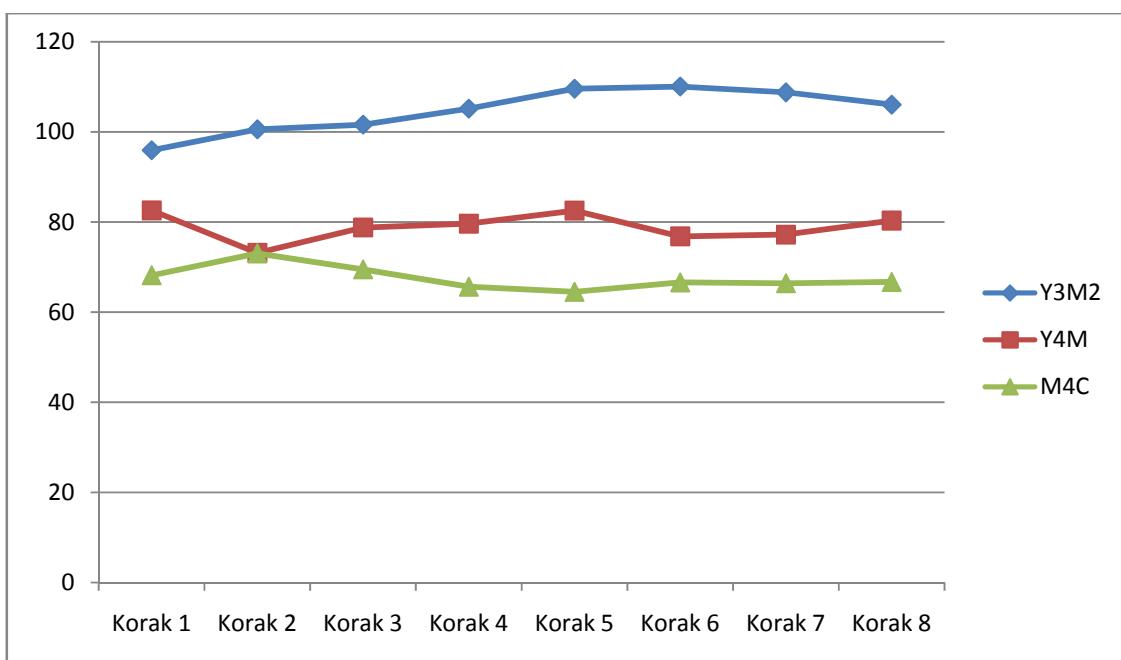
Slika 8.34, F vrijednosti za tri najsigifikantnija člana s kraja postupka eliminacije za proces A



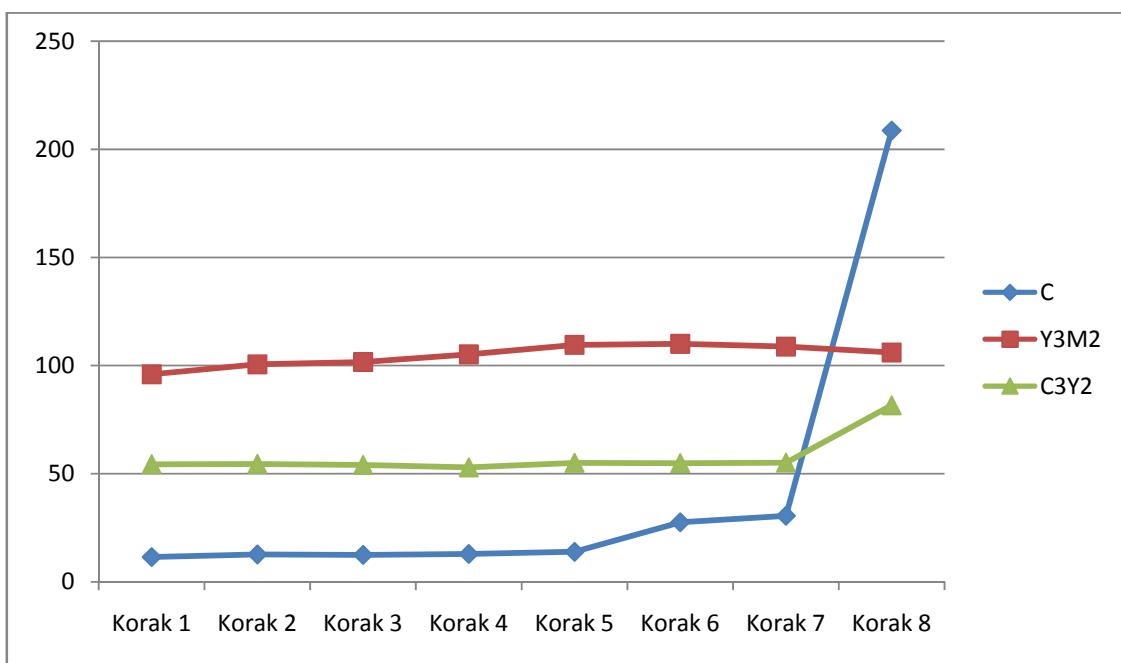
Slika 8.35, F vrijednosti za tri najsignifikantnija člana s početka postupka eliminacije za proces B



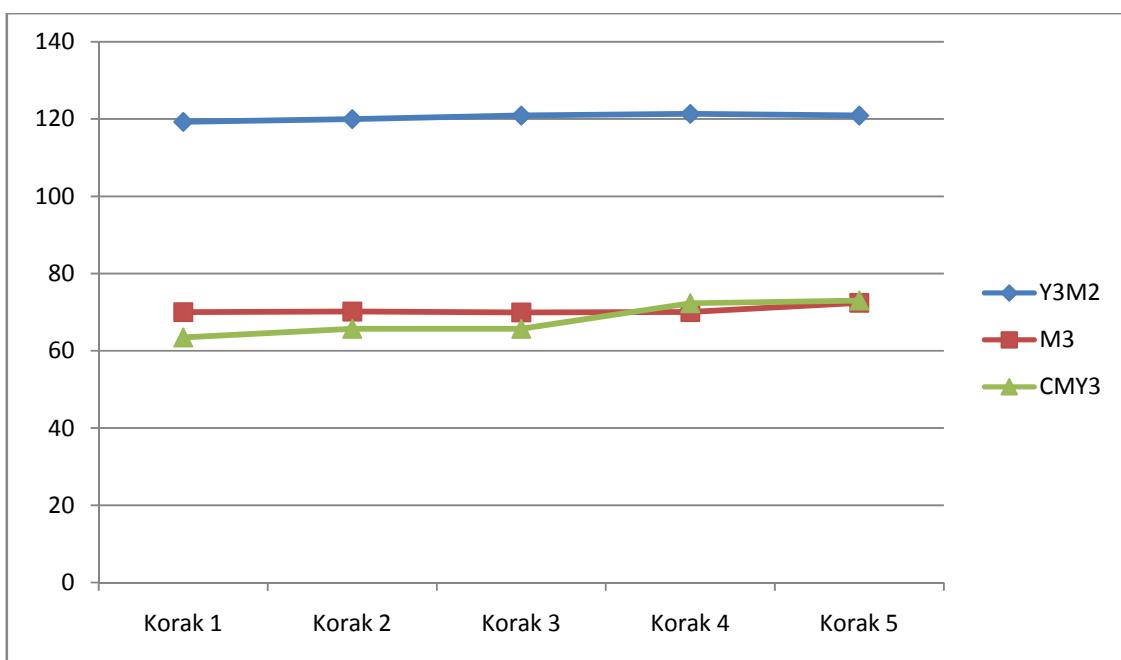
Slika 8.36, F vrijednosti za tri najsignifikantnija člana s kraja postupka eliminacije za proces B



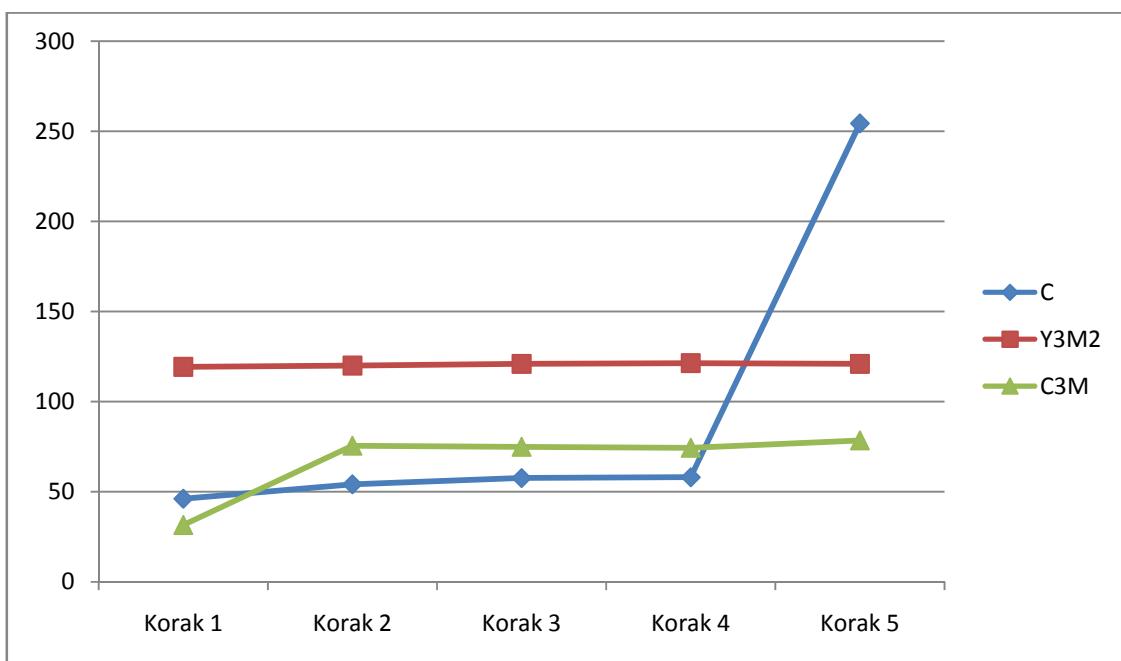
Slika 8.37, F vrijednosti za tri najsigifikantnija člana s početka postupka eliminacije za proces C



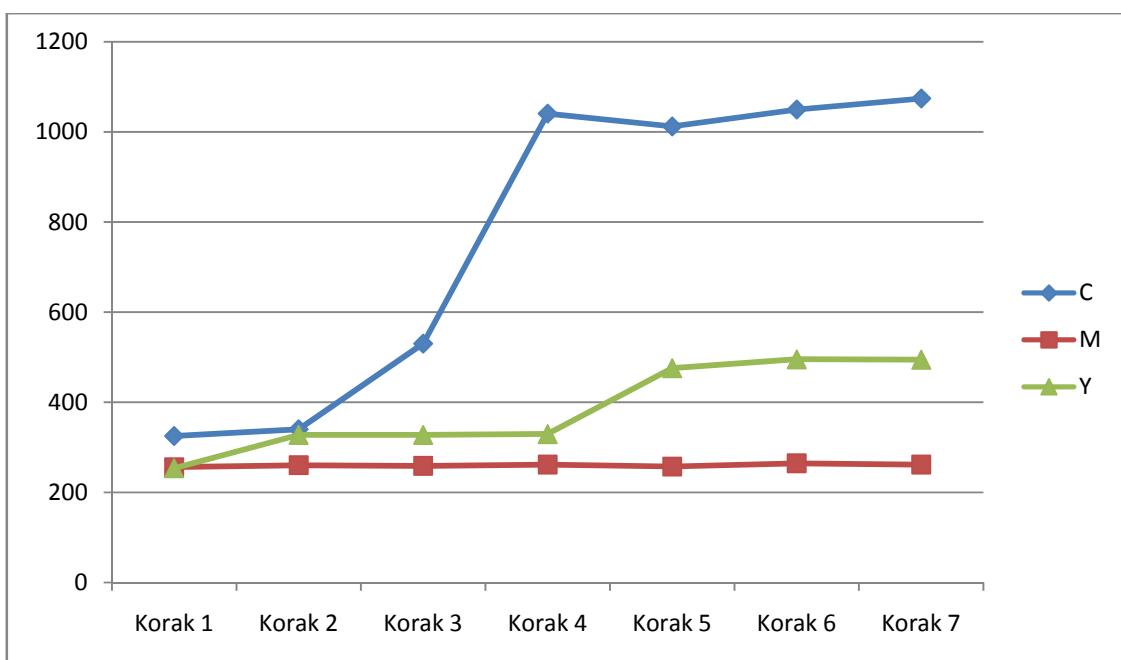
Slika 8.38, F vrijednosti za tri najsigifikantnija člana s kraja postupka eliminacije za proces C



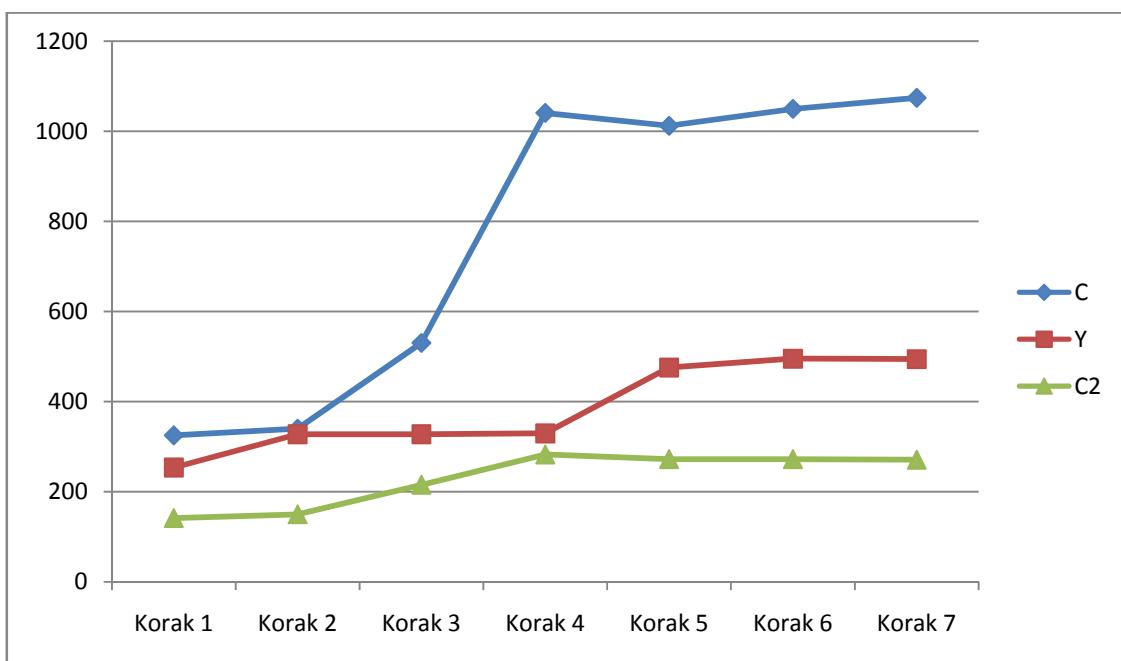
Slika 8.39, F vrijednosti za tri najsigifikantnija člana s početka postupka eliminacije za proces D



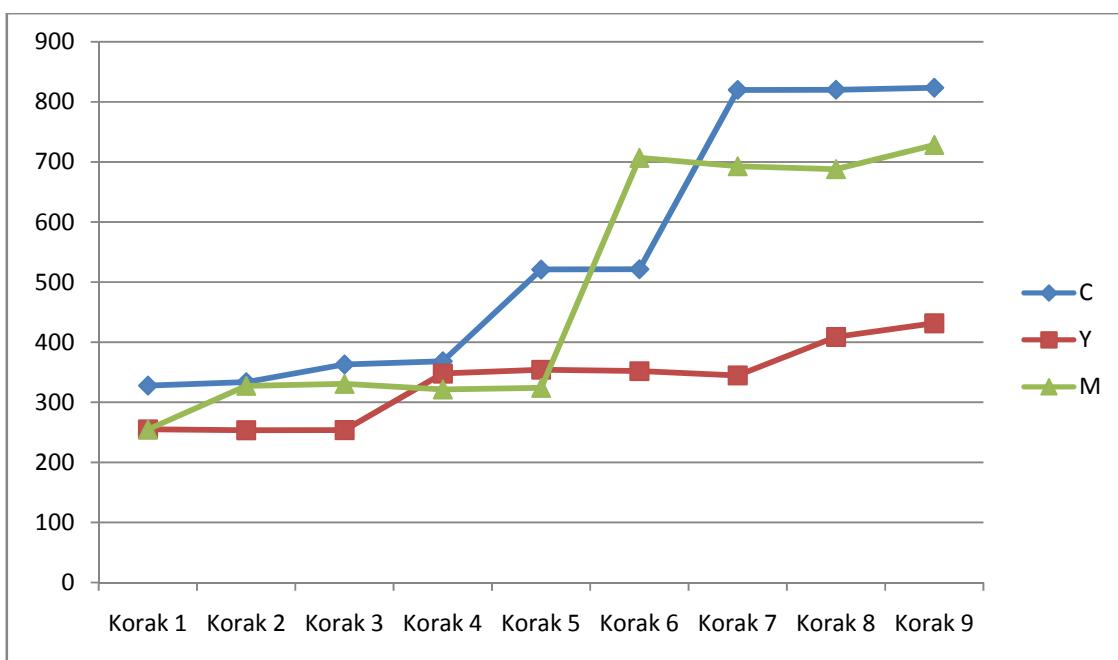
Slika 8.40, F vrijednosti za tri najsigifikantnija člana s kraja postupka eliminacije za proces D



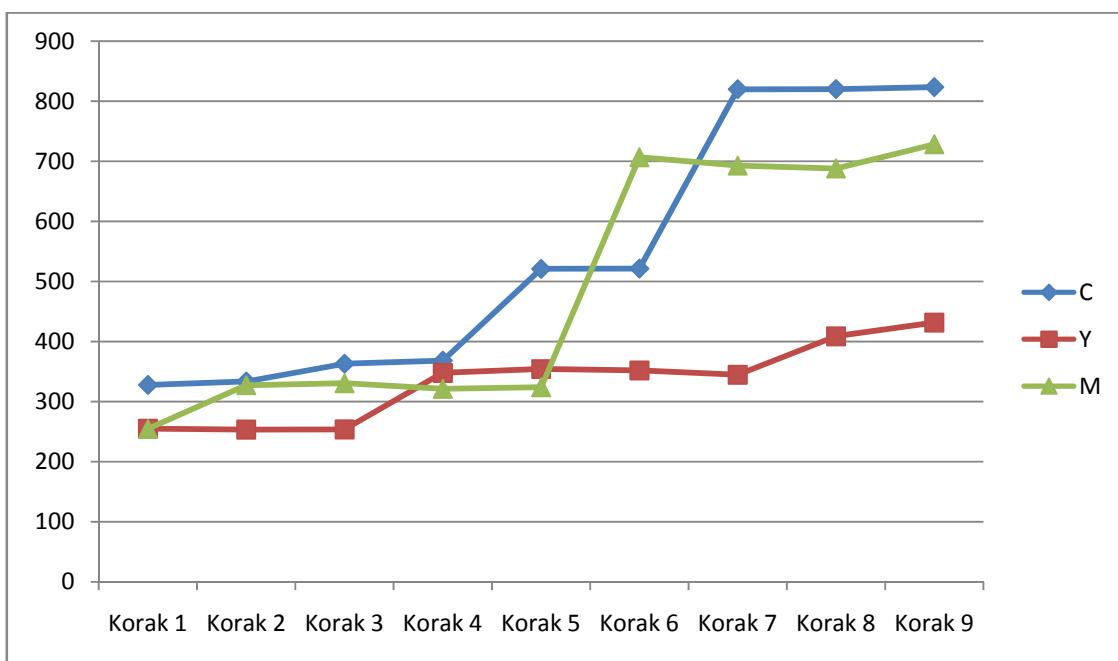
Slika 8.41, F vrijednosti za tri najsignifikantnija člana s početka postupka eliminacije za proces E



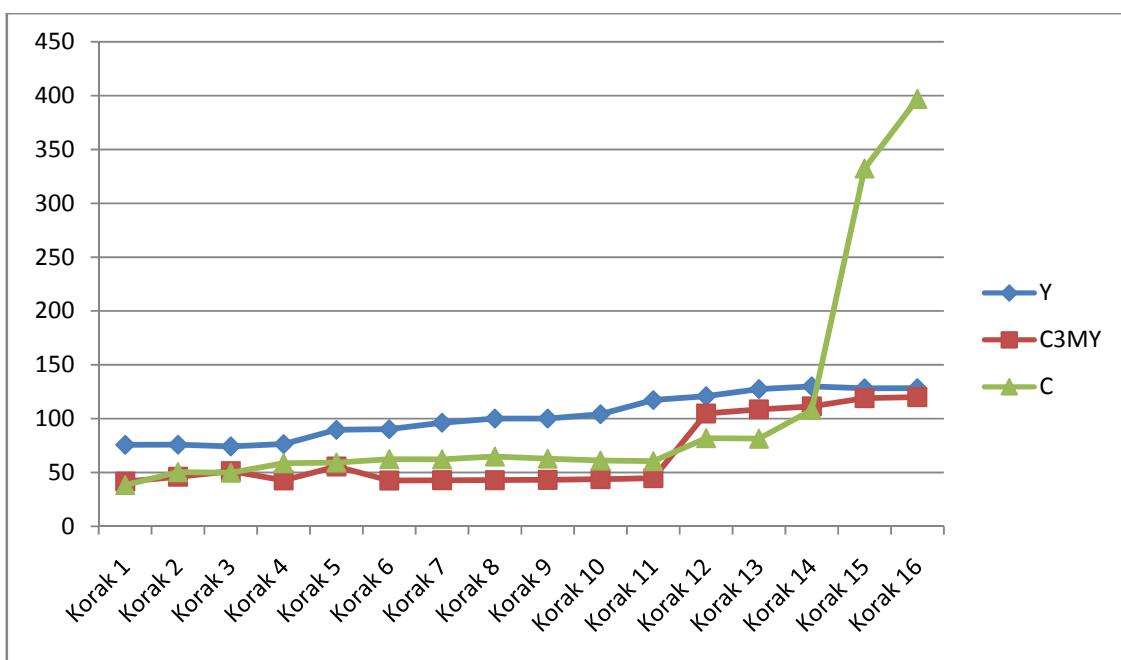
Slika 8.42, F vrijednosti za tri najsignifikantnija člana s kraja postupka eliminacije za proces E



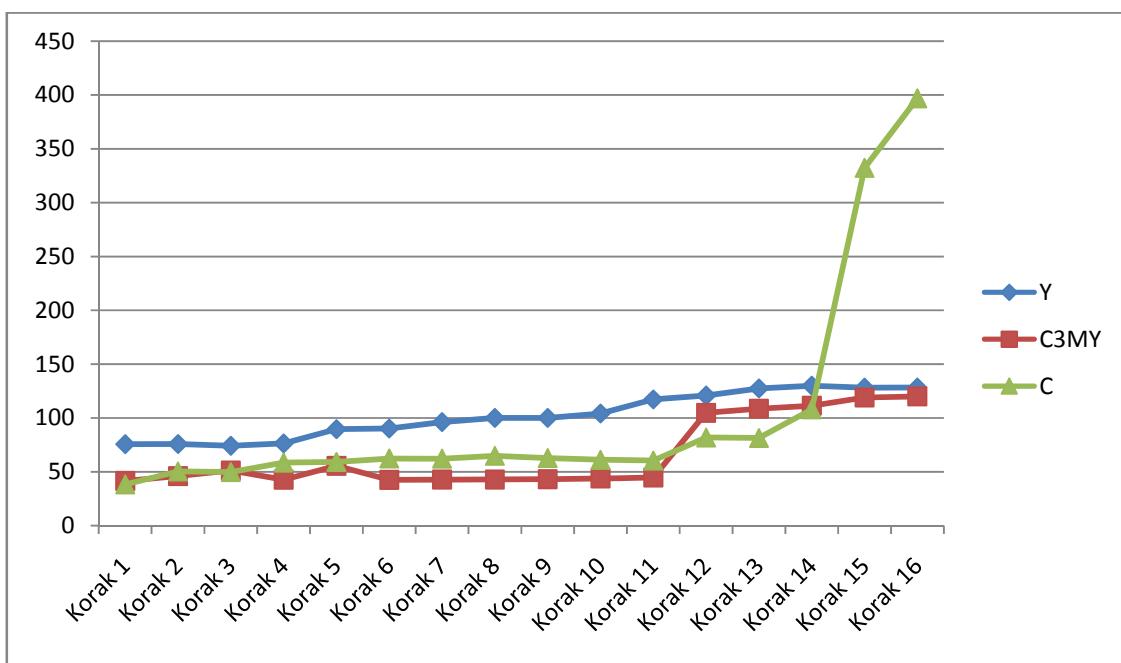
Slika 8.43, F vrijednosti za tri najsigifikantnija člana s početka postupka eliminacije za proces F



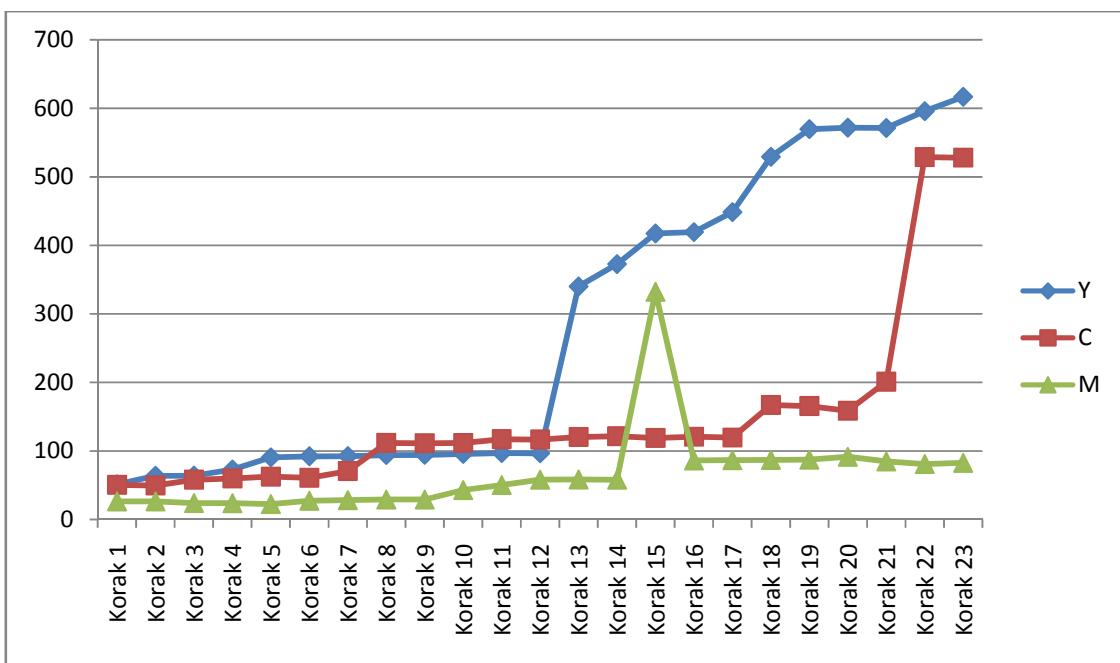
Slika 8.44, F vrijednosti za tri najsigifikantnija člana s kraja postupka eliminacije za proces F



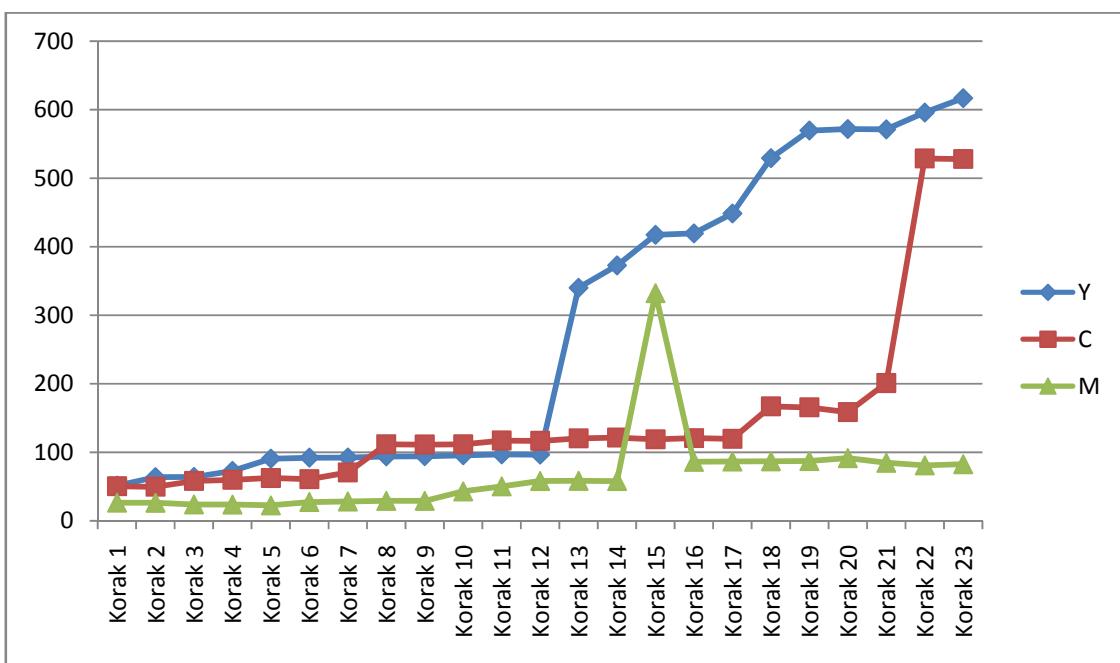
Slika 8.45, F vrijednosti za tri najsigifikantnija člana s početka postupka eliminacije za proces G



Slika 8.46, F vrijednosti za tri najsigifikantnija člana s kraja postupka eliminacije za proces G

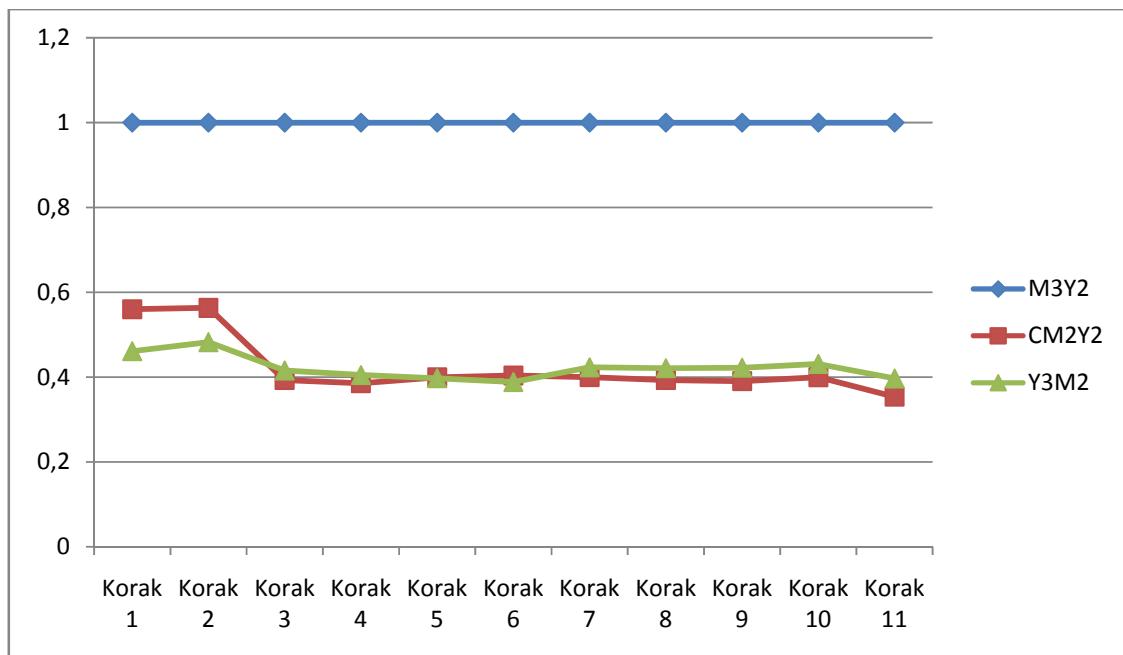


Slika 8.47, F vrijednosti za tri najsigifikantnija člana s početka postupka eliminacije za proces H

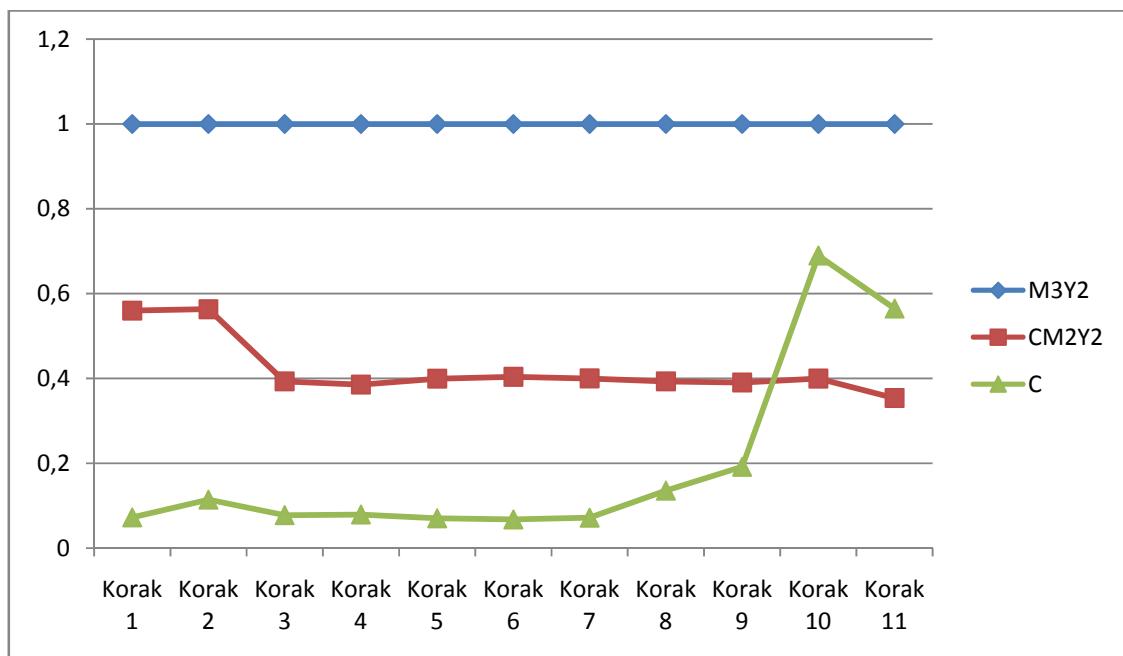


Slika 8.48, F vrijednosti za tri najsigifikantnija člana s kraja postupka eliminacije za proces H

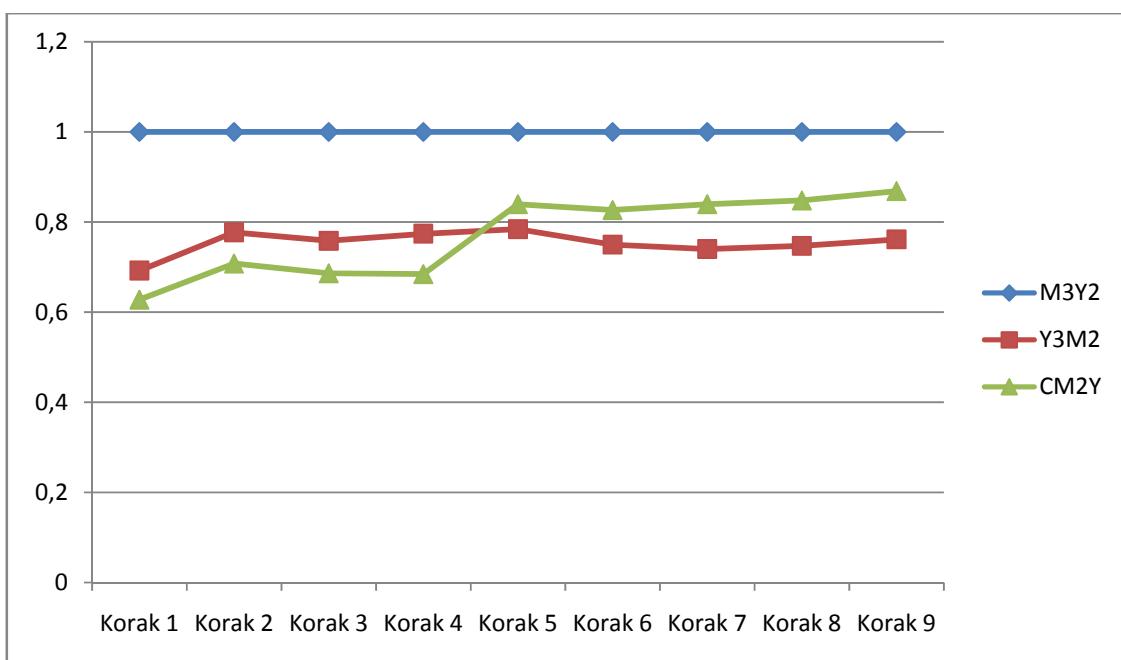
Relativna signifikantnost



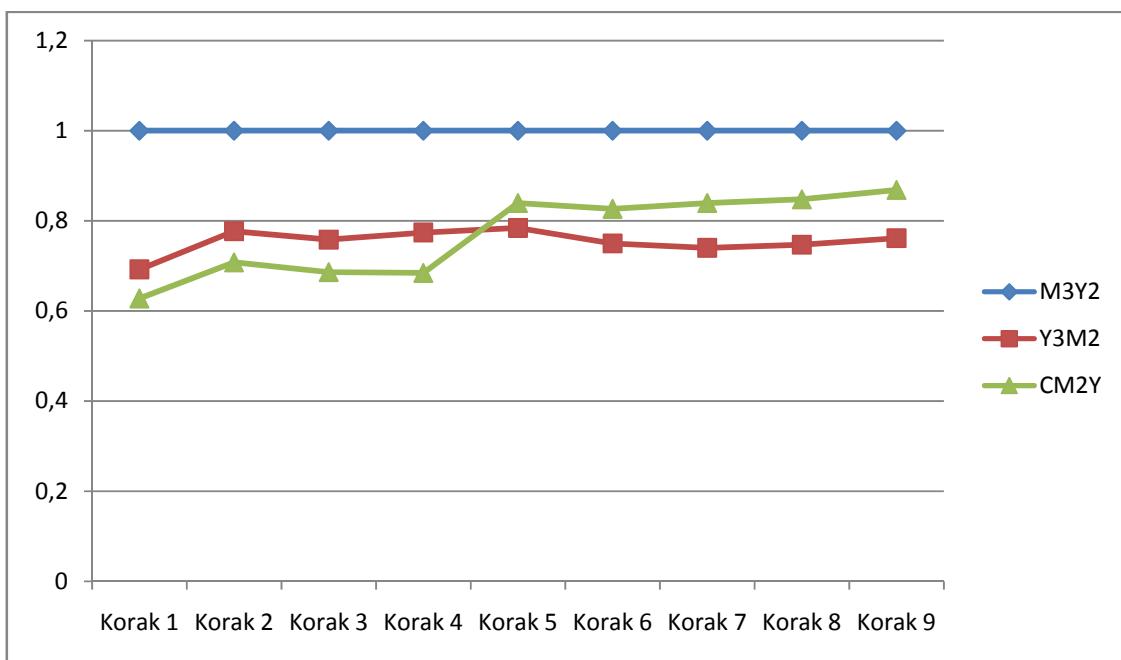
Slika 8.49, relativne F vrijednosti za tri najsigifikantnija člana s početka postupka eliminacije za proces A



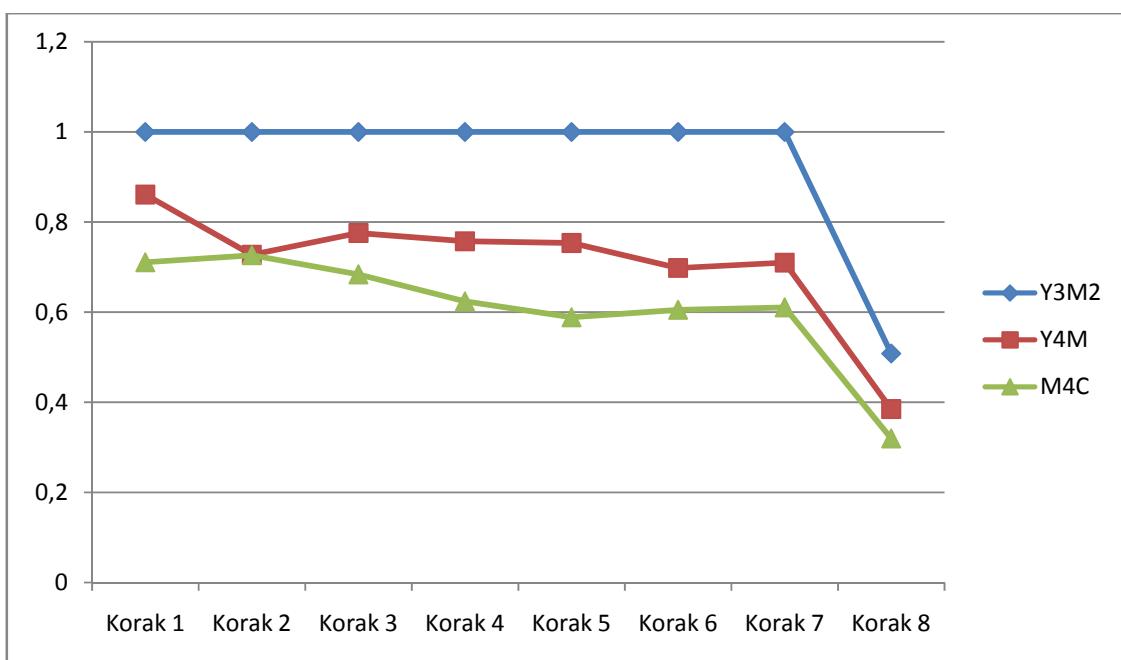
Slika 8.50, relativne F vrijednosti za tri najsigifikantnija člana s kraja postupka eliminacije za proces A



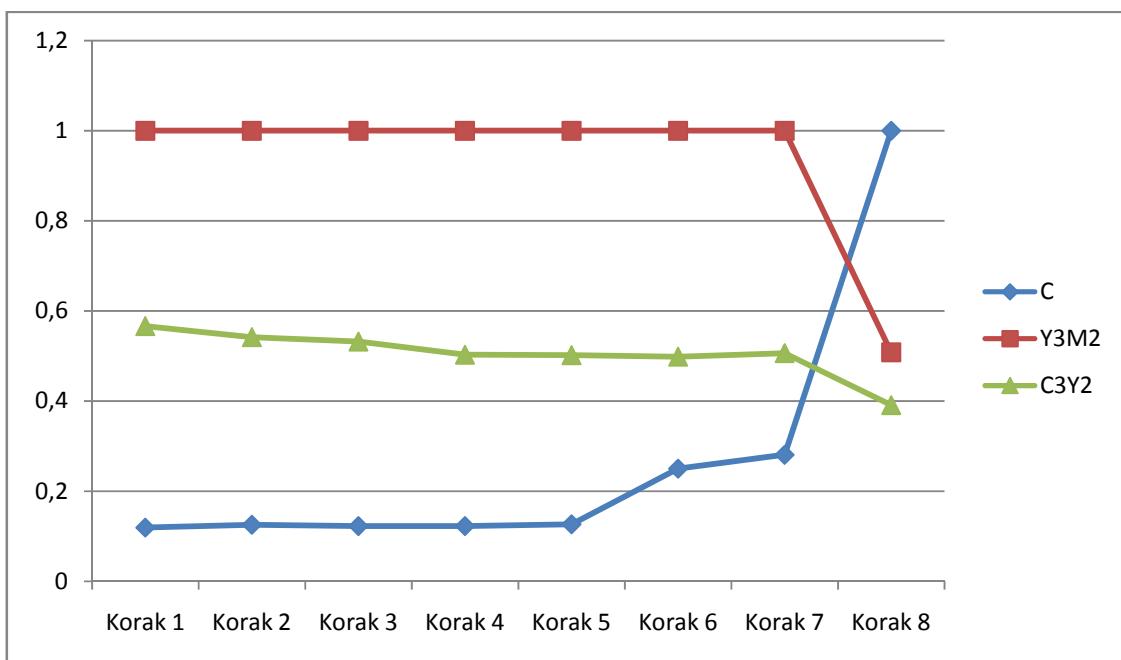
Slika 8.51, relativne F vrijednosti za tri najsignifikantnija člana s početka postupka eliminacije za proces B



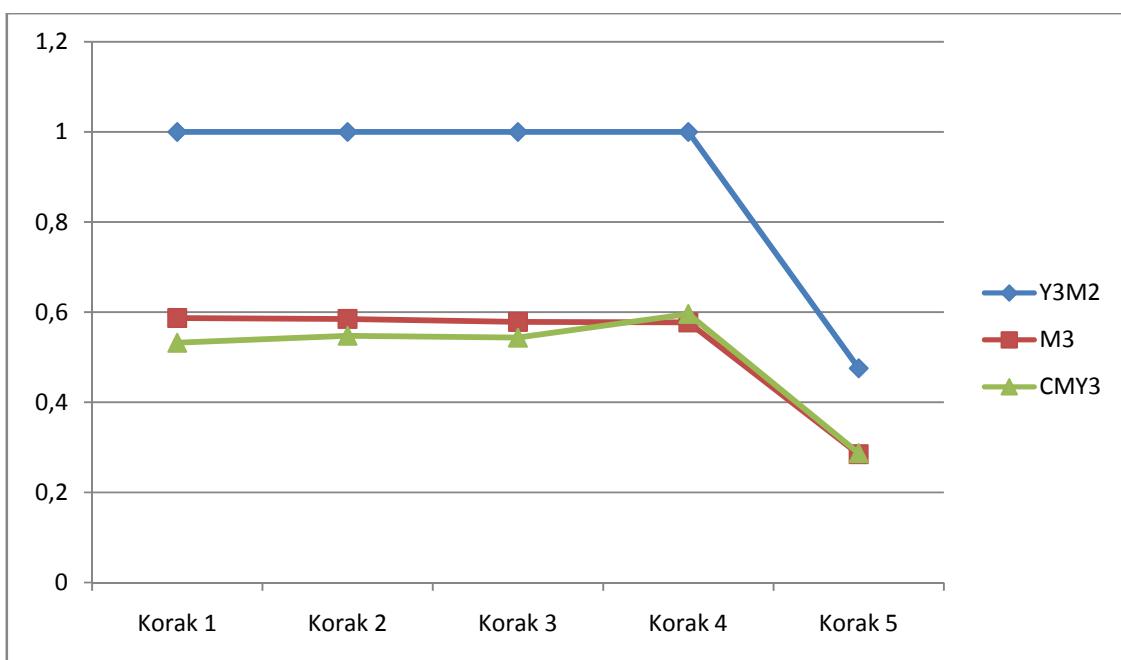
Slika 8.52, relativne F vrijednosti za tri najsignifikantnija člana s kraja postupka eliminacije za proces B



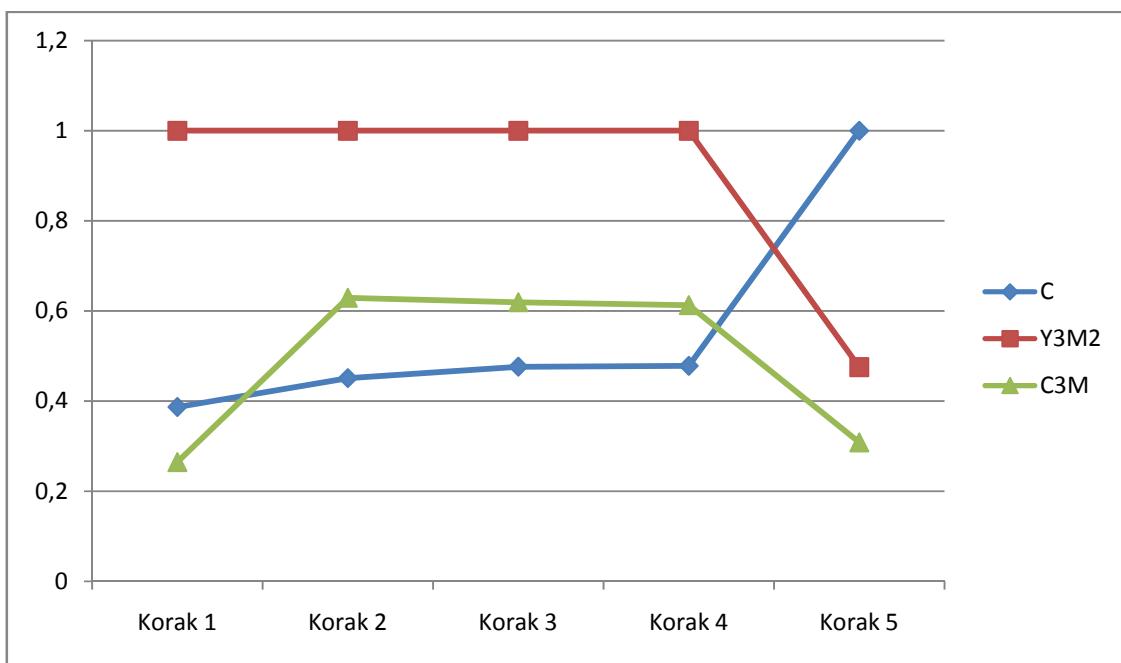
Slika 8.53, relativne F vrijednosti za tri najsignifikantnija člana s početka postupka eliminacije za proces C



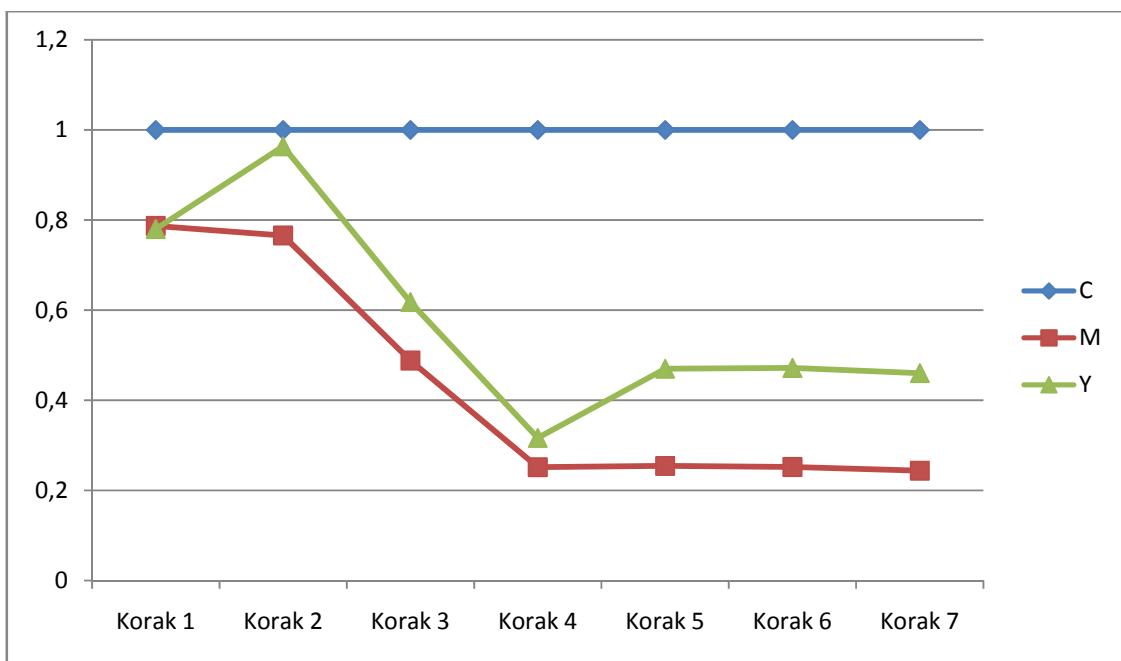
Slika 8.54, relativne F vrijednosti za tri najsignifikantnija člana s kraja postupka eliminacije za proces C



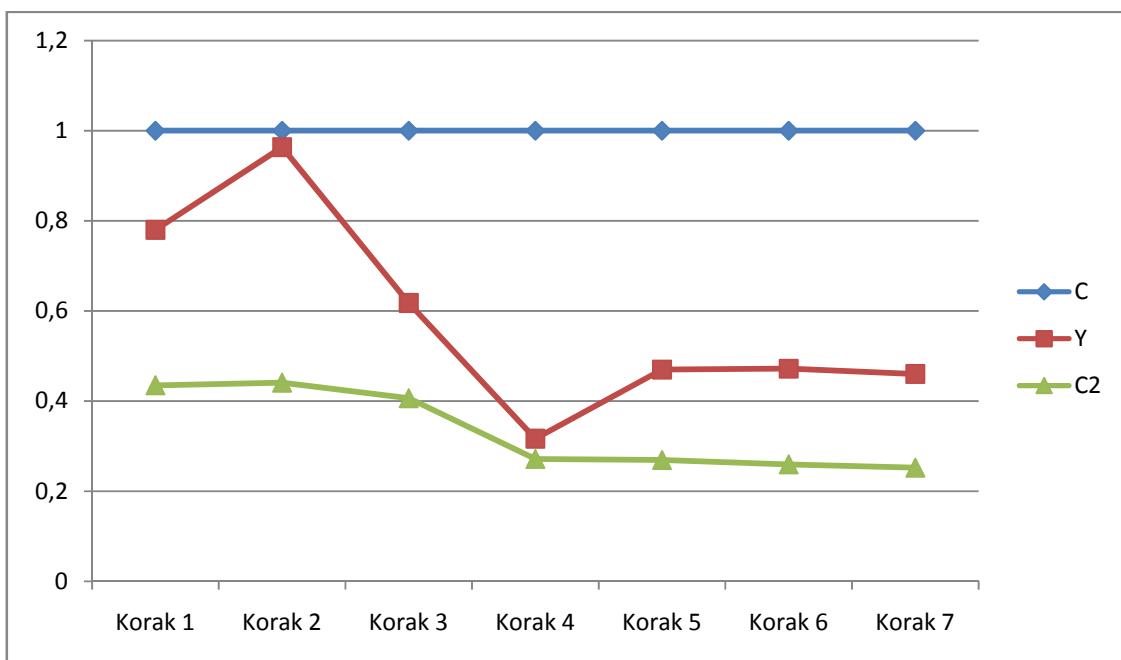
Slika 8.55, relativne F vrijednosti za tri najsignifikantnija člana s početka postupka eliminacije za proces D



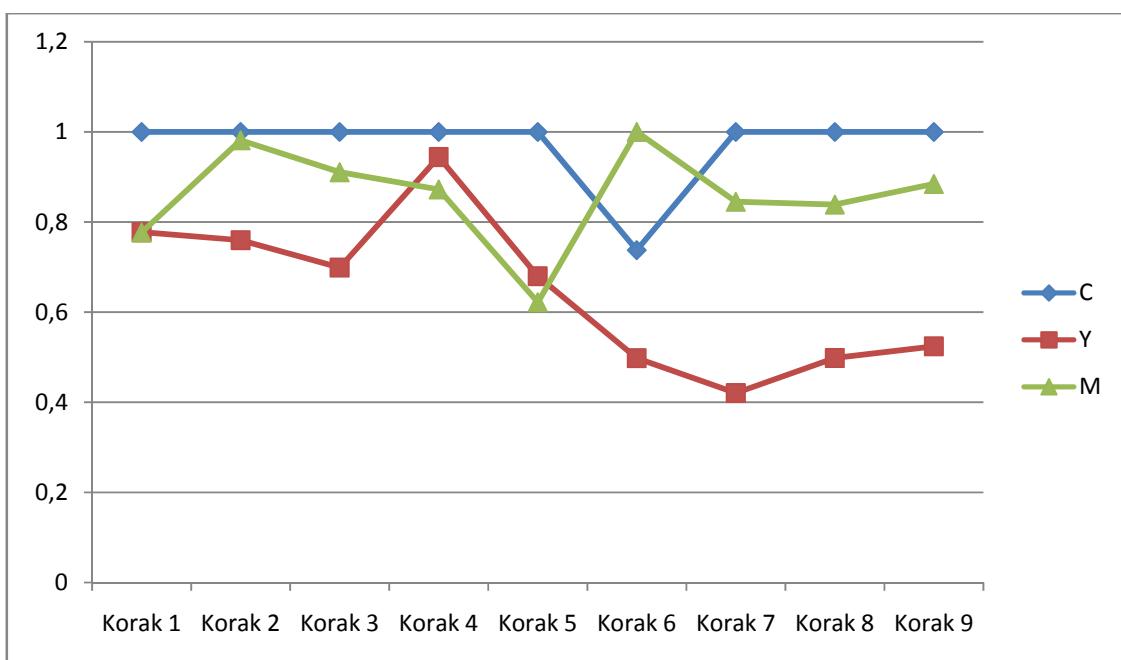
Slika 8.56, relativne F vrijednosti za tri najsignifikantnija člana s kraja postupka eliminacije za proces D



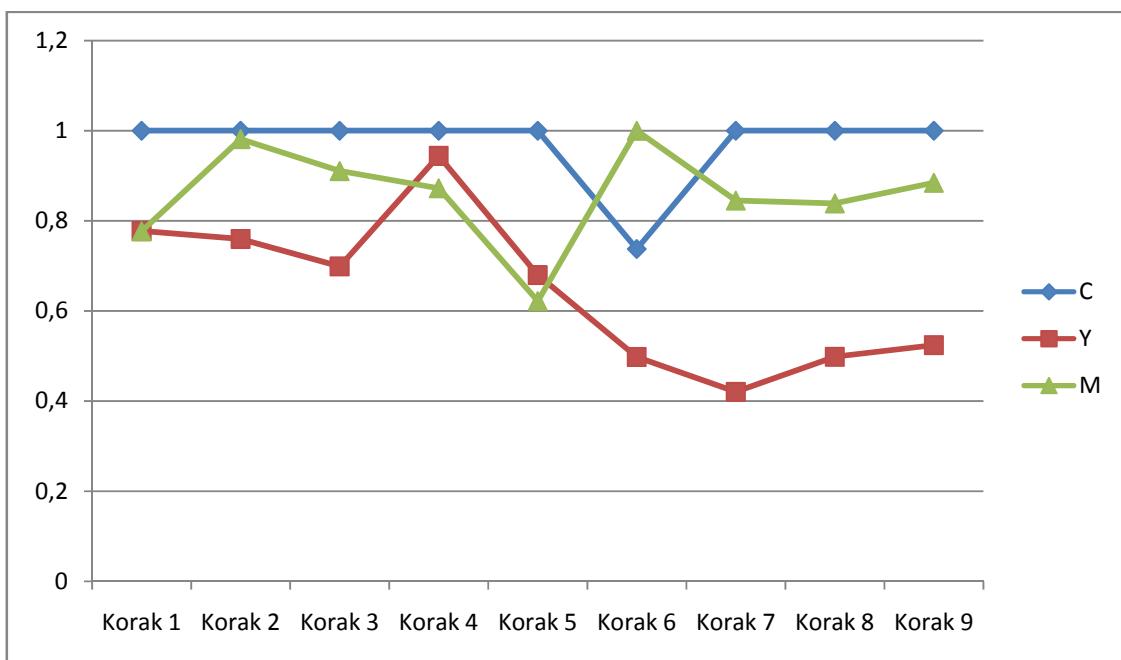
Slika 8.57, relativne F vrijednosti za tri najsignifikantnija člana s početka postupka eliminacije za proces E



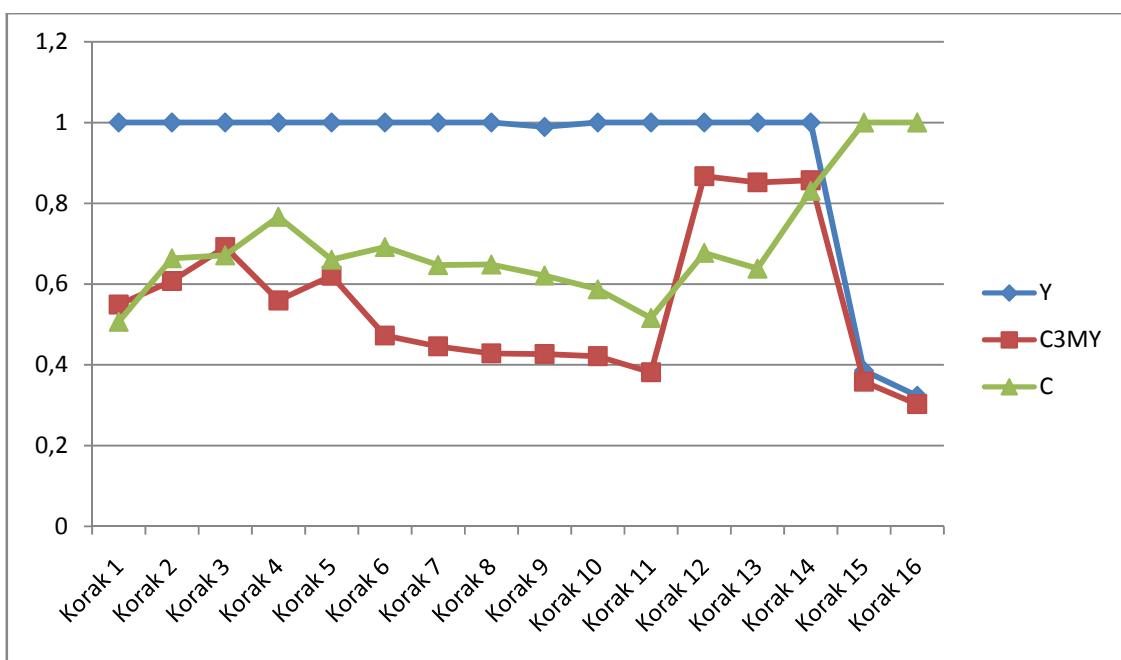
Slika 8.58, relativne F vrijednosti za tri najsignifikantnija člana s kraja postupka eliminacije za proces E



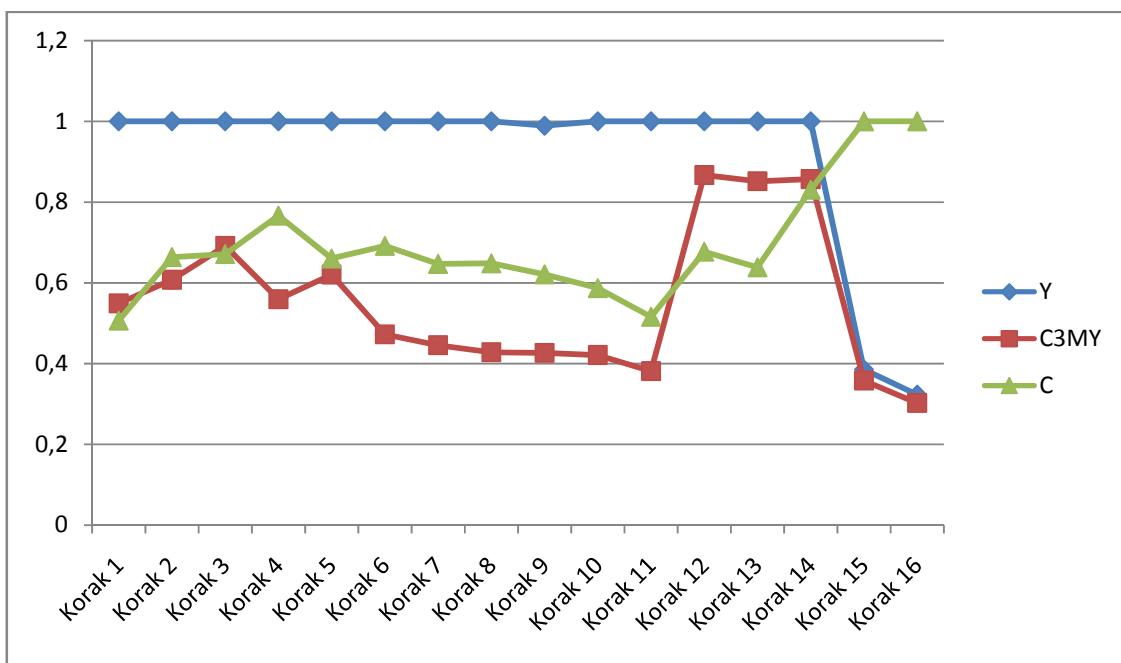
Slika 8.59, relativne F vrijednosti za tri najsignifikantnija člana s početka postupka eliminacije za proces F



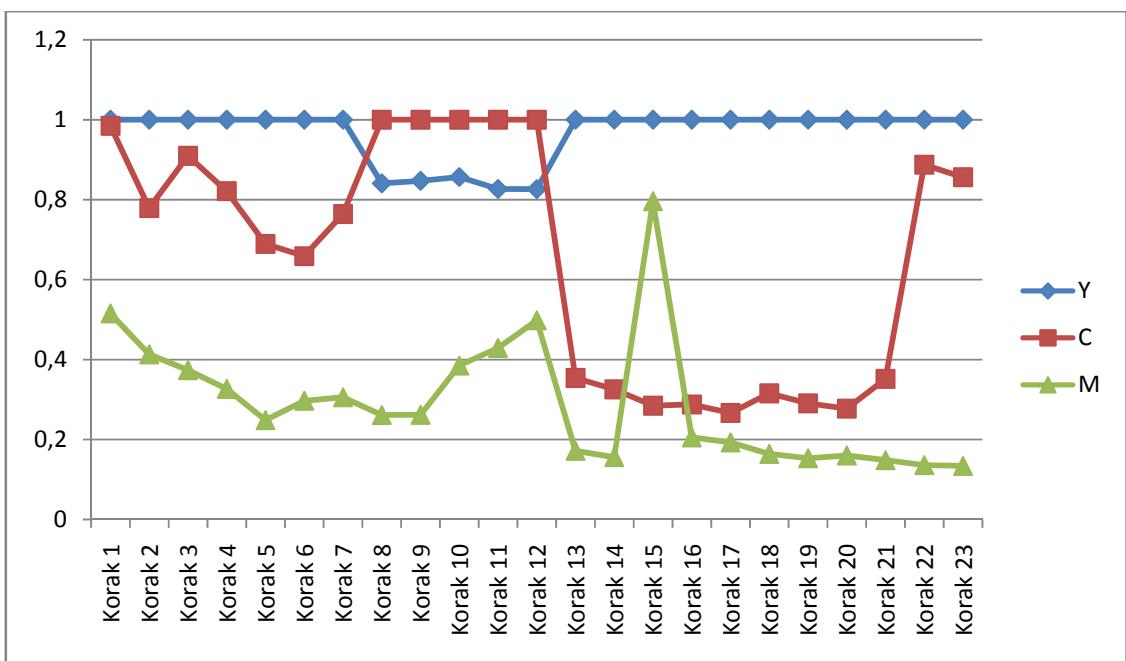
Slika 8.60, relativne F vrijednosti za tri najsignifikantnija člana s kraja postupka eliminacije za proces F



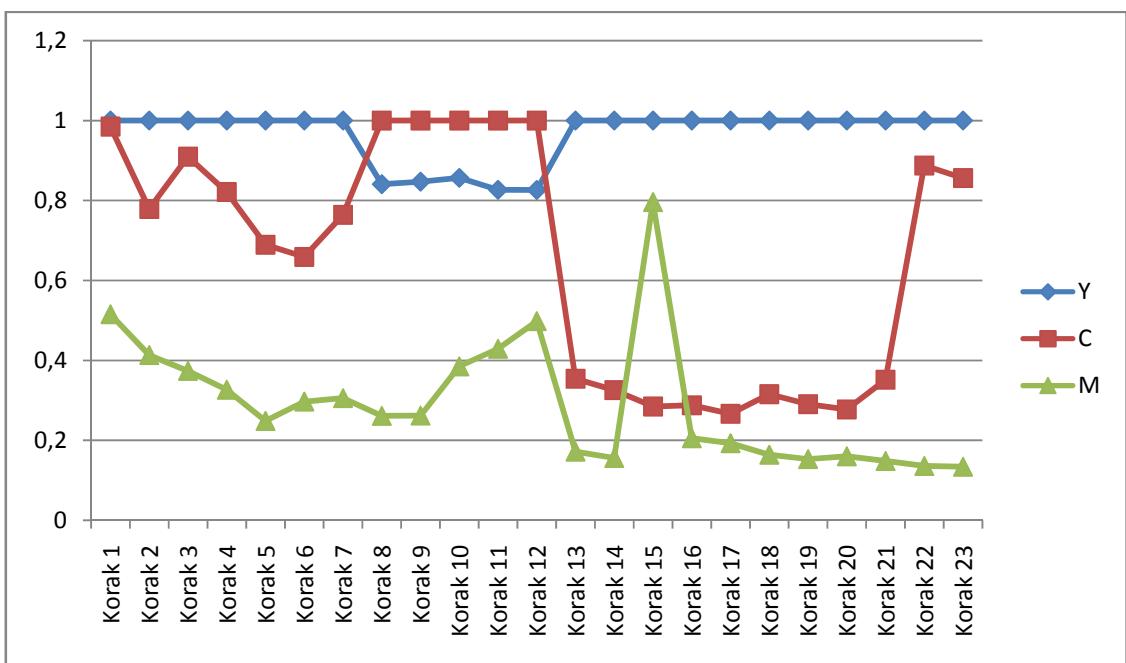
Slika 8.61, relativne F vrijednosti za tri najsignifikantnija člana s početka postupka eliminacije za proces G



Slika 8.62, relativne F vrijednosti za tri najsignifikantnija člana s kraja postupka eliminacije za proces G



Slika 8.63, relativne F vrijednosti za tri najsignifikantnija člana s početka postupka eliminacije za proces H



Slika 8.64, relativne F vrijednosti za tri najsignifikantnija člana s kraja postupka eliminacije za proces H

Tabela 8.18, Eliminirani članovi u procesu A

Eliminacijski korak	Članovi	Eliminacijski korak	Članovi
2	C^3Y	8	CM
3	MY	9	C^3
4	Y^3C^2	10	C^2
5	Y^3C	11	Y^3M
6	Y^5	12	M^5
7	CM^3Y		

Slika 8.33 prikazuje kretanje signifikantnosti tri člana koji su prve koraku bili najsignifikantniji s obzirom na vrijednost F. Tijekom cijelog postupka eliminacije najsignifikantniji od tri člana bio je M^3Y^2 . Signifikantnost druga dva člana, CM^2Y^2 i Y^3M^2 postupno je rasla tijekom postupka eliminacije. Slika 8.49 prikazuje relativne signifikantnosti tri člana koji su bili najsignifikantniji u prve koraku postupka eliminacije. Uočljivo je da je član M^3Y^2 bio najsignifikantniji od svih članova tijekom cijelog postupka eliminacije. U trećem koraku eliminacije, nakon izbacivanja člana MY došlo je do manjega pada relativne signifikantnosti članova CM^2Y^2 i Y^3M^2 . Njihova je signifikantnost u tom koraku porasla, ali je došlo do znatnoga rasta signifikantnosti člana M^3Y^2 . Uočljivo je da je do drugoga znatnijeg rasta signifikantnosti člana M^3Y^2 došlo u jedanaestom koraku eliminacijom člana Y^3M . Ovdje je već uočljiva određena pravilnost. Izbacivanjem nesignifikantnih članova koji opisuju interakciju između kanala M i Y dodatno je povećana signifikantnost člana koji puno bolje opisuje tu istu interakciju. Iako u manjoj mjeri, povećana je i signifikantnost člana Y^3M^2 koji isto opisuje interakciju među kanalima M i Y.

Slika 8.34 prikazuje kretanje signifikantnosti tri člana koji su u zadnjem koraku eliminacije bili najsignifikantniji s obzirom na vrijednost F. U ovome su se procesu od tri člana koji su bili najsignifikantniji na početku postupka eliminacije, na kraju kao najsignifikantniji održala dva člana. Treći člana postao je C. Ovdje je potrebno uočiti da se signifikantnost člana C nije znatno mijenjala do osmoga koraka te da je znatne poraste ostvario u osme, devetome i najviše u desetom koraku eliminacijom članova CM , C^3 i C^2 . Jasno je vidljivo kako je eliminacija članova koji sadrže kanal C utjecala na povećanje signifikantnosti člana C. Ipak, nije uočljiva jasna pravilnost s obzirom da su signifikantnosti članova C^4 i C^5 ostale relativno visoke pa se ne može reći da su signifikantni bili samo članovi viših redova ili samo članovi nižih redova. Prikaz relativne signifikantnosti članova koji su zadnjem koraku eliminacije bili najsignifikantniji (Slika 8.50) u slučaju ovoga procesa ne daje dodatne informacije.

Tabela 8.19, Eliminirani članovi u procesu B

Eliminacijski korak	Članovi	Eliminacijski korak	Članovi
2	M^3	7	Y^2C
3	M^3C	8	C^2Y
4	Y^5	9	C^3M
5	M^2C	10	Y^3
6	Y^3C^2		

Slika 8.35 prikazuje kretanje signifikantnosti tri člana koji su prvome koraku bili najsignifikantniji s obzirom na vrijednost F. Tijekom cijelog postupka eliminacije najsignifikantniji od tri člana bio je M^3Y^2 . Njegova se signifikantnost tijekom postupka eliminacije održavala blizu početne vrijednosti. Signifikantnost člana Y^3M^2 tijekom postupka eliminacije u generalnom je trendu rasla uz manje oscilacije. Signifikantnost člana CM^2Y postupno je rasla tijekom postupka eliminacije. Veći rast je ostvarila u petome koraku eliminacijom člana M^2C . Ovdje je uočljivo da su signifikantne interakcije viših redova među kanalima M i Y, ali i među kanalima M i C s obzirom da su eliminirani članovi M^2C i M^3C . Članovi koji modeliraju interakciju između sva tri kanala, C, M i Y pokazali su se prikladnijima.

Slika 8.51 prikazuje relativne signifikantnosti tri člana koji su bili najsignifikantniji u prвome koraku postupka eliminacije. Uočljivo je da je član M^3Y^2 bio najsignifikantniji od svih članova tijekom cijelog postupka eliminacije. Kako se njegova signifikantnost nije bitno mijenjala u postupku eliminacije, trend relativne signifikantnosti članova Y^3M^2 i CM^2Y sličan je trendu apsolutne signifikantnosti pa prikaz ne daje dodatne informacije.

Slika 8.36 prikazuje kretanje signifikantnosti tri člana koji su u zadnjem koraku eliminacije bili najsignifikantniji s obzirom na vrijednost F. U ovome su se procesu od tri člana koji su bili najsignifikantniji na početku postupka eliminacije, na kraju kao najsignifikantniji održala sva tri člana. Članovi koji su im se najviše približili bili su M^5 , M^4 i CM^2Y^2 . To ukazuje na složenost kanala M i već utvrđenu složenost interakcije među kanalima M i Y. Ipak, nije vidljiv jasan uzorak po kojem su nesignifikantni članovi eliminirani, niti je vidljiv jasan uzorak među signifikantnim članovima.

Prikaz relativne signifikantnosti članova koji su zadnjem koraku eliminacije bili najsignifikantniji (Slika 8.52) u slučaju ovoga procesa ne daje dodatne informacije s obzirom da je u cijelome postupku najsignifikantniji član bio M^3Y^2 i njegova se signifikantnost nije bitno mijenjala.

Tabela 8.20, Eliminirani članovi u procesu C

Eliminacijski korak	Članovi	Eliminacijski korak	Članovi
2	Y^4C	6	C^4
3	Y^5	7	Y^3C^2
4	C^3MY	8	C^2
5	CM	9	Y

Slika 8.37 prikazuje kretanje signifikantnosti tri člana koji su prve koraku bili najsignifikantniji s obzirom na vrijednost F. Tijekom cijelog postupka eliminacije najsignifikantniji od tri člana bio je Y^3M^2 . Njegova je signifikantnost tijekom postupka eliminacije rasla u generalnom trendu, ali se do kraja nije bitno mijenjala. Signifikantnosti članova Y^4M i M^4C nisu se bitno mijenjale tijekom postupka eliminacije. Uočljivo je da je u drugome koraku eliminacijom člana Y^4C porasla signifikantnost člana M^4C , a signifikantnost člana Y^4M se smanjila. Te pojave nije moguće objasniti s obzirom da svaki od ta tri člana opisuje interakcije među različitim kanalima pa njihova ovisnost nije jasna. Pregledom signifikantnosti svih članova također nije moguće utvrditi postojanje uzorka po kojem bi određeni članovi bili signifikantniji od ostalih. Slika 8.53 prikazuje relativne signifikantnosti tri člana koji su bili najsignifikantniji u prve koraku postupka eliminacije. Uočljivo je da je član Y^3M^2 bio najsignifikantniji od svih članova do osmoga koraka eliminacije u kojem je eliminiran član C^2 . Eliminacija člana C^2 prouzročila je nagli rast signifikantnosti člana C, ali i preostalih članova C^n . Taj je efekt logičan, ali ostaje nejasan razlog iz kojeg su eliminirani parni članovi C^n , a zadržani neparni članovi C^n pa se niti u ovome slučaju ne može reći da su odbačeni samo članovi viših ili samo članovi nižih redova.

Slika 8.38 prikazuje kretanje signifikantnosti tri člana koji su u zadnjem koraku eliminacije bili najsignifikantniji s obzirom na vrijednost F. U ovome se procesu od tri člana koji su bili najsignifikantniji na početku postupka eliminacije, na kraju kao najsignifikantniji održao samo jedan član. Članovi C i C^3Y^2 ušli su u skupinu tri najsignifikantnija člana zahvaljujući naglome rastu u osmome koraku kada je eliminiran član C^2 . Slika 8.54 prikazuje relativne signifikantnosti članova koji su u zadnjem koraku eliminacije bili najsignifikantniji. Iz nje se jasno vidi kako je član Y^3M^2 bio najsignifikantniji od svih članova do osmoga koraka, kada je njegovo mjesto preuzeo član C. Vidljivo je i kako su relativne signifikantnosti članova Y^3M^2 i C^3Y^2 u osmome koraku naglo smanjene jer se po absolutnom iznosu nisu bitno mijenjale u odnosu na signifikantnost člana C.

Tabela 8.21, Eliminirani članovi u procesu D

Eliminacijski korak	Članovi	Eliminacijski korak	Članovi
2	C^4M	5	C^2
3	Y^3C^2	6	M^2C
4	Y^2C		

Slika 8.39 prikazuje kretanje signifikantnosti tri člana koji su prve koraku bili najsignifikantniji s obzirom na vrijednost F. Tijekom cijelog postupka eliminacije najsignifikantniji od tri člana bio je Y^3M^2 . Njegova se signifikantnost tijekom postupka eliminacije gotovo uopće nije mijenjala. Signifikantnosti druga dva člana, M^3 i CMY^3 su rasle za vrlo malene iznose.

Slika 8.55 prikazuje relativne signifikantnosti tri člana koji su bili najsignifikantniji u prve koraku postupka eliminacije. Uočljivo je da je član Y^3M^2 bio najsignifikantniji od svih članova do petoga koraka eliminacije u kojem je eliminiran član C^2 . Eliminacija člana C^2 prouzročila je nagli rast signifikantnosti člana C, ali i preostalih članova C^n .

Slika 8.40 prikazuje kretanje signifikantnosti tri člana koji su u zadnjem koraku eliminacije bili najsignifikantniji s obzirom na vrijednost F. U ovome se procesu od tri člana koji su bili najsignifikantniji na početku postupka eliminacije, na kraju kao najsignifikantniji održao samo jedan član. Članovi C i C^3M ušli su u skupinu tri najsignifikantnija člana zahvaljujući naglome rastu u petome koraku kada je eliminiran član C^2 , odnosno u drugome koraku kada je eliminiran član C^4M . Oba su slučaja logična i lako objašnjiva na način da eliminacijom jednoga člana ostali njemu slični članovi dobivaju na signifikantnosti. Iako se i u ovome, kao i u prethodnim procesima javlja ta pojava, niti u ovome slučaju ne postoji jasno vidljiv uzorak i nije jasno zašto su upravo neki članovi signifikantniji od drugih.

Slika 8.54 prikazuje relativne signifikantnosti članova koji su u zadnjem koraku eliminacije bili najsignifikantniji. Iz nje se jasno vidi kako je član Y^3M^2 bio najsignifikantniji od svih članova do petoga koraka, kada je njegovo mjesto preuzeo član C. Vidljivo je i kako su relativne signifikantnosti članova Y^3M^2 i C^3M u petome koraku naglo smanjene jer se po absolutnom iznosu nisu bitno mijenjale u odnosu na signifikantnost člana C.

Tabela 8.22, Eliminirani članovi u procesu E

Eliminacijski korak	Članovi	Eliminacijski korak	Članovi
2	Y^5	6	C^2MY^2
3	C^3Y	7	C^3MY
4	C^2M	8	M^3Y
5	Y^3C		

Slika 8.41 prikazuje kretanje signifikantnosti tri člana koji su prvome koraku bili najsignifikantniji s obzirom na vrijednost F. Tijekom cijelog postupka eliminacije najsignifikantniji od tri člana bio je C. Njegova je signifikantnost tijekom postupka eliminacije uglavnom rasla, a veći iznosi rasta zabilježeni su trećem koraku nakon eliminacije člana C^3Y i u četvrtom koraku nakon eliminacije člana C^2M . Signifikantnost člana Y je znatnije porasla u drugome koraku nakon eliminacije člana Y^5 i u petom koraku nakon eliminacije člana Y^3C . Signifikantnost člana M nije se bitno mijenjala tijekom postupka eliminacije. Vidljivo je da su veći porasti signifikantnosti članova C i Y zabilježeni nakon eliminacije članova koji su uključivali te kanale. No, s druge je strane vidljivo da su eliminirana i četiri člana koji su uključivali M kanal, a da pri tome nije došlo do znatnije promjene signifikantnosti člana M.

Slika 8.57 prikazuje relativne signifikantnosti tri člana koji su bili najsignifikantniji u prвome koraku postupka eliminacije. Uočljivo je da je član C bio najsignifikantniji od svih članova tijekom cijelog postupka eliminacije. Vidljivo je i to da je u drugome koraku, nakon eliminacije člana Y^5 , član Y gotovo dosegao signifikantnost člana C.

Slika 8.42 prikazuje kretanje signifikantnosti tri člana koji su u zadnjem koraku eliminacije bili najsignifikantniji s obzirom na vrijednost F. U ovome su se procesu od tri člana koji su bili najsignifikantniji na početku postupka eliminacije, na kraju kao najsignifikantniji održala dva člana. Treći član, C^2 ušao je u skupinu tri najsignifikantnija člana rastom signifikantnosti u trećem koraku kada je eliminiran član C^3Y i u četvrtom koraku kada je eliminiran član C^2M .

Slika 8.58 prikazuje relativne signifikantnosti članova koji su u zadnjem koraku eliminacije bili najsignifikantniji. Iz tog je prikaza vidljivo da je prilikom eliminacije člana C^3Y u trećem koraku i člana C^2M u četvrtom koraku došlo do puno veće promjene signifikantnosti člana C u odnosu na član Y, nego u odnosu na član C^2 čija je signifikantnost isto rasla.

Iz iznesenog se dade iščitati da eliminacija člana koji sadrži neki kanal najviše utječe na rast njegovih članova nižih redova, a utjecaj je time veći što je veća potencija nad tim kanalom u eliminiranom članu.

Tabela 8.23, Eliminirani članovi u procesu F

Eliminacijski korak	Članovi	Eliminacijski korak	Članovi
2	M^2C	7	C^3Y
3	C^5	8	Y^5
4	Y^3C	9	CM^2Y
5	C^2MY	10	Y^3M^2
6	M^3Y		

Slika 8.43 prikazuje kretanje signifikantnosti tri člana koji su prve koraku bili najsignifikantniji s obzirom na vrijednost F. Tijekom gotovo cijelog postupka eliminacije najsignifikantniji od tri člana bio je C, osim u šestome koraku kada je najsignifikantniji bio član M. Signifikantnost člana C za znatnije je iznose porasla u petome koraku, nakon eliminacije člana C^2MY i u sedmome koraku, nakon eliminacije člana C^3Y . Slično kretanje je vidljivo ako se promotri kretanje signifikantnosti člana M. Najveći rast dogodio se u šestome koraku, nakon eliminacije člana M^3Y . Dva manja rasta zabilježena su u drugome koraku, nakon eliminacije člana M^2C i u devetom koraku, nakon eliminacije člana CM^2Y . Signifikantnost člana Y nije se bitno mijenjala. Zabilježena su tri manja porasta: U četvrtom koraku, nakon eliminacije člana Y^3C , u osmom koraku, nakon eliminacije člana Y^5 i najmanji rast u devetom koraku, nakon eliminacije člana CM^2Y . Uočljivo je da se slično prethodnom slučaju eliminacijom člana koji sadrži neke kanale jako utječe na signifikantnost ostalih članova koji sadrže te kanale, i to time više što je potencija nad kanalom eliminiranog člana veća, a potencija nad kanalom preostalog člana manja.

Slika 8.59 prikazuje relativne signifikantnosti tri člana koji su bili najsignifikantniji u prve koraku postupka eliminacije. Uočljivo je da je član C bio najsignifikantniji od svih članova tijekom gotovo cijelog postupka eliminacije, osim u šestome koraku kada je najsignifikantniji bio član M. Za razliku od većine prethodnih slučajeva u kojima je signifikantnost jednoga člana ekstremno rasla, u ovome su slučaju sva tri člana do petoga koraka eliminacije bila relativno ujednačena, a zatim je došlo do većega rasta članova C i M u odnosu na član Y. Pregledom eliminiranih članova vidljivo je da su sadržavali niske potencije nad Y kanalom u odnosu na ostale kanale.

Slika 8.42 prikazuje kretanje signifikantnosti tri člana koji su u zadnjem koraku eliminacije bili najsignifikantniji s obzirom na vrijednost F, a Slika 8.58 prikazuje relativne signifikantnosti članova koji su u zadnjem koraku eliminacije bili najsignifikantniji. Kako su se u slučaju ovoga procesa sva tri člana koji su bili najsignifikantniji na početku postupka eliminacije održali kao najsignifikantniji na kraju postupka, ti prikazi ne daju dodatne informacije.

Tabela 8.24, Eliminirani članovi u procesu G

Eliminacijski korak	Članovi	Eliminacijski korak	Članovi
2	C^4M	10	Y^3C^2
3	CM^2Y	11	CMY^3
4	C^4	12	C^2MY
5	Y^5	13	Y^4M
6	M^3C	14	C^3Y
7	Y^3M^2	15	C^2
8	M^2Y	16	C^3Y^2
9	M^3Y^2	17	C^5

Slika 8.45 prikazuje kretanje signifikantnosti tri člana koji su prvome koraku bili najsignifikantniji s obzirom na vrijednost F. Tijekom gotovo cijelog postupka eliminacije najsignifikantniji od tri člana bio je Y, a u petnaestom koraku najsignifikantniji član je postao C. Signifikantnost člana Y rasla je postupno tijekom eliminacije i nije se bitno promjenila. Signifikantnost člana C znatno je porasla u petnaestom koraku, nakon eliminacije člana C^2 . Signifikantnost člana C^3MY gotovo se nije mijenjala do dvanaestog koraka, kada je eliminiran član C^2MY , a nakon toga je rasla za vrlo male iznose. U slučaju ovoga procesa eliminacija članova koji sadrže određene kanale nije bitno utjecala na rast signifikantnosti bilo kojih članova koji sadrže iste kanale, već samo sličnih članova koji sadrže iste kanale s različitim potencijama.

Slika 8.61 prikazuje relativne signifikantnosti tri člana koji su bili najsignifikantniji u prвome koraku postupka eliminacije. Uočljivo je da je član C bio najsignifikantniji od svih članova tijekom gotovo cijelog postupka eliminacije, ali osim što je u petnaestom koraku najsignifikantniji član postao C, vidljivo je da je u devetom koraku najsignifikantnjim postao neki drugi član. To je bio član M. U slučaju ovoga procesa moguće je utvrditi određene pravilnosti u promjenama signifikantnosti članova s obzirom na eliminirane članove, slično kao i kod drugih procesa. No, kao ni kod drugih procesa, nije vidljiv jasan uzorak u izboru eliminiranih članova, niti je vidljiv uzorak među najsignifikantnjim članovima.

Slika 8.46 prikazuje kretanje signifikantnosti tri člana koji su u zadnjem koraku eliminacije bili najsignifikantniji s obzirom na vrijednost F, a Slika 8.62 prikazuje relativne signifikantnosti članova koji su u zadnjem koraku eliminacije bili najsignifikantniji. Kako su se u slučaju ovoga procesa sva tri člana koji su bili najsignifikantniji na početku postupka eliminacije održali kao najsignifikantniji na kraju postupka, ti prikazi ne daju dodatne informacije.

Tabela 8.25, Eliminirani članovi u procesu H

Eliminacijski korak	Članovi	Eliminacijski korak	Članovi
2	Y^4C	14	Y^3C
3	C^4M	15	CM^2Y
4	Y^5	16	M^4
5	Y^4	17	Y^3C^2
6	M^3C	18	C^3Y
7	C^3	19	C^3Y^2
8	C^2MY	20	C^2M^2
9	Y^4M	21	C^2M
10	M^3Y	22	C^2
11	M^2C	23	M^4Y
12	Y^3M^2	24	Y^3M
13	Y^2		

Slika 8.47 prikazuje kretanje signifikantnosti tri člana koji su prvome koraku bili najsignifikantniji s obzirom na vrijednost F. Do dvanaestog koraka eliminacije signifikantnosti sva tri člana rasle su postupno, a u trinaestom koraku, eliminacijom člana Y^2 signifikantnost člana Y naglo je porasla i on se do kraja održao kao najsignifikantniji član. U dvadesetdrugome koraku, nakon eliminacije člana C^2 došlo je do vrlo nagloga rasta signifikantnosti člana C. U petnaestom koraku, nakon eliminacije člana CM^2Y došlo je do nagloga rasta signifikantnosti člana M. Prva dva člana slijede sličnu pravilnost utvrđenu u slučaju prethodnoga procesa, ali treći član, M, odstupa od toga pravila. Iako bi moglo biti uočeno kako je do nagloga rasta njegove signifikantnosti u petnaestom koraku došlo eliminacijom interakcijskoga člana koji sadrži kanal M, valja uočiti kako su i u mnogo drugih koraka eliminirani članovi koji su sadržavali kanal M i to s višim potencijama, a nije došlo do drastičnih promjena signifikantnosti člana M.

Slika 8.63 prikazuje relativne signifikantnosti tri člana koji su bili najsignifikantniji u prвome koraku postupka eliminacije. Uočljivo je da je član Y bio najsignifikantniji od svih članova u većem dijelu postupka eliminacije, osim od osmog do dvanaestog koraka kada je najsignifikantniji bio član C. Na kraju postupka članovi Y i C bili su podjednako signifikantni, a član M je imao daleko manju značajnost. Pregledom eliminiranih članova nije moguće utvrditi zašto je nastupila tolika razlika. Osim toga, treba uočiti da je nakon nagloga rasta signifikantnosti člana M u petnaestom koraku, došlo do nagloga pada u šesnaestom koraku nakon eliminacije člana M^4 , što je u potpunoj suprotnosti s dosad utvrđenim pravilima kretanja signifikantnosti članova.

Slika 8.48 prikazuje kretanje signifikantnosti tri člana koji su u zadnjem koraku eliminacije bili najsignifikantniji s obzirom na vrijednost F, a Slika 8.64 prikazuje relativne signifikantnosti članova koji su u zadnjem koraku eliminacije bili najsignifikantniji. Kako su se u slučaju ovoga procesa sva tri člana koji su bili najsignifikantniji na početku postupka eliminacije održali kao najsignifikantniji na kraju postupka, ti prikazi ne daju dodatne informacije.

9. Zaključak

Cilj ovoga rada bio je istražiti kriterije u podacima o uređajima prema kojima bi se birali prikladni članovi modela i time formirali modeli prilagođeni uređajima. Taj je cilj bio utemeljen na hipotezama da pojedini članovi modela mogu povećati ili smanjiti njegovu sposobnost prilagodbe i moći predviđanja te da je tražena svojstva modela moguće odrediti prema kriterijima u podacima o uređaju. Prvi dio istraživanja sastojao se od evaluacije sposobnosti prilagodbe i moći predviđanja pet osnovnih modela koji se često javljaju u ranijim publikacijama na tri različite domene, te evaluacije sposobnosti prilagodbe i moći predviđanja nepotpunih modela formiranih dodavanjem proizvoljno odabranih skupina članova modelu četvrtoga reda s 23 člana. Dodatne skupine članova su odabранe tako da su različitih redova i da se sastoje od različitog broja članova. Evaluacija je provedena na tri različite domene kako bi se utvrdilo postoje li razlike u utjecaju pojedinih članova na sposobnost prilagodbe i moći predviđanja modela na različitim domenama. Utvrđeno je da pojedini članovi odnosno skupine članova na jednoj domeni mogu povećati, a na drugoj smanjiti sposobnost prilagodbe ili moći predviđanja modela. Ta je pojava značajna stoga što se karakteristike podataka transformacijom na različite domene mijenjaju pa se time potvrđuje hipoteza da je izbor članova modela važan s obzirom na karakteristike podataka. Utvrđeno je i to da se formiranjem nepotpunih modela viših redova može smanjiti sposobnost prilagodbe modela, što nije objavljeno u ranijim istraživanjima s obzirom da su u njima evaluirani modeli koji sadrže članove svih redova do maksimalnoga. Bio je poznat problem pretjerane prilagodbe, a pojava smanjene sposobnosti prilagodbe nepotpunih modela visokih redova otkrivena u ovom istraživanju ima potencijal praktične primjene pri određivanju maksimalnog dozvoljenog reda modela. Vrijedi istaknuti i značajnije promjene u razdiobi odstupanja zabilježene u slučajevima nekih modela ispitanih u ovome istraživanju. Karakteristike razdiobe također mogu poslužiti pri izboru članova i određivanju maksimalnoga reda modela na način da ih se usporedi s razdiobom odstupanja osnovnog modela od podataka. Pri tome manji značaj imaju promjene gdje razdioba odstupanja poprima naglašeniji pozitivan asimetričan oblik, ali u slučajevima kada razdioba odstupanja teži simetričnom ili negativnom asimetričnom obliku te pojave ukazuju na smanjenu sposobnost prilagodbe odnosno moći predviđanja modela.

U drugome dijelu istraživanja određene su statističke signifikantnosti pojedinih skupina članova i pojedinih članova modela. Istraživanje je provedeno na osam procesa, to jest četiri različita pisača koristeći dva tipa papira. Pri određivanju signifikantnosti su korištena dva pristupa, određivanje signifikantnosti skupina članova i određivanje signifikantnosti članova pojedinačno. Prvi pristup je za cilj imao utvrđivanje postojanja uzorka u potencijama nad nezavisnim varijablama unutar članova koji se u promatranim procesima ocijene signifikantima, odnosno postojanja sličnog uzorka u potencijama nad nezavisnim varijablama unutar članova koji se ocijene nesignifikantima. Utvrđeno je da je u većini procesa najsignifikantnija skupina linearnih članova $C \ M \ Y$ i da je ta skupina u većini slučajeva najsignifikantnija tijekom cijelog postupka eliminacije, od početka do kraja. U slučajevima dva procesa najsignifikantnjima su se pokazale skupine interakcijskih članova. Primjećeno je da se eliminacijom određenih skupina članova mijenja signifikantnost nekih drugih skupina članova, dok neke zadržavaju istu vrijednost značajnosti. Suprotno očekivanju da će se pri tome pojaviti neki jasno uočljiv uzorak, nije bilo moguće odrediti koje skupine članova ovise o kojima. Iako je za potrebe ovoga istraživanja bila odabrana metoda eliminacije skupina članova koja u odnosu na metodu dodavanja skupina članova umanjuje „efekt tlačitelja“, to jest efekt da je neki član signifikantan samo uz prisutnost nekog drugog

člana, kod modela izlaznih uređaja postoje prevelike međuvisnosti skupina članova da bi se metodom eliminacije utvrdio uzorak u izboru signifikantnih skupina članova modela. Ipak, optimizacijom modela provedenom ovim pristupom postignuti su dobri rezultati. Reducirani modeli pokazali su se znatno preciznijima s obzirom na rezultate evaluacije na nezavisnom skupu podataka B, ali i na psihofizičkoj evaluaciji slika koristeći maksimalne i reducirane modele. Poboljšanja su posebno uočljiva u slučajevima procesa za koje su odabrani maksimalni modeli koji premašuju maksimalni dozvoljeni red za te procese. U tim su slučajevima na slikama transformiranim koristeći maksimalne modele uočene greške kao posljedica pretjerane prilagodbe modela. Reducirani modeli znatno su umanjili ili potpuno uklonili te greške iako nisu bili eliminirani svi članovi viših redova. Ovdje treba napomenuti da u sklopu ovoga istraživanja zbog opsežnosti nije provedena sveobuhvatna psihofizička evaluacija na većem broju ispitanika. Drugi pristup, eliminacija članova pojedinačno, za cilj je imao utvrđivanje postojanja uzorka u samim članovima koji se u promatrаниm procesima ocijene signifikantnim, odnosno postojanja sličnog uzorka u članovima koji se ocijene nesignifikantnim. Osim postojanja uzorka, cilj je bio utvrđivanje razlika u linearnosti pojedinih kanala, to jest određivanje pravilnog izbora članova s obzirom na linearnost pojedinih kanala i složenost interakcija među njima. Taj se pristup razlikuje od dosadašnjeg u tome što su u dosadašnjim istraživanjima formirani modeli koji sadrže sve članove do određenoga reda, bez obzira na razlike u složenosti kanala i interakcija među kanalima uređaja. Utvrđeno je da su u slučaju dva od osam procesa na kraju postupka eliminacije najsignifikantniji bili linearni članovi C M Y, a u slučaju tri procesa ti su članovi bili najsignifikantniji i na početku. U ostalim slučajevima najsignifikantniji su bili neki od linearnih i interakcijski članovi ili samo interakcijski članovi. Slično kao i kod postupka eliminacije skupina članova, i ovome je postupku eliminacija pojedinih članova utjecala na promjenu signifikantnosti drugih članova. U svim slučajevima je primjećeno da eliminacija članova s jednim kanalom određenoga reda utječe na signifikantnost ostalih članova s tim kanalom drugih redova te da, slično tome, eliminacija interakcijskih članova koji sadrže određene kanale najviše utječe na signifikantnost ostalih članova koji sadrže te iste kanale. U većini slučajeva taj se utjecaj očituje rastom signifikantnosti zadržanih članova, ali zabilježen je i slučaj u kojem je došlo do smanjenja signifikantnosti. Kao ni pristupom eliminacije skupina članova, niti pristupom eliminacije pojedinih članova nije utvrđen jasan uzorak među signifikantnim, odnosno nesignifikantnim članovima modela pojedinih procesa. Razlog tome je isti, prevelika međuvisnost članova modela. Ipak, kao i kod pristupa eliminacije skupina članova, eliminacijom pojedinih članova dobiveni su reducirani modeli znatno precizniji u odnosu na maksimalne.

Metoda eliminacije u oba pristupa, eliminacija skupina članova i eliminacija pojedinačnih članova nije otkrila jasan uzorak u izboru signifikantnih članova modela. Iako su reducirani modeli dobiveni ovim postupcima znatno bolji u odnosu na maksimalne, ne može ih se smatrati najboljim mogućima. Naime, zbog međuvisnosti članova ti su modeli najbolji mogući s obzirom na tijek postupka eliminacije, ali to ne znači da je time dobivena najbolja moguća kombinacija članova. Metoda kojom bi ona mogla biti određena nije poznata. Iako ovim pristupom nije ispunjen cilj određivanja signifikantnih članova sa svrhom formiranja modela s obzirom na karakteristike podataka o uređaju, za razliku od dosadašnjih istraživanja je ukazano na utjecaj članova modela na sposobnost prilagodbe i moć predviđanja modela. Pokazano je i to da je metoda eliminacije primjenjiva za poboljšanja i može biti iskorištena kada je potrebno odrediti preciznije modele uređaja kako bi oni bili primjenjivi s obzirom na traženu preciznost.

10. Literatura

1. **Fraser, B, Murphy, C i Bunting, F.** *Real World Color Management*. Berkeley : Peachpit Press, 2005. ISBN-13: 978-0-321-26722-1.
2. *Adaptive Statistical Methods for Optimal Color Selection and Spectral Characterization of Color Scanners.* **Kosztyan, Z. T.** 2009, The Journal of Imaging Science and Technology, str. 1-10. ISBN / ISSN: 1062-3701.
3. *Color selections for characterization charts.* **Cheung, T. L. V i Westland, S.** s.l. : Second European Conference on Color in Graphics, Imaging and Vision, 2004.
4. *Analysis of colour targets for output characterization.* **Mahy, M.** s.l. : IS&T/SID Color Imaging Conference, 2000. Proceedings. str. 348-355.
5. *A New Colour Selection Method for Characterising Digital Cameras.* **Chou, Y, Li, C i Luo, M. R.** s.l. : Seventeenth Color Imaging Conference: Color Science and Engineering Systems, Technologies, and Applications, 2009. Proceedings. str. 75-78. ISBN / ISSN: 978-0-89208-288-9.
6. *An Efficient High Quality Color Transformation.* **Tastl, I, i dr.** s.l. : Seventeenth Color Imaging Conference: Color Science and Engineering Systems, Technologies, and Applications, 2009. Proceedings. str. 111-116. ISBN / ISSN: 978-0-89208-288-9.
7. **Johnson, T.** Methods for characterizing colour scanners and digital cameras. [ur.] P Green i L MacDonald. *Colour Engineering*. Chichester : Wiley, 2002, 8, str. 165-178.
8. *Color printer characterization adjustment for different substrates.* **Shaw, M, i dr.** 2003, Color research and applications, str. 454-467.
9. *Maintaining an accurate printer characterization.* **Littlewood, D i Subbarayan, G.** s.l. : Twelfth Color Imaging Conference: Color Science and Engineering Systems, Technologies, and Applications, 2004. str. 203-210. ISBN / ISSN: 0-89208-254-2.
10. *Evaluating the Use of the Perceptual Reference Medium Gamut in ICC Printing Works.* **Bonnier, N i Green, P, Sarlat, A.** s.l. : Seventeenth Color Imaging Conference: Color Science and Engineering Systems, Technologies, and Applications, 2009. Proceedings. str. 227-232. ISBN / ISSN: 978-0-89208-288-9.
11. *Using the ICC V4 Reference Medium Gamut in a real-world color workflow.* **Guay, R i Shaw, M.** s.l. : Sixteenth Color Imaging Conference: Color Science and Engineering Systems, Technologies, and Applications, 2008. Proceedings. str. 265-267. ISBN / ISSN: 978-0-89208-281-0.
12. *Specification ICC.1:2004-10.* s.l. : ICC, 2004.
13. *Color transformation accuracy and efficiency in ICC color management.* **Zeng, H i Nielson, M.** s.l. : Ninth Color Imaging Conference: Color Science and Engineering: Systems, Technologies, and Applications, 2001. Proceedings. ISBN / ISSN: 0-89208-235-6.

14. *Color accuracy in ICC color management system.* **Zeng, H.** s.l. : IS&T's 2002 PICS Conference. Proceedings. str. 175-180.
15. *Inside the ICC color device profile.* **Pawle, G. B.** s.l. : IS&T/SID 1995 Color Imaging Conference: Color Science, Systems and Applications, 1995. Proceedings. str. 160-163.
16. *Extraction of non-linear components from 3DLUT in ICC profiles and re-composition of new profile for better color reproduction.* **Fumoto, T, Yamada, O i Motomura, H.** s.l. : IS&T's NIP 13: 1997 International Conference on Digital Printing Technologies, 1997. Proceedings. str. 475-478.
17. *Printer characterization using adaptive constraint optimization.* **Urban, P i Grigat, R.** s.l. : Conference on Colour Graphics, Imaging, and Vision, 2002. Proceedings. str. 574-579.
18. *Using Sheperd's interpolation to build color transformation tables.* **Rolleston, R.** s.l. : IS&T/SID Colour Imaging Conference, 1994. Proceedings. str. 74-77.
19. *Computational Geometry Solution to Nonunique Forward Model Inversion for Multi-ink Printing.* **Braun, G. J, i dr.** s.l. : Sixteenth Color Imaging Conference: Color Science and Engineering Systems, Technologies, and Applications, 2008. Proceedings. str. 254-258. ISBN / ISSN: 978-0-89208-281-0.
20. *Two approaches in scanner-printer calibration: Colorimetric space-based vs. "closed-loop".* **Ostromoukhov, V, i dr.** s.l. : IS&T/SPIE International Symposium on Electronic Imaging: Science & Technology, 1994. Proceedings. str. 133-142.
21. *Color Look-Up Table Design for Gamut Mapping and Color Space Conversion.* **Kim, Y, i dr.** s.l. : International Conference on Digital Production Printing and Industrial Applications, 2003. str. 28-29. ISBN / ISSN: 0-89208-246-1.
22. *Spectral prediction model for variable dot-size printers.* **Rousselle, F, Bugnon, T i Hersch, R. D.** s.l. : Sixteenth Color Imaging Conference: Color Science and Engineering Systems, Technologies, and Applications, 2008. Proceedings. str. 73-78. ISBN / ISSN: 978-0-89208-281-0.
23. *A Printer Model for Color Printing.* **Zeng, H i Chin, B.** s.l. : 50th Annual Conference: A Celebration of All Imaging. Proceedings. str. 284-288. ISBN / ISSN: 0-89208-199-6.
24. *Ink-Dependent n-Factors for the Yule-Nielsen Modified Spectral Neugebauer Model.* **Rossier, R i Hersch, R. D.** s.l. : Fourth European Conference on Colour in Graphics, Imaging, and MCS/10 Vision 12th International Symposium on Multispectral Colour Science, 2010. Proceedings. str. 202-206. ISBN / ISSN: 978-0-89208-291-9.
25. *Optimization of the Predicting Model for Dye-Based Inkjet Printer.* **Ogasahara, T.** s.l. : NIP19: International Conference on Digital Printing Technologies, 2003. Proceedings. str. 785-788. ISBN / ISSN: 0-89208-247-X.

26. *Verification of the Optimum Predicting Model for Dye-Based Inkjet Printer.* **Ogasahara, T i Ohta, N.** s.l. : Image Processing, Image Quality, Image Capture Systems Conference, 2003. Proceedings. str. 429-434. ISBN / ISSN: 0-89208-245-3.
27. *A Mathematical Model for Inkjet Printer Characterisation.* **Roberts, P.** s.l. : Eighth Color Imaging Conference: Color Science and Engineering Systems, Technologies, and Applications, 2000. Proceedings. str. 134-139. ISBN / ISSN: 0-89208-231-3.
28. *Spectral-Based Printer Characterization of RGB Printers.* **Zuffi, S i Schettini, R.** s.l. : First European Conference on Color in Graphics, Imaging and Vision, 2002. str. 598-602. ISBN / ISSN: 0-89208-239-9.
29. *Accuracy of Various Types of Neugebauer Model.* **Rolleston, R i Balasubramanian, R.** s.l. : First Color Imaging Conference: Transforms and Transportability of Color, 1993. Proceedings. str. 32-36. ISBN / ISSN: 0-89208-174-0.
30. *Further Accelerating the Inversion of the Yule-Nielson Modified Neugebauer Model.* **Li, C i Luo, M. R.** s.l. : Sixteenth Color Imaging Conference: Color Science and Engineering Systems, Technologies, and Applications, 2008. Proceedings. str. 84-88. ISBN / ISSN: 978-0-89208-281-0.
31. *Yule-Nielsen Approach for Predicting the Spectral Transmittance of Halftone Prints.* **Hebert, M i Hersch, R. D.** s.l. : Seventeenth Color Imaging Conference: Color Science and Engineering Systems, Technologies, and Applications, 2009. str. 155-158. ISBN / ISSN: 978-0-89208-288-9.
32. **Morovič, J.** To develop a universal gamut mapping algorithm. *Doktorska disertacija.* s.l. : University of Derby, 1998.
33. *A Model for Colour Prediction of Halftoned Samples Incorporating Light Scattering and Ink Spreading.* **Emmel, P i Hersch, R. D.** s.l. : Seventh Color Imaging Conference: Color Science, Systems and Applications, 1999. Proceedings. str. 173-181. ISBN / ISSN: 0-89208-224-0.
34. *A unified model for color prediction of halftoned prints.* **Emmel, P i Hersch, R. D.** s.l. : Journal of Imaging Science and Technology, 2000, str. 351-359.
35. *Applications of colour mixing models to electronic printing.* **Kang, H. R.** s.l. : Journal of Electronic Imaging, 1994, str. 276-287.
36. *Input Device Characterisation: A Comparison Between Iteration and Regression Methods Using Either XYZ or L*a*b*.* **Izadan, H i Nobbs, J. H.** s.l. : Third European Conference on Color in Graphics, Imaging and Vision, 2006. Proceedings. str. 158-162.
37. *Comparing different methods of printer characterization.* **Herzog, P i Roger, T.** s.l. : IS&T 51st PICS Conference, 1998. Proceedings. str. 23-29.
38. **Westland, S i Ripamonti, C.** *Computational Color Science Using Matlab.* Chichester : Wiley, 2004. ISBN: 0-470-84562-7.

39. *A neural network approach to color reproduction in color printers.* **Tominaga, S.** s.l. : IS&T/SID Color Imaging Conference, 1993. Proceedings. str. 173-177.
40. *Color printer characterization using radial basis function networks.* **Artusi, A i Wilkie, A.** 2001. Proceedings of Color Imaging: Device-Independent Color, Color Hardcopy, and Graphic Arts. str. 70-80.
41. *A comparative study of the characterization of colour cameras by means of neural networks and polynomial transforms.* **Cheung, T. L. V i Westland, S.** s.l. : Journal of Coloration Technology, 2004.
42. *Color camera characterization using artificial neural networks.* **Cheung, T. L. V i Westland, S.** s.l. : Tenth Color Imaging Conference, 2002. Proceedings. str. 117-120.
43. **Green, P.** Overview of characterization methods. *Colour Enginnering.* Chichester : John Wiley & Sons, 2002, 6, str. 127-141.
44. *A tetrahedral interpolation technique for colour space conversion.* **Kasson, J, Plouffe, J i Nin, S.** s.l. : SPIE Conference, 1993. Proceedings. str. 127-138.
45. *CIELAB to CMYK color conversion by prism and slant prism interpolation method.* **Motomura, H, i dr.** s.l. : IS&T/SID Color Imaging Conference, 1994. Proceedings. str. 156-158.
46. *A minimax method for sequential linear interpolation on non-linear colour transforms.* **Agar, A i Allebach, J. P.** s.l. : IS&T/SID Colour Imaging Conference, 1996. Proceedings. str. 1-5.
47. *Efficient Implementation of Nonlinear Color Transformations.* **Allebach, J. P, Chang, J. Z i Bouman, C. A.** s.l. : First Color Imaging Conference: Transforms and Transportability of Color, 1993. Proceedings. str. 143-148. ISBN / ISSN: 0-89208-174-0.
48. *Device characterization using spline smoothing and sequential linear interpolation.* **Bell, I. E i Cowan, W.** s.l. : IS&T/SID Colour Imaging Conference, 1994. Proceedings. str. 29-33.
49. *Improved color table inversion near the gamut boundary.* **Bhachech, M, Shaw, M i DiCarlo, J. M.** s.l. : 14th Color Imaging Conference, 2006. Proceedings. str. 44-49.
50. **Bala, R.** Device characterization. [ur.] G Sharma. *Digital Color Imaging Handbook.* Boca Raton : CRC Press, 2003, 5, str. 269-284.
51. *The characterisation of colour printing devices via physical, numerical and LUT models.* **Lo, M, i dr.** s.l. : Third European Conference on Color in Graphics, Imaging and Vision, 2006. str. 95-99. ISBN / ISSN: 0-89208-262-3 .
52. **Sharma, G i al., et.** *Digital Color Imaging Handbook.* Boca Raton : CRC Press, 2003. ISBN: 0-8493-0900.
53. *Characterizing desktop printers without full control of all colorants.* **Morovič, J i Luo, R. M.** s.l. : IS&T/SID Color Imaging Conference, 1996. Proceedings. str. 70-74.

54. Croarkin, C, Tobias, P i al., at. *Engineering Statistics Handbook*. s.l. : NIST/SEMATECH, 2003.
55. A study of digital camera colorimetric characterization based on polynomial modeling. Hong, G. W, Luo, M. R i Rhodes, P. A. 2001, Color Research and Application, str. 76-84.
56. Color calibration of scanners using polynomial transformation. Yilmaz, Y, i dr. s.l. : ISPRS Congress, 2004. Proceedings. str. 890-895.
57. Color Calibration of Digital Camera Using Polynomial Transformation. Jetsu, T, i dr. s.l. : Third European Conference on Color in Graphics, Imaging and Vision, 2006. Proceedings. str. 163-166. ISBN / ISSN: 0-89208-262-3 .
58. Evaluating the Effect of Noise on 3D LUT-Based Color Transformations. Wang, Z, Aristova, A i Hardeberg, J. Y. s.l. : CGIV 2010 -- Fourth European Conference on Colour in Graphics, Imaging, and MCS/10 Vision 12th International Symposium on Multispectral Colour Science, 2010. Proceedings. str. 88-93. ISBN / ISSN: 978-0-89208-291-9.
59. End-to-end color printer calibration by total least squares regression. Xia, M, i dr. 1999, IEEE Transactions on Image Processing, str. 700-716.
60. Total least squares regression in neugebauer model parameter estimation for dot-on-dot halftone screens. Xia, M, i dr. s.l. : IS&T's NIP 14: International Conference on Digital Printing Technologies, 1998.
61. Constrained least-squares regression in color spaces. Finlayson, G. D i Drew, M. S. s.l. : Journal of Electronic Imaging, 1997, str. 484-493.
62. White-Point Preserving Color Correction. Finlayson, G. D i Drew, M. S. s.l. : Fifth Color Imaging Conference: Color Science, Systems and Applications, 1997. Proceedings. str. 258-261. ISBN / ISSN: 0-89208-206-2.
63. Colour printer characterization by regression with greyspace constraint. Drew, M. S, i dr. s.l. : Sixth Color Imaging Conference: Color Science, Systems and Applications, 1998. Proceedings. str. 193-196. ISBN / ISSN: 0-89208-213-5 .
64. A test target for defining media gamut boundaries. Green, P. J. s.l. : Color Imaging: Device-Independent Color, Color Hardcopy, and Graphic Arts, 2001. Proceedings. str. 105-113.
65. Building Accurate and Smooth ICC Profiles by Lattice Regression. Garcia, E. K i Gupta, M. R. s.l. : Seventeenth Color Imaging Conference: Color Science and Engineering Systems, Technologies, and Applications, 2009. Proceedings. str. 101-106. ISBN / ISSN: 978-0-89208-288-9.
66. Shaped Local Regression and its Application to Color Transforms. Monga, V i Bala, R. s.l. : Seventeenth Color Imaging Conference: Color Science and Engineering Systems, Technologies, and Applications, 2009. Proceedings. str. 272-277. ISBN / ISSN: 978-0-89208-288-9.

67. **Field, A.** *Discovering Statistics Using SPSS: Third Edition*. London : Sage Publications, 2009. ISBN: 978-1847879073.
68. **Kleinbaum, G. D, i dr.** *Applied Regression Analysis and Other Multivariable Methods*. Belmont : Duxbury, 2008. ISBN: 978-0-495-38496-0.
69. *Statistical distribution of CIELAB color difference*. **Viggiano, J. A. S.** s.l. : Neobjavljeni rad, <http://sysdoc.doors.ch/BORLAND/Statistics.pdf>, 1999.

PRILOG A

Proces A

Tabela A.1, Odstupanje maksimalnog modela od empirijskih podataka, proces A

	N - broj polja	dEab	Min	Medijan	Maks	Int. pouz. 95%
RGB->D	918	1,49	0,16	1,31	6,18	0,11

Tabela A.2, Postupak eliminacije skupina članova, proces A

Korak 1		
Blok članova	Fp	p
C M Y	21,78264159	0,00000000
C ⁴ M ² Y ² C ² M ⁴ Y ² C ² M ² Y ⁴	15,49828825	0,00000000
C ³ M ³ Y ² C ³ M ² Y ³ C ² M ³ Y ³	8,32933172	0,00001872
C ⁴ M ³ Y C ⁴ MY ³ C ³ M ⁴ Y CM ⁴ Y ³ C ³ MY ⁴ CM ³ Y ⁴	7,60579523	0,00000006
C ⁵ MY CM ⁵ Y CMY ⁵	5,54095707	0,00091525
C ⁵ M ² Y C ⁵ MY ² C ² M ⁵ Y CM ⁵ Y ² C ² MY ⁵ CM ² Y ⁵	5,00454116	0,00004841
C ⁴ MY CM ⁴ Y CMY ⁴	4,68296271	0,00300322
C ³ M ³ M ³ Y ³ C ³ Y ³	3,76895719	0,01054229
C ⁷ M M ⁷ Y Y ⁷ C C ⁷ Y M ⁷ C Y ⁷ M	3,31359293	0,00316149
C ² M ² M ² Y ² C ² Y ²	3,30513439	0,01981757
C ⁵ M ³ M ⁵ Y ³ Y ⁵ C ³ C ⁵ Y ³ M ⁵ C ³ Y ⁵ M ³	3,05574142	0,00583646
C ³ M ² Y ² C ² M ³ Y ² C ² M ² Y ³	2,49646630	0,05866144
C ³ M ² Y C ³ MY ² C ² M ³ Y CM ³ Y ² C ² MY ³ CM ² Y ³	1,69383176	0,11960992
C ⁴ M ³ M ⁴ Y ³ Y ⁴ C ³ C ⁴ Y ³ M ⁴ C ³ Y ⁴ M ³	1,30035405	0,25446426
Odsječak	1,22581925	0,26857379
C ² M ² Y ²	1,02207196	0,31235149
C ³ MY CM ³ Y CMY ³	0,75225176	0,52121923
C ⁴ M ² Y C ⁴ MY ² C ² M ⁴ Y CM ⁴ Y ² C ² MY ⁴ CM ² Y ⁴	0,68559201	0,66135514
C ⁴ M ⁴ M ⁴ Y ⁴ C ⁴ Y ⁴	0,56989956	0,63495761
C ² M ² Y C ² MY ² CM ² Y ²	0,32954093	0,80400315
C ⁶ MY CM ⁶ Y CMY ⁶	0,32700799	0,80584055
C ⁶ M M ⁶ Y Y ⁶ C C ⁶ Y M ⁶ C Y ⁶ M	- 0,03434395	1,00000000
C ³ M ² M ³ Y ² Y ³ C ² C ³ Y ² M ³ C ² Y ³ M ²	- 0,25973725	1,00000000
C ² MY CM ² Y CMY ²	- 0,28573150	1,00000000
C ⁴ M ² M ⁴ Y ² Y ⁴ C ² C ⁴ Y ² M ⁴ C ² Y ⁴ M ²	- 1,16840562	1,00000000
C ⁶ M ² M ⁶ Y ² Y ⁶ C ² C ⁶ Y ² M ⁶ C ² Y ⁶ M ²	- 2,00747813	1,00000000
CM MY CY	- 2,12912369	1,00000000
C ⁴ M ⁴ Y ⁴	- 2,56730408	1,00000000
C ⁵ M ² M ⁵ Y ² Y ⁵ C ² C ⁵ Y ² M ⁵ C ² Y ⁵ M ²	- 2,56808887	1,00000000
C ⁵ M ⁵ Y ⁵	- 3,21967286	1,00000000
C ³ M ³ Y ³	- 3,38501820	1,00000000

C ⁵ M M ⁵ Y Y ⁵ C C ⁵ Y M ⁵ C Y ⁵ M	- 3,52172560	1,00000000
C ² M M ² Y Y ² C C ² Y M ² C Y ² M	- 3,54360181	1,00000000
C ⁶ M ⁶ Y ⁶	- 4,05246353	1,00000000
CMY	- 4,41158252	1,00000000
C ⁸ M ⁸ Y ⁸	- 4,43695897	1,00000000
C ⁷ M ⁷ Y ⁷	- 4,51755187	1,00000000
C ³ M M ³ Y Y ³ C C ³ Y M ³ C Y ³ M	- 5,20437890	1,00000000
C ⁴ M M ⁴ Y Y ⁴ C C ⁴ Y M ⁴ C Y ⁴ M	- 5,97448843	1,00000000
C ² M ² Y ²	- 6,52518894	1,00000000
Korak 2: eliminacija bloka C² M² Y²		
C M Y	50,61808962	0,00000000
C ³ M ³ Y ³	14,28775166	0,00000000
C ⁴ M ² Y ² C ² M ⁴ Y ² C ² M ² Y ⁴	11,07461113	0,00000040
C ⁴ M ⁴ Y ⁴	9,36433106	0,00000440
C ³ M ³ Y ² C ³ M ² Y ³ C ² M ³ Y ³	8,48802493	0,00001498
C ⁴ M ³ Y C ⁴ MY ³ C ³ M ⁴ Y CM ⁴ Y ³ C ³ MY ⁴ CM ³ Y ⁴	8,08119441	0,00000002
C ⁵ M ⁵ Y ⁵	5,67024232	0,00076454
C ⁵ MY CM ⁵ Y CMY ⁵	4,54911242	0,00361157
C ⁷ M M ⁷ Y Y ⁷ C C ⁷ Y M ⁷ C Y ⁷ M	3,95982909	0,00065725
C ³ M ³ M ³ Y ³ C ³ Y ³	3,53489060	0,01450401
C ⁴ MY CM ⁴ Y CMY ⁴	3,28799559	0,02028106
Odsječak	3,23098776	0,07265447
C ⁵ M ² Y C ⁵ MY ² C ² M ⁵ Y CM ⁵ Y ² C ² MY ⁵ CM ² Y ⁵	3,20776131	0,00406923
C ⁶ M ⁶ Y ⁶	3,13034110	0,02510111
C ² M ² M ² Y ² C ² Y ²	2,95911685	0,03161510
C ⁵ M ³ M ⁵ Y ³ Y ⁵ C ³ C ⁵ Y ³ M ⁵ C ³ Y ⁵ M ³	2,44403877	0,02394606
C ⁶ M ² M ⁶ Y ² Y ⁶ C ² C ⁶ Y ² M ⁶ C ² Y ⁶ M ²	1,51468193	0,17034937
C ⁷ M ⁷ Y ⁷	1,49007503	0,21588193
C ³ M ² Y ² C ² M ³ Y ² C ² M ² Y ³	1,36805057	0,25130469
C ³ M ² M ³ Y ² Y ³ C ² C ³ Y ² M ³ C ² Y ³ M ²	1,33783582	0,23767361
C ³ M ² Y C ³ MY ² C ² M ³ Y CM ³ Y ² C ² MY ³ CM ² Y ³	1,25636279	0,27535937
C ⁴ M ³ M ⁴ Y ³ Y ⁴ C ³ C ⁴ Y ³ M ⁴ C ³ Y ⁴ M ³	1,09386848	0,36424994
C ⁴ M ⁴ M ⁴ Y ⁴ C ⁴ Y ⁴	0,84273822	0,47066897
C ⁴ M ² M ⁴ Y ² Y ⁴ C ² C ⁴ Y ² M ⁴ C ² Y ⁴ M ²	0,60648478	0,72529094
C ⁸ M ⁸ Y ⁸	0,58329051	0,62609371
C ⁵ M ² M ⁵ Y ² Y ⁵ C ² C ⁵ Y ² M ⁵ C ² Y ⁵ M ²	0,21136944	0,97325975
C ⁶ MY CM ⁶ Y CMY ⁶	0,18597567	0,90595618
C ⁶ M M ⁶ Y Y ⁶ C C ⁶ Y M ⁶ C Y ⁶ M	0,16967476	0,98484103
C ⁴ M ² Y C ⁴ MY ² C ² M ⁴ Y CM ⁴ Y ² C ² MY ⁴ CM ² Y ⁴	0,15945295	0,98713197
C ² M M ² Y Y ² C C ² Y M ² C Y ² M	- 0,01342422	1,00000000
C ³ MY CM ³ Y CMY ³	- 0,35281695	1,00000000
C ² M ² Y ²	- 0,48888116	1,00000000
C ² M ² Y C ² MY ² CM ² Y ²	- 1,18416321	1,00000000

CM MY CY	- 1,20763360	1,00000000
C ² MY CM ² Y CMY ²	- 1,76236112	1,00000000
C ³ M M ³ Y Y ³ C C ³ Y M ³ C Y ³ M	- 2,83050602	1,00000000
C ⁵ M M ⁵ Y Y ⁵ C C ⁵ Y M ⁵ C Y ⁵ M	- 3,27168125	1,00000000
CMY	- 5,00919283	1,00000000
C ⁴ M M ⁴ Y Y ⁴ C C ⁴ Y M ⁴ C Y ⁴ M	- 5,02168255	1,00000000
Korak 3: eliminacija bloka C⁴M M⁴Y Y⁴C C⁴Y M⁴C Y⁴M		
C M Y	39,60502067	0,00000000
C ⁶ M ² M ⁶ Y ² Y ⁶ C ² C ⁶ Y ² M ⁶ C ² Y ⁶ M ²	18,61463372	0,00000000
C ⁵ M ² M ⁵ Y ² Y ⁵ C ² C ⁵ Y ² M ⁵ C ² Y ⁵ M ²	10,74887756	0,00000000
C ⁴ M ³ Y C ⁴ MY ³ C ³ M ⁴ Y CM ⁴ Y ³ C ³ MY ⁴ CM ³ Y ⁴	7,95300895	0,00000002
C ⁴ M ² Y ² C ² M ⁴ Y ² C ² M ² Y ⁴	7,60564463	0,00005138
C ³ M ³ Y ² C ³ M ² Y ³ C ² M ³ Y ³	7,06349374	0,00010959
C ⁶ M M ⁶ Y Y ⁶ C C ⁶ Y M ⁶ C Y ⁶ M	6,98978193	0,00000030
C ⁵ M M ⁵ Y Y ⁵ C C ⁵ Y M ⁵ C Y ⁵ M	6,95600689	0,00000033
C ⁷ M M ⁷ Y Y ⁷ C C ⁷ Y M ⁷ C Y ⁷ M	6,85724301	0,00000042
CM MY CY	6,70187250	0,00018156
C ³ M ³ Y ³	5,55511254	0,00089660
C ³ M M ³ Y Y ³ C C ³ Y M ³ C Y ³ M	5,25626073	0,00002551
C ⁶ M ⁶ Y ⁶	4,92067868	0,00216080
C ² M M ² Y Y ² C C ² Y M ² C Y ² M	4,66361251	0,00011400
C ⁵ M ⁵ Y ⁵	4,65401958	0,00312361
C ⁴ M ⁴ Y ⁴	4,64229437	0,00317458
C ⁷ M ⁷ Y ⁷	4,54188165	0,00364628
C ⁵ M ² Y C ⁵ MY ² C ² M ⁵ Y CM ⁵ Y ² C ² MY ⁵ CM ² Y ⁵	4,26933472	0,00030533
C ² M ² M ² Y ² C ² Y ²	4,01582537	0,00751658
C ⁴ M ² M ⁴ Y ² Y ⁴ C ² C ⁴ Y ² M ⁴ C ² Y ⁴ M ²	3,85265586	0,00085442
C ⁸ M ⁸ Y ⁸	3,43883730	0,01652403
C ³ M ³ M ³ Y ³ C ³ Y ³	3,37671314	0,01797857
C ⁵ MY CM ⁵ Y CMY ⁵	3,25589271	0,02117803
Odsječak	2,41302554	0,12074319
C ⁴ MY CM ⁴ Y CMY ⁴	2,31372770	0,07467701
C ³ M ² Y C ³ MY ² C ² M ³ Y CM ³ Y ² C ² MY ³ CM ² Y ³	2,30391729	0,03273045
C ³ M ² M ³ Y ² Y ³ C ² C ³ Y ² M ³ C ² Y ³ M ²	2,17631033	0,04333156
C ⁴ M ² Y C ⁴ MY ² C ² M ⁴ Y CM ⁴ Y ² C ² MY ⁴ CM ² Y ⁴	1,63931463	0,13338945
C ⁴ M ⁴ M ⁴ Y ⁴ C ⁴ Y ⁴	1,61661027	0,18407634
C ⁶ MY CM ⁶ Y CMY ⁶	0,66091064	0,57626362
C ⁴ M ³ M ⁴ Y ³ Y ⁴ C ³ C ⁴ Y ³ M ⁴ C ³ Y ⁴ M ³	0,20992049	0,97372363
C ³ M ² Y ² C ² M ³ Y ² C ² M ² Y ³	0,17310441	0,91459222
C ³ MY CM ³ Y CMY ³	0,02850650	0,99351091
C ⁵ M ³ M ⁵ Y ³ Y ⁵ C ³ C ⁵ Y ³ M ⁵ C ³ Y ⁵ M ³	- 0,25700007	1,00000000
C ² MY CM ² Y CMY ²	- 0,58751614	1,00000000
C ² M ² Y C ² MY ² CM ² Y ²	- 0,68567355	1,00000000

$C^2M^2Y^2$	- 1,03287853	1,00000000
CMY	- 3,61490093	1,00000000
Korak 4: eliminacija bloka CMY		
$C M Y$	41,22977496	0,00000000
$C^2M^2Y^2$	18,96432623	0,00001513
$C^6M^2 M^6Y^2 Y^6C^2 C^6Y^2 M^6C^2 Y^6M^2$	18,94377357	0,00000000
$C^3M^3Y^2 C^3M^2Y^3 C^2M^3Y^3$	12,93401369	0,00000003
$C^4M^2Y^2 C^2M^4Y^2 C^2M^2Y^4$	11,35235682	0,00000027
$C^5M^2 M^5Y^2 Y^5C^2 C^5Y^2 M^5C^2 Y^5M^2$	10,91168686	0,00000000
$C^4M^3Y C^4MY^3 C^3M^4Y CM^4Y^3 C^3MY^4 CM^3Y^4$	9,80263257	0,00000000
$CM MY CY$	8,64088659	0,00001208
$C^6M M^6Y Y^6C C^6Y M^6C Y^6M$	6,82105782	0,00000046
$C^7M M^7Y Y^7C C^7Y M^7C Y^7M$	6,77208842	0,00000052
$C^5M M^5Y Y^5C C^5Y M^5C Y^5M$	6,66882367	0,00000068
$C^2M^2Y C^2MY^2 CM^2Y^2$	5,55783769	0,00089312
$C^7 M^7 Y^7$	5,54015599	0,00091533
$C^6 M^6 Y^6$	5,46178938	0,00102057
$C^3M^2Y^2 C^2M^3Y^2 C^2M^2Y^3$	5,01686491	0,00189132
$C^3M M^3Y Y^3C C^3Y M^3C Y^3M$	4,81756430	0,00007738
$C^2M M^2Y Y^2C C^2Y M^2C Y^2M$	4,60249190	0,00013287
$C^8 M^8 Y^8$	4,30411054	0,00505884
$C^5 M^5 Y^5$	4,05247529	0,00714779
$C^2M^2 M^2Y^2 C^2Y^2$	3,96456086	0,00806326
$C^4M^2 M^4Y^2 Y^4C^2 C^4Y^2 M^4C^2 Y^4M^2$	3,81782250	0,00093042
$C^3 M^3 Y^3$	3,57485217	0,01373211
$C^3M^3 M^3Y^3 C^3Y^3$	3,52649885	0,01466656
Odsječak	3,19915936	0,07407121
$C^5M^2Y C^5MY^2 C^2M^5Y CM^5Y^2 C^2MY^5 CM^2Y^5$	3,15513018	0,00460861
$C^5MY CM^5Y CMY^5$	3,07468960	0,02705305
$C^2MY CM^2Y CMY^2$	2,98521950	0,03051846
$C^4 M^4 Y^4$	2,95085884	0,03196213
$C^4MY CM^4Y CMY^4$	2,41328208	0,06548135
$C^3M^2 M^3Y^2 Y^3C^2 C^3Y^2 M^3C^2 Y^3M^2$	2,15616119	0,04527457
$C^4M^4 M^4Y^4 C^4Y^4$	1,62775172	0,18149599
$C^3M^2Y C^3MY^2 C^2M^3Y CM^3Y^2 C^2MY^3 CM^2Y^3$	1,61437348	0,14015854
$C^4M^2Y C^4MY^2 C^2M^4Y CM^4Y^2 C^2MY^4 CM^2Y^4$	0,84942847	0,53195008
$C^3MY CM^3Y CMY^3$	0,64906193	0,58369337
$C^6MY CM^6Y CMY^6$	0,56692868	0,63693184
$C^4M^3 M^4Y^3 Y^4C^3 C^4Y^3 M^4C^3 Y^4M^3$	0,35915842	0,90465454
$C^5M^3 M^5Y^3 Y^5C^3 C^5Y^3 M^5C^3 Y^5M^3$	- 0,09798575	1,00000000
Korak 5: eliminacija bloka $C^5M^3 M^5Y^3 Y^5C^3 C^5Y^3 M^5C^3 Y^5M^3$		
$C M Y$	39,68319319	0,00000000
$C^2M^2Y^2$	20,29702465	0,00000766

$C^5M^2 M^5Y^2 Y^5C^2 C^5Y^2 M^5C^2 Y^5M^2$	15,93054915	0,00000000
$C^6M^2 M^6Y^2 Y^6C^2 C^6Y^2 M^6C^2 Y^6M^2$	15,23899160	0,00000000
$C^3M^3Y^2 C^3M^2Y^3 C^2M^3Y^3$	14,24252929	0,00000000
$C^4M^2 M^4Y^2 Y^4C^2 C^4Y^2 M^4C^2 Y^4M^2$	14,17825017	0,00000000
$C^4M^2Y^2 C^2M^4Y^2 C^2M^2Y^4$	12,54873593	0,00000005
$C^4M^3Y C^4MY^3 C^3M^4Y CM^4Y^3 C^3MY^4 CM^3Y^4$	10,12503010	0,00000000
$CM MY CY$	8,93193275	0,00000802
$C^2M^2 M^2Y^2 C^2Y^2$	8,65432238	0,00001183
$C^5M M^5Y Y^5C C^5Y M^5C Y^5M$	8,42990990	0,00000001
$C^6M M^6Y Y^6C C^6Y M^6C Y^6M$	8,17344595	0,00000001
$C^3M^2 M^3Y^2 Y^3C^2 C^3Y^2 M^3C^2 Y^3M^2$	7,67204370	0,00000005
$C^7M M^7Y Y^7C C^7Y M^7C Y^7M$	7,66978454	0,00000005
$C^3M M^3Y Y^3C C^3Y M^3C Y^3M$	6,17948812	0,00000240
$C^4M^3 M^4Y^3 Y^4C^3 C^4Y^3 M^4C^3 Y^4M^3$	5,74681955	0,00000729
$C^2M^2Y C^2MY^2 CM^2Y^2$	5,66624042	0,00076774
$C^3M^2Y^2 C^2M^3Y^2 C^2M^2Y^3$	5,22024103	0,00142614
$C^2M M^2Y Y^2C C^2Y M^2C Y^2M$	5,13666940	0,00003449
$C^7 M^7 Y^7$	4,35264381	0,00473031
$C^8 M^8 Y^8$	4,05938398	0,00707815
$C^5M^2Y C^5MY^2 C^2M^5Y CM^5Y^2 C^2MY^5 CM^2Y^5$	3,64471117	0,00141859
$C^6 M^6 Y^6$	3,50730114	0,01505128
$C^3M^3 M^3Y^3 C^3Y^3$	3,32076548	0,01939148
$C^2MY CM^2Y CMY^2$	3,16662827	0,02389087
$C^5MY CM^5Y CMY^5$	2,68408474	0,04568771
$C^4M^4 M^4Y^4 C^4Y^4$	2,47688543	0,06018683
$C^4MY CM^4Y CMY^4$	2,09389467	0,09960992
$C^5 M^5 Y^5$	1,81196484	0,14348093
$C^3M^2Y C^3MY^2 C^2M^3Y CM^3Y^2 C^2MY^3 CM^2Y^3$	1,04389209	0,39532344
$C^3 M^3 Y^3$	0,86692513	0,45782544
$C^6MY CM^6Y CMY^6$	0,79094876	0,49910454
$Odsječak$	0,71128370	0,39927922
$C^4 M^4 Y^4$	0,60225165	0,61367100
$C^3MY CM^3Y CMY^3$	0,42252788	0,73689705
$C^4M^2Y C^4MY^2 C^2M^4Y CM^4Y^2 C^2MY^4 CM^2Y^4$	0,39309023	0,88368384
Korak 6: eliminacija bloka $C^4M^2Y C^4MY^2 C^2M^4Y CM^4Y^2 C^2MY^4 CM^2Y^4$		
$C M Y$	48,80296217	0,00000000
$C^5M^2Y C^5MY^2 C^2M^5Y CM^5Y^2 C^2MY^5 CM^2Y^5$	16,86412906	0,00000000
$C^5M^2 M^5Y^2 Y^5C^2 C^5Y^2 M^5C^2 Y^5M^2$	16,59464738	0,00000000
$C^4M^2Y^2 C^2M^4Y^2 C^2M^2Y^4$	15,88730770	0,00000000
$C^6M^2 M^6Y^2 Y^6C^2 C^6Y^2 M^6C^2 Y^6M^2$	15,87099235	0,00000000
$C^2MY CM^2Y CMY^2$	15,66820087	0,00000000
$C^4M^2 M^4Y^2 Y^4C^2 C^4Y^2 M^4C^2 Y^4M^2$	15,20261166	0,00000000
$C^3M^3Y^2 C^3M^2Y^3 C^2M^3Y^3$	14,61247886	0,00000000

C ² M ² Y ²	14,55911138	0,00014661
C ³ M ² Y C ³ MY ² C ² M ³ Y CM ³ Y ² C ² MY ³ CM ² Y ³	12,07436009	0,00000000
C ⁴ M ³ Y C ⁴ MY ³ C ³ M ⁴ Y CM ⁴ Y ³ C ³ MY ⁴ CM ³ Y ⁴	12,04198434	0,00000000
C ² M M ² Y Y ² C C ² Y M ² C Y ² M	10,32570731	0,00000000
C ³ M M ³ Y Y ³ C C ³ Y M ³ C Y ³ M	10,21587461	0,00000000
C ⁵ M M ⁵ Y Y ⁵ C C ⁵ Y M ⁵ C Y ⁵ M	9,29289851	0,00000000
C ³ M ² M ³ Y ² Y ³ C ² C ³ Y ² M ³ C ² Y ³ M ²	8,65205810	0,00000000
C ⁶ M M ⁶ Y Y ⁶ C C ⁶ Y M ⁶ C Y ⁶ M	8,49848684	0,00000001
CM MY CY	7,90776525	0,00003359
C ⁷ M M ⁷ Y Y ⁷ C C ⁷ Y M ⁷ C Y ⁷ M	7,70204347	0,00000005
C ² M ² M ² Y ² C ² Y ²	7,58553439	0,00005271
C ⁴ M ³ M ⁴ Y ³ Y ⁴ C ³ C ⁴ Y ³ M ⁴ C ³ Y ⁴ M ³	6,89230736	0,00000038
C ² M ² Y C ² MY ² CM ² Y ²	5,25495559	0,00135838
C ⁷ M ⁷ Y ⁷	4,19630484	0,00586313
C ⁴ MY CM ⁴ Y CMY ⁴	4,10038820	0,00668877
C ⁶ M ⁶ Y ⁶	3,79021660	0,01023027
C ⁸ M ⁸ Y ⁸	3,76337029	0,01061261
C ³ MY CM ³ Y CMY ³	3,59572914	0,01334066
C ³ M ³ M ³ Y ³ C ³ Y ³	3,35782972	0,01843692
C ³ M ² Y ² C ² M ³ Y ² C ² M ² Y ³	2,87663377	0,03530276
C ³ M ³ Y ³	2,86594396	0,03581285
C ⁵ M ⁵ Y ⁵	2,72785358	0,04308789
C ⁵ MY CM ⁵ Y CMY ⁵	2,66171529	0,04706607
C ⁴ M ⁴ M ⁴ Y ⁴ C ⁴ Y ⁴	2,47239836	0,06053952
C ⁴ M ⁴ Y ⁴	2,07664154	0,10186873
Odsječak	0,98812774	0,32050946
C ⁶ MY CM ⁶ Y CMY ⁶	- 0,04901425	1,00000000

Korak 7: eliminacija bloka C⁶MY CM⁶Y CMY⁶

C M Y	46,05440402	0,00000000
C ⁴ MY CM ⁴ Y CMY ⁴	32,74123564	0,00000000
C ⁵ MY CM ⁵ Y CMY ⁵	27,78352781	0,00000000
C ³ MY CM ³ Y CMY ³	25,48504756	0,00000000
C ² MY CM ² Y CMY ²	19,79366559	0,00000000
C ⁵ M ² Y C ⁵ MY ² C ² M ⁵ Y CM ⁵ Y ² C ² MY ⁵ CM ² Y ⁵	16,95345836	0,00000000
C ⁴ M ² Y ² C ² M ⁴ Y ² C ² M ² Y ⁴	15,96144244	0,00000000
C ⁵ M ² M ⁵ Y ² Y ⁵ C ² C ⁵ Y ² M ⁵ C ² Y ⁵ M ²	15,78480270	0,00000000
C ³ M ³ Y ² C ³ M ² Y ³ C ² M ³ Y ³	15,38439188	0,00000000
C ⁶ M ² M ⁶ Y ² Y ⁶ C ² C ⁶ Y ² M ⁶ C ² Y ⁶ M ²	15,10418837	0,00000000
C ⁴ M ² M ⁴ Y ² Y ⁴ C ² C ⁴ Y ² M ⁴ C ² Y ⁴ M ²	14,31165446	0,00000000
C ⁴ M ³ Y C ⁴ MY ³ C ³ M ⁴ Y CM ⁴ Y ³ C ³ MY ⁴ CM ³ Y ⁴	12,60807175	0,00000000
C ³ M ² Y C ³ MY ² C ² M ³ Y CM ³ Y ² C ² MY ³ CM ² Y ³	11,22367004	0,00000000
C ² M ² Y ²	10,83528533	0,00104058
C ⁵ M M ⁵ Y Y ⁵ C C ⁵ Y M ⁵ C Y ⁵ M	9,21692451	0,00000000

C ³ M M ³ Y Y ³ C C ³ Y M ³ C Y ³ M	8,84045225	0,00000000
C ⁶ M M ⁶ Y Y ⁶ C C ⁶ Y M ⁶ C Y ⁶ M	8,80873461	0,00000000
C ² M M ² Y Y ² C C ² Y M ² C Y ² M	8,45450233	0,00000001
C ⁷ M M ⁷ Y Y ⁷ C C ⁷ Y M ⁷ C Y ⁷ M	8,38561020	0,00000001
C ³ M ² M ³ Y ² Y ³ C ² C ³ Y ² M ³ C ² Y ³ M ²	8,17294749	0,00000001
C ² M ² M ² Y ² C ² Y ²	6,92084051	0,00013341
CM MY CY	6,82312327	0,00015292
C ⁴ M ³ M ⁴ Y ³ Y ⁴ C ³ C ⁴ Y ³ M ⁴ C ³ Y ⁴ M ³	6,60940250	0,00000079
C ⁷ M ⁷ Y ⁷	3,98241445	0,00786254
C ⁸ M ⁸ Y ⁸	3,93489637	0,00839155
C ² M ² Y C ² MY ² CM ² Y ²	3,60739610	0,01312864
C ³ M ³ M ³ Y ³ C ³ Y ³	3,51844775	0,01481968
C ⁶ M ⁶ Y ⁶	3,19327484	0,02303920
C ⁴ M ⁴ M ⁴ Y ⁴ C ⁴ Y ⁴	2,56199326	0,05374772
C ³ M ³ Y ³	2,16219565	0,09109598
C ⁵ M ⁵ Y ⁵	1,85446767	0,13584108
C ³ M ² Y ² C ² M ³ Y ² C ² M ² Y ³	1,79454292	0,14671315
Odsječak	1,32231597	0,25052882
C ⁴ M ⁴ Y ⁴	1,15785886	0,32492416
Korak 8: eliminacija bloka C ⁴ M ⁴ Y ⁴		

Tabela A.3, Odstupanje reduciranih modela od empirijskih podataka, proces A

	N - broj polja	dEab	Min	Medijan	Maks	Int. pouz. 95%
RGB->D	918	1,45	0,05	1,28	5,37	0,10

Reducirani model:

1 C M Y CM MY CY C²M M²Y Y²C C²Y M²C Y²M C³ M³ Y³ C²MY
 CM²Y CMY² C²M² M²Y² C²Y² C³M M³Y Y³C C³Y M³C Y³M C²M²Y C²MY²
 CM²Y² C³MY C³Y CMY³ C³M² M³Y² Y³C² C³Y² M³C² Y³M² C⁵ M⁵ Y⁵ C²M²Y²
 C³M²Y C³MY² C²M³Y C³Y² C²MY³ CM²Y³ C⁴MY CM⁴Y CMY⁴ C³M³ M³Y³ C³Y³
 C⁴M² M⁴Y² Y⁴C² C⁴Y² M⁴C² Y⁴M² C⁵M M⁵Y Y⁵C C⁵Y M⁵C Y⁵M C⁶ M⁶ Y⁶
 C³M²Y² C²M³Y² C²M²Y³ C⁵MY CM⁵Y CMY⁵ C⁴M³ M⁴Y³ Y⁴C³ C⁴Y³ M⁴C³ Y⁴M³
 C⁵M² M⁵Y² Y⁵C² C⁵Y² M⁵C² Y⁵M² C⁶M M⁶Y Y⁶C C⁶Y M⁶C Y⁶M C⁷ M⁷ Y⁷
 C³M³Y² C³M²Y³ C²M³Y³ C⁴M²Y² C²M⁴Y² C²M²Y⁴ C⁴M³Y C⁴MY³ C³M⁴Y CM⁴Y³ C³MY⁴
 CM³Y⁴ C⁵M²Y C⁵MY² C²M⁵Y CM⁵Y² C²MY⁵ CM²Y⁵ C⁴M⁴ M⁴Y⁴ C⁴Y⁴ C⁶M² M⁶Y²
 Y⁶C² C⁶Y² M⁶C² Y⁶M² C⁷M M⁷Y Y⁷C C⁷Y M⁷C Y⁷M C⁸ M⁸ Y⁸

Proces B

Tabela A.4, Odstupanje maksimalnog modela od empirijskih podataka, proces B

	N - broj polja	dEab	Min	Medijan	Maks	Int. pouz. 95%
RGB->D	918	1,71	0,12	1,51	5,66	0,12

Tabela A.5, Postupak eliminacije skupina članova, proces B

Korak 1		
Blok članova	Fp	p
C ⁴ M ² Y ² C ² M ⁴ Y ² C ² M ² Y ⁴	17,63281594	0,00000000
C ⁴ M ⁴ M ⁴ Y ⁴ C ⁴ Y ⁴	12,10830315	0,00000010
C ⁴ M ³ Y C ⁴ MY ³ C ³ M ⁴ Y CM ⁴ Y ³ C ³ MY ⁴ CM ³ Y ⁴	11,89961222	0,00000000
C ³ M ³ Y ² C ³ M ² Y ³ C ² M ³ Y ³	10,59851978	0,00000078
C M Y	9,84197272	0,00000226
C ⁵ M ³ M ⁵ Y ³ Y ⁵ C ³ C ⁵ Y ³ M ⁵ C ³ Y ⁵ M ³	8,48434051	0,00000001
C ³ M ² Y ² C ² M ³ Y ² C ² M ² Y ³	4,78225370	0,00261839
C ⁵ M ² Y C ⁵ MY ² C ² M ⁵ Y CM ⁵ Y ² C ² MY ⁵ CM ² Y ⁵	4,06700381	0,00050490
C ⁵ MY CM ⁵ Y CMY ⁵	3,25926480	0,02108788
C ⁴ MY CM ⁴ Y CMY ⁴	2,84214593	0,03699427
C ² M ² Y ²	2,72538588	0,04325128
CMY	2,69108896	0,10132679
C ² M ² Y ²	1,75459144	0,18570083
C ⁶ MY CM ⁶ Y CMY ⁶	1,48017359	0,21857800
Odsječak	1,44522760	0,22967168
C ² M ² Y C ² MY ² CM ² Y ²	1,20197212	0,30805709
C ³ MY CM ³ Y CMY ³	1,05322130	0,36831524
C ³ M ³ M ³ Y ³ C ³ Y ³	0,85020086	0,46668021
C ³ M ² M ³ Y ² Y ³ C ² C ³ Y ² M ³ C ² Y ³ M ²	0,41319971	0,87051203
C ³ M ² Y C ³ MY ² C ² M ³ Y CM ³ Y ² C ² MY ³ CM ² Y ³	0,07776234	0,99821003
C ² MY CM ² Y CMY ²	- 0,05447539	1,00000000
C ⁴ M ³ M ⁴ Y ³ Y ⁴ C ³ C ⁴ Y ³ M ⁴ C ³ Y ⁴ M ³	- 0,12314902	1,00000000
C ² M ² M ² Y ² C ² Y ²	- 0,44021770	1,00000000
C ⁴ M ² Y C ⁴ MY ² C ² M ⁴ Y CM ⁴ Y ² C ² MY ⁴ CM ² Y ⁴	- 0,72686652	1,00000000
C ³ M ³ Y ³	- 1,00913652	1,00000000
C ⁴ M ² M ⁴ Y ² Y ⁴ C ² C ⁴ Y ² M ⁴ C ² Y ⁴ M ²	- 1,72601741	1,00000000
C ² M M ² Y Y ² C C ² Y M ² C Y ² M	- 3,34212389	1,00000000
CM MY CY	- 3,54972530	1,00000000
C ⁵ M ² M ⁵ Y ² Y ⁵ C ² C ⁵ Y ² M ⁵ C ² Y ⁵ M ²	- 5,00152759	1,00000000
C ⁶ M ² M ⁶ Y ² Y ⁶ C ² C ⁶ Y ² M ⁶ C ² Y ⁶ M ²	- 5,24967101	1,00000000
C ⁴ M ⁴ Y ⁴	- 7,24825869	1,00000000
C ³ M M ³ Y Y ³ C C ³ Y M ³ C Y ³ M	- 9,41506989	1,00000000

$C^7M M^7Y Y^7C C^7Y M^7C Y^7M$	- 11,65822402	1,00000000
$C^5 M^5 Y^5$	- 12,44187825	1,00000000
$C^4M M^4Y Y^4C C^4Y M^4C Y^4M$	- 13,22027576	1,00000000
$C^6M M^6Y Y^6C C^6Y M^6C Y^6M$	- 13,95774125	1,00000000
$C^5M M^5Y Y^5C C^5Y M^5C Y^5M$	- 14,58277179	1,00000000
$C^6 M^6 Y^6$	- 16,09069247	1,00000000
$C^7 M^7 Y^7$	- 18,36752383	1,00000000
$C^8 M^8 Y^8$	- 19,57538176	1,00000000

Korak 2: eliminacija bloka $C^8 M^8 Y^8$

$C^4M^4 M^4Y^4 C^4Y^4$	16,29952546	0,00000000
$C^4M^3Y C^4MY^3 C^3M^4Y CM^4Y^3 C^3MY^4 CM^3Y^4$	12,57758723	0,00000000
$C^3M^3Y^2 C^3M^2Y^3 C^2M^3Y^3$	9,61410530	0,00000310
$C^5M^3 M^5Y^3 Y^5C^3 C^5Y^3 M^5C^3 Y^5M^3$	7,63007702	0,00000006
$C^4M^2Y^2 C^2M^4Y^2 C^2M^2Y^4$	5,44269636	0,00104871
CMY	4,67254285	0,03096047
$C^6M^2 M^6Y^2 Y^6C^2 C^6Y^2 M^6C^2 Y^6M^2$	3,63732974	0,00144679
$C^3M^2Y^2 C^2M^3Y^2 C^2M^2Y^3$	2,80264213	0,03900219
$C^5M^2Y C^5MY^2 C^2M^5Y CM^5Y^2 C^2MY^5 CM^2Y^5$	2,35105871	0,02948452
$CM MY CY$	2,33809328	0,07232417
$C^5M^2 M^5Y^2 Y^5C^2 C^5Y^2 M^5C^2 Y^5M^2$	1,43925705	0,19676763
Odsječak	1,20291566	0,27308756
$C^4M^3 M^4Y^3 Y^4C^3 C^4Y^3 M^4C^3 Y^4M^3$	0,67233441	0,67208706
$C^3M^3 M^3Y^3 C^3Y^3$	0,41138052	0,74487348
$C^2M M^2Y Y^2C C^2Y M^2C Y^2M$	0,30023476	0,93681249
$C^2M^2Y^2$	0,06923872	0,79251986
$C^4M^2 M^4Y^2 Y^4C^2 C^4Y^2 M^4C^2 Y^4M^2$	0,06779398	0,99878716
$C^2M^2 M^2Y^2 C^2Y^2$	0,05941118	0,98100936
$C^2MY CM^2Y CMY^2$	0,03742431	0,99031672
$C^3M^2 M^3Y^2 Y^3C^2 C^3Y^2 M^3C^2 Y^3M^2$	- 0,10900558	1,00000000
$C^3M^2Y C^3MY^2 C^2M^3Y CM^3Y^2 C^2MY^3 CM^2Y^3$	- 0,20787288	1,00000000
$CM Y$	- 0,28666950	1,00000000
$C^2M^2Y C^2MY^2 CM^2Y^2$	- 0,38558352	1,00000000
$C^3MY CM^3Y CMY^3$	- 0,87860740	1,00000000
$C^3M M^3Y Y^3C C^3Y M^3C Y^3M$	- 0,96640850	1,00000000
$C^4M^2Y C^4MY^2 C^2M^4Y CM^4Y^2 C^2MY^4 CM^2Y^4$	- 1,11891240	1,00000000
$C^4MY CM^4Y CMY^4$	- 2,22563372	1,00000000
$C^4M M^4Y Y^4C C^4Y M^4C Y^4M$	- 3,04749066	1,00000000
$C^6MY CM^6Y CMY^6$	- 3,12250495	1,00000000
$C^5MY CM^5Y CMY^5$	- 3,47113641	1,00000000
$C^2 M^2 Y^2$	- 4,08986724	1,00000000
$C^7 M^7 Y^7$	- 4,27584679	1,00000000
$C^5M M^5Y Y^5C C^5Y M^5C Y^5M$	- 4,37119126	1,00000000
$C^7M M^7Y Y^7C C^7Y M^7C Y^7M$	- 4,38380620	1,00000000

$C^6 M^6 Y^6$	- 4,51227687	1,00000000
$C^5 M^5 Y^5$	- 4,66249253	1,00000000
$C^6 M M^6 Y Y^6 C C^6 Y M^6 C Y^6 M$	- 4,73573239	1,00000000
$C^3 M^3 Y^3$	- 4,74706836	1,00000000
$C^4 M^4 Y^4$	- 4,75463492	1,00000000

Korak 3: eliminacija bloka $C^4 M^4 Y^4$

$C^4 M^4 M^4 Y^4 C^4 Y^4$	17,30147778	0,00000000
$C^4 M^3 Y C^4 M Y^3 C^3 M^4 Y C M^4 Y^3 C^3 M Y^4 C M^3 Y^4$	12,00120953	0,00000000
$C^3 M^3 Y^2 C^3 M^2 Y^3 C^2 M^3 Y^3$	9,52274362	0,00000352
$C^5 M^3 M^5 Y^3 Y^5 C^3 C^5 Y^3 M^5 C^3 Y^5 M^3$	8,68653431	0,00000000
$C M Y$	5,17071224	0,00152885
$C^4 M^2 Y^2 C^2 M^4 Y^2 C^2 M^2 Y^4$	3,82603125	0,00974852
$C^6 M^2 M^6 Y^2 Y^6 C^2 C^6 Y^2 M^6 C^2 Y^6 M^2$	2,91743335	0,00807346
$C^5 M^2 Y C^5 M Y^2 C^2 M^5 Y C M^5 Y^2 C^2 M Y^5 C M^2 Y^5$	2,79693537	0,01068907
$C^3 M^2 Y^2 C^2 M^3 Y^2 C^2 M^2 Y^3$	2,16809988	0,09041717
Odsječak	2,10069158	0,14764394
CM MY CY	1,83853927	0,13867728
$C^7 M^7 Y^7$	1,49684732	0,21405450
$C^4 M Y C M^4 Y C M Y^4$	1,22402519	0,29990387
$C^4 M^3 M^4 Y^3 Y^4 C^3 C^4 Y^3 M^4 C^3 Y^4 M^3$	1,11498020	0,35164056
$C^3 M Y C M^3 Y C M Y^3$	0,94358980	0,41901302
$C^6 M^6 Y^6$	0,88030128	0,45085505
$C^5 M Y C M^5 Y C M Y^5$	0,87537046	0,45341673
$C^2 M M^2 Y Y^2 C C^2 Y M^2 C Y^2 M$	0,63332025	0,70366444
CMY	0,61039759	0,43488081
$C^5 M^2 M^5 Y^2 Y^5 C^2 C^5 Y^2 M^5 C^2 Y^5 M^2$	0,57966408	0,74673925
$C^5 M^5 Y^5$	0,41838855	0,73985612
$C^2 M^2 Y^2$	0,33092725	0,56528342
$C^2 M^2 Y^2$	0,27452194	0,84379970
$C^6 M Y C M^6 Y C M Y^6$	0,27035892	0,84679182
$C^2 M^2 M^2 Y^2 C^2 Y^2$	0,17824729	0,91115870
$C^3 M^3 Y^3$	0,14970068	0,92988778
$C^3 M^2 M^3 Y^2 Y^3 C^2 C^3 Y^2 M^3 C^2 Y^3 M^2$	0,14658040	0,98971523
$C^3 M^3 M^3 Y^3 C^3 Y^3$	0,13101158	0,94164544
$C^4 M^2 M^4 Y^2 Y^4 C^2 C^4 Y^2 M^4 C^2 Y^4 M^2$	- 0,04112647	1,00000000
$C^2 M Y C M^2 Y C M Y^2$	- 0,28275122	1,00000000
$C^3 M M^3 Y Y^3 C C^3 Y M^3 C Y^3 M$	- 0,46575322	1,00000000
$C^3 M^2 Y C^3 M Y^2 C^2 M^3 Y C M^3 Y^2 C^2 M Y^3 C M^2 Y^3$	- 0,81478126	1,00000000
$C^4 M^2 Y C^4 M Y^2 C^2 M^4 Y C M^4 Y^2 C^2 M Y^4 C M^2 Y^4$	- 1,30628122	1,00000000
$C^2 M^2 Y C^2 M Y^2 C M^2 Y^2$	- 1,33930677	1,00000000
$C^4 M M^4 Y Y^4 C C^4 Y M^4 C Y^4 M$	- 2,00233217	1,00000000
$C^7 M M^7 Y Y^7 C C^7 Y M^7 C Y^7 M$	- 2,63594195	1,00000000
$C^5 M M^5 Y Y^5 C C^5 Y M^5 C Y^5 M$	- 2,75236762	1,00000000

$C^6M M^6Y Y^6C C^6Y M^6C Y^6M$	- 3,15509073	1,00000000
Korak 4: eliminacija bloka $C^6M M^6Y Y^6C C^6Y M^6C Y^6M$		
$C^4M^4 M^4Y^4 C^4Y^4$	18,02390439	0,00000000
$C^5M^3 M^5Y^3 Y^5C^3 C^5Y^3 M^5C^3 Y^5M^3$	7,70579985	0,00000005
$C^4M^3Y C^4MY^3 C^3M^4Y CM^4Y^3 C^3MY^4 CM^3Y^4$	7,61011191	0,00000006
$C M Y$	7,59646820	0,00005201
$C^3M^3Y^2 C^3M^2Y^3 C^2M^3Y^3$	5,88289733	0,00056824
$C^5M^2Y C^5MY^2 C^2M^5Y CM^5Y^2 C^2MY^5 CM^2Y^5$	5,03727687	0,00004441
$C^7 M^7 Y^7$	3,75056758	0,01080460
$C^4M^2Y^2 C^2M^4Y^2 C^2M^2Y^4$	3,25790029	0,02111847
$C^6M^2 M^6Y^2 Y^6C^2 C^6Y^2 M^6C^2 Y^6M^2$	3,20355447	0,00410655
$C^6 M^6 Y^6$	3,12738849	0,02519452
$C^5MY CM^5Y CMY^5$	2,92672421	0,03301429
$C^4MY CM^4Y CMY^4$	2,90013499	0,03421479
$C^5 M^5 Y^5$	2,59682580	0,05132683
Odsječak	2,00856313	0,15681894
$C^7M M^7Y Y^7C C^7Y M^7C Y^7M$	1,58711471	0,14789988
$C^3M^3 M^3Y^3 C^3Y^3$	1,58386862	0,19185221
$C^3 M^3 Y^3$	1,55322007	0,19941213
$C^5M^2 M^5Y^2 Y^5C^2 C^5Y^2 M^5C^2 Y^5M^2$	1,42305382	0,20285708
$C^6MY CM^6Y CMY^6$	1,39885500	0,24187984
$C^3MY CM^3Y CMY^3$	1,35639504	0,25494341
$C^2M M^2Y Y^2C C^2Y M^2C Y^2M$	1,25143518	0,27776617
$C^3M^2Y^2 C^2M^3Y^2 C^2M^2Y^3$	1,20591449	0,30657420
$C^4M M^4Y Y^4C C^4Y M^4C Y^4M$	1,03157794	0,40325678
$C^3M M^3Y Y^3C C^3Y M^3C Y^3M$	0,96603870	0,44718072
$C^5M M^5Y Y^5C C^5Y M^5C Y^5M$	0,95313670	0,45616003
$C^2 M^2 Y^2$	0,81112793	0,48786843
$C^4M^3 M^4Y^3 Y^4C^3 C^4Y^3 M^4C^3 Y^4M^3$	0,74240949	0,61559816
$C^3M^2 M^3Y^2 Y^3C^2 C^3Y^2 M^3C^2 Y^3M^2$	0,56907610	0,75514296
$C^4M^2 M^4Y^2 Y^4C^2 C^4Y^2 M^4C^2 Y^4M^2$	0,43175790	0,85792748
$CM MY CY$	0,24174378	0,86722324
$C^2M^2Y^2$	0,19024331	0,66283677
$C^2M^2 M^2Y^2 C^2Y^2$	0,07789989	0,97195398
CMY	- 0,42745108	1,00000000
$C^4M^2Y C^4MY^2 C^2M^4Y CM^4Y^2 C^2MY^4 CM^2Y^4$	- 0,51252922	1,00000000
$C^2MY CM^2Y CMY^2$	- 0,53641342	1,00000000
$C^3M^2Y C^3MY^2 C^2M^3Y CM^3Y^2 C^2MY^3 CM^2Y^3$	- 0,74360832	1,00000000
$C^2M^2Y C^2MY^2 CM^2Y^2$	- 1,12691221	1,00000000
Korak 5: eliminacija bloka $C^2M^2Y C^2MY^2 CM^2Y^2$		
$C^4M^4 M^4Y^4 C^4Y^4$	18,35032496	0,00000000
$C^4M^3Y C^4MY^3 C^3M^4Y CM^4Y^3 C^3MY^4 CM^3Y^4$	8,32337415	0,00000001
$C M Y$	7,98981697	0,00002999

$C^5M^3 M^5Y^3 Y^5C^3 C^5Y^3 M^5C^3 Y^5M^3$	7,62770831	0,00000006
$C^3M^3Y^2 C^3M^2Y^3 C^2M^3Y^3$	7,42866260	0,00006573
$C^4M^2Y^2 C^2M^4Y^2 C^2M^2Y^4$	6,67915712	0,00018724
$C^5M^2Y C^5MY^2 C^2M^5Y CM^5Y^2 C^2MY^5 CM^2Y^5$	6,24893146	0,00000201
$C^6M^2 M^6Y^2 Y^6C^2 C^6Y^2 M^6C^2 Y^6M^2$	3,97177283	0,00063696
$C^7 M^7 Y^7$	3,76399139	0,01060686
$C^6 M^6 Y^6$	3,10696050	0,02589670
$C^4MY CM^4Y CMY^4$	2,96424682	0,03138767
$C^5MY CM^5Y CMY^5$	2,68192762	0,04582041
$C^5 M^5 Y^5$	2,53879812	0,05544072
$C^3M^2Y^2 C^2M^3Y^2 C^2M^2Y^3$	2,48737080	0,05935700
$C^3M^3 M^3Y^3 C^3Y^3$	1,89058500	0,12967562
Odsječak	1,85862453	0,17318160
$C^3MY CM^3Y CMY^3$	1,82820219	0,14052085
$C^7M M^7Y Y^7C C^7Y M^7C Y^7M$	1,75312272	0,10603362
$C^5M^2 M^5Y^2 Y^5C^2 C^5Y^2 M^5C^2 Y^5M^2$	1,72333626	0,11265498
$C^3M^2Y C^3MY^2 C^2M^3Y CM^3Y^2 C^2MY^3 CM^2Y^3$	1,68669607	0,12130828
$C^2M^2Y^2$	1,65987629	0,19800652
$C^3 M^3 Y^3$	1,49603573	0,21426160
$C^6MY CM^6Y CMY^6$	1,44831558	0,22743569
$C^2M M^2Y Y^2C C^2Y M^2C Y^2M$	1,20597579	0,30091294
$C^4M M^4Y Y^4C C^4Y M^4C Y^4M$	1,03424064	0,40152987
$C^5M M^5Y Y^5C C^5Y M^5C Y^5M$	1,00908695	0,41800207
$C^3M M^3Y Y^3C C^3Y M^3C Y^3M$	0,92443042	0,47651015
$C^2 M^2 Y^2$	0,91538370	0,43296118
$C^4M^2Y C^4MY^2 C^2M^4Y CM^4Y^2 C^2MY^4 CM^2Y^4$	0,90919959	0,48751188
$C^4M^3 M^4Y^3 Y^4C^3 C^4Y^3 M^4C^3 Y^4M^3$	0,76373381	0,59860283
$C^3M^2 M^3Y^2 Y^3C^2 C^3Y^2 M^3C^2 Y^3M^2$	0,56744213	0,75643647
$C^4M^2 M^4Y^2 Y^4C^2 C^4Y^2 M^4C^2 Y^4M^2$	0,43672266	0,85449411
$C^2MY CM^2Y CMY^2$	0,42380236	0,73598701
CMY	0,11265672	0,73723085
$C^2M^2 M^2Y^2 C^2Y^2$	0,01774056	0,99678321
CM MY CY	- 0,33008244	1,00000000

Korak 6: eliminacija bloka CM MY CY

$C^4M^4 M^4Y^4 C^4Y^4$	22,42485744	0,00000000
$C^5M^3 M^5Y^3 Y^5C^3 C^5Y^3 M^5C^3 Y^5M^3$	11,95744716	0,00000000
$C M Y$	11,52820969	0,00000021
$C^4M^3Y C^4MY^3 C^3M^4Y CM^4Y^3 C^3MY^4 CM^3Y^4$	9,05884225	0,00000000
$C^3M^3Y^2 C^3M^2Y^3 C^2M^3Y^3$	7,65830577	0,00004765
$C^4M^2Y^2 C^2M^4Y^2 C^2M^2Y^4$	5,91389144	0,00054388
$C^5M^2Y C^5MY^2 C^2M^5Y CM^5Y^2 C^2MY^5 CM^2Y^5$	5,81080171	0,00000618
$C^7 M^7 Y^7$	4,80281243	0,00254160
$C^6M^2 M^6Y^2 Y^6C^2 C^6Y^2 M^6C^2 Y^6M^2$	4,49174254	0,00017503

C ³ M ³ M ³ Y ³ C ³ Y ³	4,38230874	0,00454045
C ⁶ M ⁶ Y ⁶	4,20480043	0,00579635
C ⁵ M ⁵ Y ⁵	3,63779566	0,01259916
C ⁵ MY CM ⁵ Y CMY ⁵	3,18380220	0,02334119
C ⁴ MY CM ⁴ Y CMY ⁴	3,15971138	0,02411379
C ⁵ M ² M ⁵ Y ² Y ⁵ C ² C ⁵ Y ² M ⁵ C ² Y ⁵ M ²	2,90252181	0,00835221
C ⁷ M M ⁷ Y Y ⁷ C C ⁷ Y M ⁷ C Y ⁷ M	2,45851593	0,02316115
C ⁴ M ² M ⁴ Y ² Y ⁴ C ² C ⁴ Y ² M ⁴ C ² Y ⁴ M ²	2,37728710	0,02779039
C ³ M ³ Y ³	2,25056116	0,08113667
C ⁴ M M ⁴ Y Y ⁴ C C ⁴ Y M ⁴ C Y ⁴ M	2,14786172	0,04608638
C ³ M M ³ Y Y ³ C C ³ Y M ³ C Y ³ M	2,09166727	0,05205093
C ² M ² M ² Y ² C ² Y ²	2,08868978	0,10028597
C ² M ² Y ²	2,08477089	0,14917918
C ³ M ² Y C ³ MY ² C ² M ³ Y CM ³ Y ² C ² MY ³ CM ² Y ³	1,96144510	0,06875476
C ⁵ M M ⁵ Y Y ⁵ C C ⁵ Y M ⁵ C Y ⁵ M	1,90618989	0,07724365
C ⁶ MY CM ⁶ Y CMY ⁶	1,89979166	0,12814054
C ² M M ² Y Y ² C C ² Y M ² C Y ² M	1,85338757	0,08624693
C ² M ² Y ²	1,83948177	0,13849431
C ³ M ² Y ² C ² M ³ Y ² C ² M ² Y ³	1,79303665	0,14700534
C ⁴ M ³ M ⁴ Y ³ Y ⁴ C ³ C ⁴ Y ³ M ⁴ C ³ Y ⁴ M ³	1,60375519	0,14311514
C ³ MY CM ³ Y CMY ³	1,59376526	0,18946159
CMY	1,53553147	0,21565979
C ³ M ² M ³ Y ² Y ³ C ² C ³ Y ² M ³ C ² Y ³ M ²	1,23908032	0,28390550
Odsječak	1,01109237	0,31495553
C ⁴ M ² Y C ⁴ MY ² C ² M ⁴ Y CM ⁴ Y ² C ² MY ⁴ CM ² Y ⁴	0,88735721	0,50352207
C ² MY CM ² Y CMY ²	- 0,02310528	1,00000000

Korak 7: eliminacija bloka C²MY CM²Y CMY²

C ⁴ M ⁴ M ⁴ Y ⁴ C ⁴ Y ⁴	22,63399726	0,00000000
C ³ MY CM ³ Y CMY ³	20,33980041	0,00000000
C ² M ² Y ²	19,42314926	0,00001195
C ³ M ³ Y ² C ³ M ² Y ³ C ² M ³ Y ³	15,60287060	0,00000000
C M Y	14,06379591	0,00000001
C ⁵ M ² Y C ⁵ MY ² C ² M ⁵ Y CM ⁵ Y ² C ² MY ⁵ CM ² Y ⁵	13,28364840	0,00000000
C ⁵ M ³ M ⁵ Y ³ Y ⁵ C ³ C ⁵ Y ³ M ⁵ C ³ Y ⁵ M ³	12,69930253	0,00000000
C ⁴ M ³ Y C ⁴ MY ³ C ³ M ⁴ Y CM ⁴ Y ³ C ³ MY ⁴ CM ³ Y ⁴	11,93953126	0,00000000
C ⁴ MY CM ⁴ Y CMY ⁴	11,28173928	0,00000030
C ⁴ M ² Y ² C ² M ⁴ Y ² C ² M ² Y ⁴	7,14045706	0,00009822
C ⁵ MY CM ⁵ Y CMY ⁵	5,80843416	0,00062964
C ³ M ² Y ² C ² M ³ Y ² C ² M ² Y ³	5,44129605	0,00104891
C ³ M ³ M ³ Y ³ C ³ Y ³	4,93268015	0,00212321
C ⁶ M ² M ⁶ Y ² Y ⁶ C ² C ⁶ Y ² M ⁶ C ² Y ⁶ M ²	4,44982684	0,00019424
C ⁷ M ⁷ Y ⁷	4,32008935	0,00494561
CMY	3,92589033	0,04790010

$C^6 M^6 Y^6$	3,85622585	0,00934759
$C^5 M^5 Y^5$	3,47578249	0,01570770
$C^3 M^2 Y C^3 M Y^2 C^2 M^3 Y C M^3 Y^2 C^2 M Y^3 C M^2 Y^3$	3,35083328	0,00288492
$C^2 M^2 M^2 Y^2 C^2 Y^2$	2,81517641	0,03833653
$C^5 M^2 M^5 Y^2 Y^5 C^2 C^5 Y^2 M^5 C^2 Y^5 M^2$	2,68983136	0,01367543
$C^4 M^2 Y C^4 M Y^2 C^2 M^4 Y C M^4 Y^2 C^2 M Y^4 C M^2 Y^4$	2,62411208	0,01590056
$C^3 M^3 Y^3$	2,38885056	0,06761826
$C^7 M M^7 Y Y^7 C C^7 Y M^7 C Y^7 M$	2,34574954	0,02981132
$C^3 M M^3 Y Y^3 C C^3 Y M^3 C Y^3 M$	2,29251071	0,03355091
$C^2 M M^2 Y Y^2 C C^2 Y M^2 C Y^2 M$	2,24986703	0,03686280
$C^4 M M^4 Y Y^4 C C^4 Y M^4 C Y^4 M$	2,22181278	0,03920776
$C^4 M^2 M^4 Y^2 Y^4 C^2 C^4 Y^2 M^4 C^2 Y^4 M^2$	2,22063992	0,03930880
$C^6 M Y C M^6 Y C M Y^6$	2,20772600	0,08582574
$C^4 M^3 M^4 Y^3 Y^4 C^3 C^4 Y^3 M^4 C^3 Y^4 M^3$	1,86886302	0,08350753
$C^5 M M^5 Y Y^5 C C^5 Y M^5 C Y^5 M$	1,85599615	0,08577464
$C^2 M^2 Y^2$	1,69932013	0,16570784
$C^3 M^2 M^3 Y^2 Y^3 C^2 C^3 Y^2 M^3 C^2 Y^3 M^2$	1,43470245	0,19843116
Odsječak	0,72524091	0,39469254

Korak 8: eliminacija bloka $C^3 M^2 M^3 Y^2 Y^3 C^2 C^3 Y^2 M^3 C^2 Y^3 M^2$

$C^4 M^4 M^4 Y^4 C^4 Y^4$	26,21971527	0,00000000
$C^3 M Y C M^3 Y C M Y^3$	20,71826111	0,00000000
$C^2 M^2 Y^2$	19,59223634	0,00001095
$C^5 M^3 M^5 Y^3 Y^5 C^3 C^5 Y^3 M^5 C^3 Y^5 M^3$	17,99477437	0,00000000
$C M Y$	17,97705611	0,00000000
$C^3 M^3 Y^2 C^3 M^2 Y^3 C^2 M^3 Y^3$	15,62981269	0,00000000
$C^4 M^3 Y C^4 M Y^3 C^3 M^4 Y C M^4 Y^3 C^3 M Y^4 C M^3 Y^4$	14,03874751	0,00000000
$C^5 M^2 Y C^5 M Y^2 C^2 M^5 Y C M^5 Y^2 C^2 M Y^5 C M^2 Y^5$	12,95992189	0,00000000
$C^4 M Y C M^4 Y C M Y^4$	12,84709329	0,00000003
$C^2 M^2 M^2 Y^2 C^2 Y^2$	9,00099580	0,00000726
$C^4 M^2 Y^2 C^2 M^4 Y^2 C^2 M^2 Y^4$	8,19881268	0,00002233
$C^5 M Y C M^5 Y C M Y^5$	7,83818970	0,00003698
$C^3 M^3 M^3 Y^3 C^3 Y^3$	7,39305831	0,00006893
$C^4 M^2 M^4 Y^2 Y^4 C^2 C^4 Y^2 M^4 C^2 Y^4 M^2$	6,36559554	0,00000148
$C^7 M^7 Y^7$	5,87757561	0,00057150
$C^6 M^6 Y^6$	5,21241087	0,00144033
$C^3 M^2 Y^2 C^2 M^3 Y^2 C^2 M^2 Y^3$	4,83426800	0,00243181
$C^3 M^2 Y C^3 M Y^2 C^2 M^3 Y C M^3 Y^2 C^2 M Y^3 C M^2 Y^3$	4,73757308	0,00009426
$C^5 M^5 Y^5$	4,54183300	0,00364222
CMY	4,39546221	0,03635502
$C^6 M Y C M^6 Y C M Y^6$	3,60412840	0,01318622
$C^3 M M^3 Y Y^3 C C^3 Y M^3 C Y^3 M$	3,36918078	0,00275878
$C^4 M^3 M^4 Y^3 Y^4 C^3 C^4 Y^3 M^4 C^3 Y^4 M^3$	3,18272953	0,00430913
$C^6 M^2 M^6 Y^2 Y^6 C^2 C^6 Y^2 M^6 C^2 Y^6 M^2$	3,11434324	0,00506901

$C^5M^2 M^5Y^2 Y^5C^2 C^5Y^2 M^5C^2 Y^5M^2$	2,95302330	0,00741558
$C^4M M^4Y Y^4C C^4Y M^4C Y^4M$	2,95156011	0,00744108
$C^4M^2Y C^4MY^2 C^2M^4Y CM^4Y^2 C^2MY^4 CM^2Y^4$	2,81626745	0,01020516
$C^3 M^3 Y^3$	2,71702443	0,04371134
Odsječak	2,45792798	0,11733696
$C^2M M^2Y Y^2C C^2Y M^2C Y^2M$	2,04510694	0,05751705
$C^2 M^2 Y^2$	1,96497751	0,11777077
$C^7M M^7Y Y^7C C^7Y M^7C Y^7M$	1,87407747	0,08259305
$C^5M M^5Y Y^5C C^5Y M^5C Y^5M$	1,83824659	0,08898287
Korak 9: eliminacija bloka $C^2 M^2 Y^2$		
$C M Y$	69,41721900	0,00000000
$C^4M^4 M^4Y^4 C^4Y^4$	26,31492269	0,00000000
$C^3MY CM^3Y CMY^3$	18,51375860	0,00000000
$C^5M^3 M^5Y^3 Y^5C^3 C^5Y^3 M^5C^3 Y^5M^3$	18,04287704	0,00000000
$C^2M^2Y^2$	16,98617595	0,00004165
$C^3M^3Y^2 C^3M^2Y^3 C^2M^3Y^3$	13,96957115	0,00000001
$C^3 M^3 Y^3$	13,54702138	0,00000001
$C^5M^2Y C^5MY^2 C^2M^5Y CM^5Y^2 C^2MY^5 CM^2Y^5$	13,40568886	0,00000000
$C^4M^3Y C^4MY^3 C^3M^4Y CM^4Y^3 C^3MY^4 CM^3Y^4$	12,90633050	0,00000000
$C^4MY CM^4Y CMY^4$	11,99948466	0,00000011
$C^2M^2 M^2Y^2 C^2Y^2$	11,52950343	0,00000021
$C^3M^3 M^3Y^3 C^3Y^3$	8,04213286	0,00002778
$C^5MY CM^5Y CMY^5$	7,80419915	0,00003876
$C^4M^2Y^2 C^2M^4Y^2 C^2M^2Y^4$	6,85498011	0,00014616
$C^4M^2 M^4Y^2 Y^4C^2 C^4Y^2 M^4C^2 Y^4M^2$	6,34997306	0,00000154
$C^7 M^7 Y^7$	5,74359302	0,00068843
$C^5 M^5 Y^5$	5,51521040	0,00094574
$C^6 M^6 Y^6$	5,36120347	0,00117132
$C^3M^2Y C^3MY^2 C^2M^3Y CM^3Y^2 C^2MY^3 CM^2Y^3$	4,42516053	0,00020622
$C^6MY CM^6Y CMY^6$	4,15793027	0,00617794
$C^3M M^3Y Y^3C C^3Y M^3C Y^3M$	3,87608217	0,00080415
$C^3M^2Y^2 C^2M^3Y^2 C^2M^2Y^3$	3,64893080	0,01240325
CMY	3,63077042	0,05708518
$C^4M^3 M^4Y^3 Y^4C^3 C^4Y^3 M^4C^3 Y^4M^3$	3,36642596	0,00277623
$C^4M M^4Y Y^4C C^4Y M^4C Y^4M$	3,11767160	0,00502786
$C^6M^2 M^6Y^2 Y^6C^2 C^6Y^2 M^6C^2 Y^6M^2$	3,00193399	0,00660887
$C^4M^2Y C^4MY^2 C^2M^4Y CM^4Y^2 C^2MY^4 CM^2Y^4$	2,86002728	0,00921511
$C^2M M^2Y Y^2C C^2Y M^2C Y^2M$	2,81570354	0,01021646
$C^5M^2 M^5Y^2 Y^5C^2 C^5Y^2 M^5C^2 Y^5M^2$	2,73341643	0,01236163
$C^5M M^5Y Y^5C C^5Y M^5C Y^5M$	1,72027885	0,11332456
$C^7M M^7Y Y^7C C^7Y M^7C Y^7M$	1,48386489	0,18069434
Odsječak	1,30382553	0,25386336
Korak 10: eliminacija bloka $C^7M M^7Y Y^7C C^7Y M^7C Y^7M$		

Tabela A.6, Odstupanje reducirano modela od empirijskih podataka, proces B

	N - broj polja	dEab	Min	Medijan	Maks	Int. pouz. 95%
RGB->D	918	1,61	0,16	1,41	6,04	0,12

Reducirani model:

1 C M Y CMY C²M M²Y Y²C C²Y M²C Y²M C³ M³ Y³ C²M² M²Y² C²Y²
 C³M M³Y Y³C C³Y M³C Y³M C³MY CM³Y CMY³ C⁴M M⁴Y Y⁴C C⁴Y M⁴C Y⁴M
 C⁵ M⁵ Y⁵ C²M²Y² C³M²Y C³MY² C²M³Y CM³Y² C²MY³ CM²Y³ C⁴MY CM⁴Y CMY⁴
 C³M³ M³Y³ C³Y³ C⁴M² M⁴Y² Y⁴C² C⁴Y² M⁴C² Y⁴M² C⁵M M⁵Y Y⁵C C⁵Y M⁵C
 Y⁵M C⁶ M⁶ Y⁶ C³M²Y² C²M³Y² C²M²Y³ C⁴M²Y C⁴MY² C²M⁴Y CM⁴Y² C²MY⁴
 CM²Y⁴ C⁵MY CM⁵Y CMY⁵ C⁴M³ M⁴Y³ Y⁴C³ C⁴Y³ M⁴C³ Y⁴M³ C⁵M² M⁵Y² Y⁵C²
 C⁵Y² M⁵C² Y⁵M² C⁷ M⁷ Y⁷ C³M³Y² C³M²Y³ C²M³Y³ C⁴M²Y² C²M⁴Y² C²M²Y⁴
 C⁴M³Y C⁴MY³ C³M⁴Y CM⁴Y³ C³MY⁴ CM³Y⁴ C⁵M²Y C⁵MY² C²M⁵Y CM⁵Y² C²MY⁵
 CM²Y⁵ C⁶MY CM⁶Y CMY⁶ C⁴M⁴ M⁴Y⁴ C⁴Y⁴ C⁵M³ M⁵Y³ Y⁵C³ C⁵Y³ M⁵C³ Y⁵M³
 C⁶M² M⁶Y² Y⁶C² C⁶Y² M⁶C² Y⁶M²

PRILOG B

Proces C

Tabela B.1, Odstupanje maksimalnog modela od empirijskih podataka, proces C

	N - broj polja	dEab	Min	Medijan	Maks	Int. pouz. 95%
RGB->D	918	3,18	0,28	2,95	11,44	0,21

Tabela B.2, Postupak eliminacije skupina članova, proces C

Korak 1		
Blok članova	Fp	p
Y ³ M ²	95,929992864	0,00000000
Y ⁴ M	82,58509915	0,00000000
M ⁴ C	68,18018084	0,00000000
C ³ Y ²	54,32940408	0,00000000
M ³ Y ²	48,98356558	0,00000000
C ³ M ²	43,91013253	0,00000000
C ² MY ²	40,97572110	0,00000000
M ² Y ²	36,47985410	0,00000000
CM ² Y ²	35,57145408	0,00000000
CMY ³	32,71711037	0,00000001
C ² Y	27,13144101	0,00000024
CMY ²	25,39351602	0,00000057
M ³ Y	22,11086166	0,00000300
C ⁴ Y	21,30049832	0,00000452
C ² MY	21,07561597	0,00000507
M ² Y	21,02134552	0,00000521
C ² Y ²	20,25946498	0,00000769
Y ² M	19,64619466	0,00001052
M ²	19,19656693	0,00001324
M ⁴ Y	17,97146237	0,00002484
CMY	17,87200635	0,00002615
CM ² Y	17,62916811	0,00002963
CM ³ Y	17,03817966	0,00004019
MY	16,14398489	0,00006383
M ³ C ²	14,75012252	0,00013173
M ³ C	13,74103439	0,00022322
Y ³ M	12,18431879	0,00050639
C	11,43607369	0,00075274
M ³	10,69697121	0,00111570
C ³ Y	10,48599672	0,00124881
M	9,46957378	0,00215513

C ³ M	8,90570518	0,00292306
Y ²	8,85991243	0,00299653
CY	8,55234722	0,00354120
C ² M	8,28574199	0,00409456
C ² M ²	7,02271799	0,00819566
C ² M ² Y	5,37030586	0,02071581
C ⁴ M	5,24724134	0,02222220
M ⁵	4,71144340	0,03023482
M ⁴	4,19412793	0,04086674
Y ³ C	3,95963813	0,04691926
Y ³	3,84012123	0,05036180
Y ² C	2,45120432	0,11780175
Odsječak	1,81906850	0,17777841
Y	1,63270749	0,20167297
Y ³ C ²	- 0,42220629	1,00000000
C ²	- 0,98218175	1,00000000
C ³	- 1,85810701	1,00000000
M ² C	- 3,29767556	1,00000000
C ³ MY	- 3,36528355	1,00000000
Y ⁴	- 3,42571657	1,00000000
CM	- 4,58872037	1,00000000
C ⁵	- 4,62316917	1,00000000
C ⁴	- 4,76647719	1,00000000
Y ⁵	- 8,81116013	1,00000000
Y ⁴ C	- 11,00193181	1,00000000

Korak 2: eliminacija člana Y⁴C

Y ³ M ²	100,57031148	0,00000000
Y ⁴ M	73,13971633	0,00000000
M ⁴ C	73,04156784	0,00000000
C ³ Y ²	54,49812418	0,00000000
M ³ Y ²	48,83154772	0,00000000
C ³ M ²	45,37011046	0,00000000
C ² MY ²	43,05247006	0,00000000
M ² Y ²	38,58179255	0,00000000
CMY ³	33,95688137	0,00000001
CM ² Y ²	32,32244713	0,00000002
C ² Y	26,10248077	0,00000040
CMY ²	25,28028528	0,00000060
C ² MY	22,92931572	0,00000198
Y ² M	21,95700341	0,00000324
M ² Y	21,33893903	0,00000443
CMY	19,53338647	0,00001114
C ⁴ Y	19,43850426	0,00001170

M^2	19,34016882	0,00001230
M^3Y	18,92662285	0,00001521
C^2Y^2	18,77843035	0,00001641
MY	18,63616699	0,00001765
M^2C	18,17620940	0,00002236
CM^3Y	17,79460092	0,00002721
CM^2Y	17,15195837	0,00003790
M^4Y	15,61976146	0,00008377
M^3C^2	14,54738662	0,00014641
CY	14,32812705	0,00016417
C	12,62979523	0,00040025
M^3	10,79841142	0,00105686
Y^3M	9,39562123	0,00224275
C^2M^2	8,95108192	0,00285198
Y^2	8,77929345	0,00313037
M	8,77096944	0,00314454
C^3Y	8,38323772	0,0038253
C^3M	7,98461808	0,00482656
C^2M	7,53538367	0,00617561
Y^2C	5,88353193	0,01548727
C^2M^2Y	5,45239773	0,01976990
M^5	4,46342557	0,03491463
C^4M	4,15989545	0,04169607
M^4	4,09076530	0,04342609
Y^3C	2,57226995	0,10911746
C^2	1,55595679	0,21259660
C^3	1,00346591	0,31675410
Y^3	0,99362869	0,31913651
Odsječak	0,73038433	0,39299582
Y^3C^2	- 0,47285073	1,00000000
M^2C	- 0,49141389	1,00000000
C^5	- 1,84235618	1,00000000
C^4	- 2,00580465	1,00000000
Y	- 2,28013600	1,00000000
Y^4	- 3,85942076	1,00000000
CM	- 4,11014069	1,00000000
C^3MY	- 4,18805601	1,00000000
Y^5	- 6,42118103	1,00000000

Korak 3: eliminacija člana Y^5

Y^3M^2	101,60978232	0,00000000
Y^4M	78,79395663	0,00000000
M^4C	69,49048745	0,00000000
C^3Y^2	54,06096060	0,00000000

M ³ Y ²	50,21145864	0,00000000
C ³ M ²	44,73723139	0,00000000
C ² MY ²	44,19853378	0,00000000
M ² Y ²	41,44720917	0,00000000
CM ² Y ²	32,81693986	0,00000001
CMY ³	31,81950136	0,00000002
C ² Y	26,81567980	0,00000028
CMY ²	26,42660923	0,00000034
Y ²	24,05695385	0,00000112
C ² MY	23,25905584	0,00000167
Y ² M	20,78729132	0,00000587
Y ³	20,65158284	0,00000629
MY	20,12170199	0,00000825
M ² Y	19,77344049	0,00000986
M ⁴ Y	19,46192847	0,00001156
CMY	19,37785568	0,00001207
CM ³ Y	18,51066936	0,00001883
M ²	18,42328951	0,00001969
C ² Y ²	18,13232068	0,00002287
C ⁴ Y	17,51201303	0,00003147
Y ⁴	17,38800170	0,00003355
M ³ C	17,20039108	0,00003696
CM ² Y	17,01798232	0,00004061
M ³ Y	16,81136116	0,00004518
M ³ C ²	16,80242986	0,00004539
CY	14,53642513	0,00014724
C	12,45652586	0,00043853
M ³	10,27804399	0,00139569
Y ³ M	10,24847271	0,00141797
C ² M ²	9,52724332	0,00208902
M	9,29576521	0,00236685
C ³ M	8,44518489	0,00375361
C ² M	7,87609474	0,00512192
C ² M ² Y	7,67787902	0,00571023
C ³ Y	7,30894459	0,00699600
M ⁵	5,97398723	0,01471740
C ⁴ M	5,41205568	0,02022862
Y ² C	5,10294750	0,02413375
M ⁴	4,59881360	0,03227245
C ²	1,81382863	0,17840279
C ³	1,53469133	0,21574617
Y	1,37057657	0,24203563
Y ³ C	1,18163947	0,27732564

Odsječak	1,07964964	0,29906664
M ² C	0,54521380	0,46048047
Y ³ C ²	- 0,86924025	1,00000000
C ⁴	- 1,44077386	1,00000000
C ⁵	- 1,44394768	1,00000000
CM	- 3,48386338	1,00000000
C ³ MY	- 4,17276682	1,00000000

Korak 4: eliminacija člana C³MY

Y ³ M ²	105,15789799	0,00000000
Y ⁴ M	79,63178987	0,00000000
M ⁴ C	65,62396636	0,00000000
C ² MY	60,02967969	0,00000000
C ³ Y ²	52,89625514	0,00000000
M ³ Y ²	50,86452715	0,00000000
C ² MY ²	46,18144468	0,00000000
C ³ M ²	43,94765898	0,00000000
CMY ³	42,97655086	0,00000000
M ² Y ²	41,18391759	0,00000000
CM ² Y ²	34,66228446	0,00000001
C ² Y	28,93347730	0,00000010
Y ²	24,22578460	0,00000103
Y ² M	21,44616061	0,00000420
Y ³	21,28534735	0,00000456
CMY	21,27103672	0,00000459
M ⁴ Y	20,53354349	0,00000668
CMY ²	20,42631418	0,00000706
C ² Y ²	18,68036228	0,00001725
Y ⁴	18,40113151	0,00001991
MY	18,31325616	0,00002083
M ³ C ²	17,79449094	0,00002720
M ² Y	17,26809966	0,00003568
M ³ Y	16,54615300	0,00005182
M ³ C	16,02919408	0,00006773
C ⁴ Y	15,91248842	0,00007195
CY	13,48896120	0,00025471
C	12,89700992	0,00034765
M ²	11,86186081	0,00060049
CM ³ Y	11,39406557	0,00076960
CM ² Y	11,38515359	0,00077326
M	11,02912247	0,00093448
C ² M ²	9,87121378	0,00173599
Y ³ M	9,59691301	0,00201200
C ³ Y	9,57156601	0,00203966

M ⁵	8,99294953	0,00278785
C ² M ² Y	7,92752762	0,00497951
M ³	5,79014876	0,01632503
M ⁴	4,34518762	0,03740652
Y ² C	3,99133560	0,04604753
C ⁴ M	3,23862285	0,07226945
C ² M	2,54336457	0,11112383
C ³ M	2,15780660	0,14221061
Y	1,26340231	0,26131989
Y ³ C	1,26276226	0,26144064
C ³	0,85634358	0,35502203
Odsječak	0,85512227	0,35536519
M ² C	0,33442482	0,56321566
C ²	- 0,77213708	1,00000000
Y ³ C ²	- 1,00293511	1,00000000
C ⁴	- 1,27164281	1,00000000
C ⁵	- 1,55900306	1,00000000
CM	- 3,98457659	1,00000000
C3MY	- 4,17276682	1,00000000

Korak 5: eliminacija člana CM

Y ³ M ²	109,57255546	0,00000000
Y ⁴ M	82,55179998	0,00000000
C ² MY	70,39468867	0,00000000
M ⁴ C	64,49562238	0,00000000
C ³ Y ²	55,00689705	0,00000000
C ³ M ²	50,36929466	0,00000000
M ³ Y ²	48,71716315	0,00000000
C ² MY ²	46,66538187	0,00000000
CMY ³	43,84933931	0,00000000
M ² Y ²	42,49598206	0,00000000
CM ² Y ²	34,98958501	0,00000000
M ³ C ²	34,10404928	0,00000001
C ² Y	29,23408100	0,00000008
C ² M ²	27,56503172	0,00000019
CMY	25,83325006	0,00000046
Y ²	25,48719186	0,00000054
Y ³	22,90015575	0,00000201
M ⁴ Y	22,64125208	0,00000229
Y ² M	21,96400299	0,00000323
M ³ C	20,37332799	0,00000725
C ² Y ²	20,33705758	0,00000739
Y ⁴	20,31403901	0,00000747
CMY ²	19,96258990	0,00000894

MY	18,26420200	0,00002136
M ³ Y	16,60164346	0,00005035
M ² Y	16,45739045	0,00005425
C ⁴ Y	16,16548757	0,00006310
C	13,86530958	0,00020909
M	13,85711554	0,00020999
CY	13,35781606	0,00027284
C ² M	13,16830363	0,00030140
CM ³ Y	12,53777009	0,00042008
CM ² Y	10,74049828	0,00108988
M ²	10,73940428	0,00109052
C ³ Y	9,97051273	0,00164577
Y ³ M	9,89300566	0,00171572
M ⁵	9,50639667	0,00211247
C ³ M	6,41540132	0,01148900
C ⁴ M	5,94285009	0,01497731
C ² M ² Y	5,35853644	0,02085410
M ³	5,30792337	0,02146461
Y ² C	4,53755254	0,03344028
M ⁴	4,33546675	0,03761924
M ² C	2,99368174	0,08394618
Y ³ C	1,57494153	0,20982939
Y	1,32533863	0,24995392
C ³	0,70332450	0,40190029
Odsječak	0,15420374	0,69464669
C ²	0,07436342	0,78515147
Y ³ C ²	- 0,74495478	1,00000000
C ⁵	- 1,36228002	1,00000000
C ⁴	- 1,45653785	1,00000000

Korak 6: eliminacija člana C⁴

Y ³ M ²	110,05926658	0,00000000
Y ⁴ M	76,82404212	0,00000000
C ² MY	70,30021599	0,00000000
M ⁴ C	66,60596803	0,00000000
C ³ Y ²	54,86214317	0,00000000
M ³ Y ²	48,79818699	0,00000000
C ³ M ²	48,26130189	0,00000000
C ² MY ²	46,59685386	0,00000000
CMY ³	43,83297333	0,00000000
M ² Y ²	41,89174405	0,00000000
CM ² Y ²	34,90315622	0,00000000
M ³ C ²	33,70825117	0,00000001
C ² Y	28,71528369	0,00000011

C	27,51499465	0,00000020
CMY	25,32269972	0,00000059
C^2M^2	24,66846272	0,00000082
C^5	24,55539415	0,00000087
Y^2	24,08541686	0,00000110
Y^2M	22,41749029	0,00000256
M^3C	22,12489985	0,00000297
M^4Y	22,06085083	0,00000307
Y^3	20,64888350	0,00000630
CMY^2	19,98477424	0,00000884
C^2Y^2	19,90668373	0,00000920
MY	18,17561325	0,00002235
Y^4	17,97728961	0,00002476
M^2Y	16,53688743	0,00005206
M^3Y	15,79519654	0,00007645
C^4Y	15,47486214	0,00009029
M	14,26954048	0,00016923
CY	13,28259878	0,00028382
CM^3Y	12,94605265	0,00033875
C^2M	12,63126591	0,00039985
M^2	12,24291230	0,00049081
CM^2Y	10,58224334	0,00118594
C^3Y	9,43627970	0,00219379
M^5	9,25244744	0,00242263
Y^3M	8,21826231	0,00424753
C^3	7,45189122	0,00646545
M^3	5,98373560	0,01463616
C^3M	5,97515031	0,01470707
C^4M	5,67342993	0,01743857
C^2M^2Y	5,14191277	0,02360028
Y^2C	4,50716900	0,03403583
M^2C	4,44385662	0,03531349
M^4	4,37312209	0,03680059
Y^3C	1,79152237	0,18109167
Y	1,47967316	0,22415672
C^2	0,58724948	0,44369329
Odsječak	- 0,09564292	1,00000000
Y^3C^2	- 0,22482499	1,00000000

Korak 7: eliminacija člana Y^3C^2

Y^3M^2	108,77160112	0,00000000
Y^4M	77,20828312	0,00000000
C^2MY	71,33597272	0,00000000
M^4C	66,40802733	0,00000000

C ³ Y ²	55,07552654	0,00000000
M ³ Y ²	49,54458005	0,00000000
C ³ M ²	47,15906346	0,00000000
C ² MY ²	46,87025183	0,00000000
C ² Y ²	45,48890074	0,00000000
CMY ³	44,08598407	0,00000000
M ² Y ²	40,57381289	0,00000000
CM ² Y ²	34,98107992	0,00000000
M ³ C ²	34,14884352	0,00000001
C	30,53470316	0,00000004
Y ² C	30,42465677	0,00000005
C ² Y	29,35827986	0,00000008
Y ²	28,24795253	0,00000014
C ⁵	26,54862177	0,00000032
CMY	25,53623214	0,00000053
C ² M ²	23,84956394	0,00000124
CY	23,44345169	0,00000152
Y ² M	22,54408683	0,00000240
M ⁴ Y	22,34184358	0,00000266
M ³ C	22,12197999	0,00000298
Y ³	21,39877366	0,00000430
CMY ²	20,18543204	0,00000798
MY	18,56411909	0,00001831
Y ⁴	17,66175684	0,00002912
M ² Y	16,89403406	0,00004327
M ³ Y	16,33911578	0,00005766
C ⁴ Y	16,21665361	0,00006144
M	14,23872107	0,00017196
C ² M	13,04889390	0,00032089
CM ³ Y	12,93527448	0,00034066
M ²	12,08993886	0,00053212
CM ² Y	10,68722721	0,00112122
M ⁵	9,54966225	0,00206364
C ³	8,20554742	0,00427700
Y ³ M	7,44508077	0,00648960
C ³ M	6,14195692	0,01339025
M ³	5,94123865	0,01499045
Y ³ C	5,83568491	0,01590987
C ³ Y	5,51886562	0,01903575
C ⁴ M	4,95107908	0,02633070
C ² M ² Y	4,56090251	0,03298913
M ⁴	4,49332773	0,03431063
M ² C	4,35545676	0,03718180

Y	2,38709890	0,12270497
C ²	0,30640019	0,58004017
Odsječak	0,09485185	0,75817122

Korak 8: eliminacija člana C²

C	208,65360127	0,00000000
Y ³ M ²	106,03795578	0,00000000
C ³ Y ²	81,60583752	0,00000000
Y ⁴ M	80,32591385	0,00000000
C ² MY	72,03233265	0,00000000
C ² Y ²	71,06625554	0,00000000
C ² Y	68,21026636	0,00000000
M ⁴ C	66,70096603	0,00000000
M ³ Y ²	51,32571542	0,00000000
C ³ M ²	49,47477694	0,00000000
C ² MY ²	46,43101587	0,00000000
C ⁵	43,17836316	0,00000000
CMY ³	43,14174255	0,00000000
CY	42,17002566	0,00000000
M ² Y ²	38,65729282	0,00000000
Y ² C	37,96513777	0,00000000
M ³ C ²	34,82346179	0,00000001
CM ² Y ²	34,05773062	0,00000001
C ³	32,06624254	0,00000002
Y ²	28,58442850	0,00000011
CMY	24,68868241	0,00000081
C ² M ²	23,62501252	0,00000139
M ³ C	23,49820278	0,00000148
Y ³	23,15321520	0,00000176
M ⁴ Y	22,50864622	0,00000244
Y ² M	21,50190395	0,00000408
Y ⁴	20,29716095	0,00000754
CMY ²	19,71481974	0,00001015
C ³ Y	18,77496558	0,00001643
M ³ Y	18,12234908	0,00002297
M ² Y	17,72826979	0,00002814
MY	17,61669107	0,00002980
C ² M	16,57266959	0,00005109
M	15,70977733	0,00007991
C ⁴ Y	14,77726353	0,00012981
M ²	14,71830441	0,00013386
CM ³ Y	11,71958390	0,00064737
CM ² Y	9,94388629	0,00166927
M ⁵	9,78712835	0,00181597

C^3M	8,10483574	0,00451874
Y^3M	7,45293718	0,00646143
M^3	7,37513573	0,00674446
Y^3C	5,97961506	0,01466969
C^2M^2Y	5,74353813	0,01675984
M^2C	5,34369469	0,02103043
M^4	5,14504853	0,02355739
C^4M	4,54080335	0,03337621
Y	2,37566347	0,12360328
Odsječak	- 0,73340536	1,00000000
Korak 9: eliminacija člana Y		

Tabela B.3, Odstupanje reduciranih modela od empirijskih podataka, proces C

	N - broj polja	dEab	Min	Medijan	Maks	Int. pouz. 95%
RGB->D	918	3,15	0,15	2,88	11,56	0,20

Reducirani model:

1 C M MY CY M² Y² CMY C²M M²Y Y²C C²Y M²C Y²M C³ M³ Y³
 C²MY CM²Y CMY² C²M² M²Y² C²Y² C³M M³Y Y³C C³Y M³C Y³M M⁴ Y⁴
 C²M²Y C²MY² CM²Y² CM³Y CMY³ C³M² M³Y² C³Y² M³C² Y³M² C⁴M M⁴Y C⁴Y
 M⁴C Y⁴M C⁵ M⁵

Proces D

Tabela B.4, Odstupanje maksimalnog modela od empirijskih podataka, proces D

	N - broj polja	dEab	Min	Medijan	Maks	Int. pouz. 95%
RGB->D	918	2,44	0,08	2,20	9,20	0,18

Tabela B.5, Postupak eliminacije skupina članova, proces D

Korak 1		
Blok članova	Fp	p
Y ³ M ²	119,27274355	0,00000000
M ³	70,00025940	0,00000000
CMY ³	63,43993944	0,00000000
C ³ M ²	63,33848705	0,00000000
M ⁴	62,53119812	0,00000000
M ³ C ²	61,35536634	0,00000000
C ² MY	60,95915955	0,00000000
Y ⁴ M	56,18380158	0,00000000
M ⁴ C	53,76553577	0,00000000
M ²	51,08808762	0,00000000
C ³ Y	48,42835827	0,00000000
Y ² M	48,31487590	0,00000000
C	46,13241530	0,00000000
M ⁵	45,09344311	0,00000000
Y	38,80354806	0,00000000
M ³ Y	37,29158979	0,00000000
C ³ M	31,56424258	0,00000003
C ² Y	31,39484821	0,00000003
C ² M	31,06150207	0,00000003
C ² M ² Y	29,99959408	0,00000006
CM ² Y ²	26,20977124	0,00000038
MY	25,55036315	0,00000053
C ² MY ²	24,00439844	0,00000115
M ² Y ²	22,53571259	0,00000241
M	21,10092632	0,00000501
C ⁴ Y	20,43955334	0,00000701
M ³ Y ²	20,09494877	0,00000836
M ⁴ Y	18,98252260	0,00001478
C ⁵	17,89395860	0,00002586
C ² M ²	17,87404742	0,00002612
CM ³ Y	17,55774298	0,00003074
C ⁴	17,30626874	0,00003500

C ³ Y ²	15,78770554	0,00007679
CM ² Y	15,75849789	0,00007796
Y ⁴ C	15,51827262	0,00008832
CMY	15,37572970	0,00009511
Y ³	14,65609900	0,00013835
Y ³ M	13,14516078	0,00030517
M ² Y	12,69992127	0,00038575
Y ⁴	12,12249278	0,00052321
Y ³ C	10,98146208	0,00095865
M ³ C	10,94788040	0,00097595
C ³	9,08096187	0,00265842
CMY ²	6,68338957	0,00989471
Y ²	6,04943922	0,01410609
CM	5,55593792	0,01864083
Y ⁵	4,76817677	0,02925948
M ² C	3,21066189	0,07351053
C ² Y ²	3,20302832	0,07385299
CY	3,19484093	0,07422219
Y ² C	2,33163765	0,12713528
C ³ MY	2,05350216	0,15221909
Y ³ C ²	1,21901384	0,26986238
Odsječak	0,76805277	0,38106427
C ²	- 0,53413070	1,00000000
C ⁴ M	- 2,46432433	1,00000000

Korak 2: eliminacija člana C⁴M

Y ³ M ²	119,99579928	0,00000000
C ³ M	75,50791249	0,00000000
M ³	70,15621942	0,00000000
CMY ³	65,69409967	0,00000000
C ² MY	64,00960873	0,00000000
C ³ M ²	63,93369887	0,00000000
M ³ C ²	62,35593938	0,00000000
M ⁴	62,03860393	0,00000000
Y ⁴ M	57,34058701	0,00000000
M ⁴ C	55,73024210	0,00000000
C	54,10412829	0,00000000
M ²	51,87631471	0,00000000
Y ² M	48,35395482	0,00000000
C ³ Y	45,10694181	0,00000000
M ⁵	44,30848470	0,00000000
Y	40,01264404	0,00000000
M ³ Y	37,37707199	0,00000000
C ² M	33,64455152	0,00000001

C ² M ² Y	30,17338732	0,00000005
C ² Y	27,50767840	0,00000020
CM ² Y ²	26,87953504	0,00000027
MY	24,90413785	0,00000073
C ² MY ²	22,52695292	0,00000242
M ² Y ²	22,07631837	0,00000305
M ³ Y ²	20,90691825	0,00000553
C ⁴	20,26830574	0,00000765
M	20,21965316	0,00000785
C ² M ²	19,49047314	0,00001139
C ⁴ Y	19,41333021	0,00001185
C ⁵	19,08250777	0,00001404
M ⁴ Y	18,88810196	0,00001551
CM ³ Y	18,27558032	0,00002124
CMY	16,66411351	0,00004876
Y ⁴ C	16,10369669	0,00006517
CM ² Y	15,61889757	0,00008381
Y ³	14,52216431	0,00014835
C ³ Y ²	14,30704602	0,00016599
Y ³ M	14,26424644	0,00016975
C ³	13,83051714	0,00021298
M ² Y	12,91269178	0,00034484
Y ³ C	12,73337967	0,00037899
Y ⁴	11,82684809	0,00061179
M ³ C	10,94092002	0,00097953
CMY ²	6,89286047	0,00880723
CM	6,79265899	0,00931115
Y ²	6,20597771	0,01291884
Y ⁵	4,43452770	0,03550729
C ³ MY	3,75506993	0,05297351
Y ² C	3,36499809	0,06693979
C ² Y ²	2,46706677	0,11662124
CY	2,42656050	0,1196102
M ² C	2,35165239	0,12551678
C ²	1,95385520	0,16253120
Y ³ C ²	1,45730521	0,22769014
Odsječak	0,67415826	0,41183234

Korak 3: eliminacija člana Y^3C^2

Y ³ M ²	120,91125342	0,00000000
C ³ M	74,88451597	0,00000000
M ³	69,91957040	0,00000000
CMY ³	65,69787635	0,00000000
C ² MY	63,57930013	0,00000000

C ³ M ²	62,85403501	0,00000000
M ³ C ²	62,06280693	0,00000000
M ⁴	61,97309643	0,00000000
C	57,58295943	0,00000000
Y ⁴ M	57,27975147	0,00000000
M ⁴ C	54,99721548	0,00000000
M ²	51,61934960	0,00000000
Y ² M	47,62493698	0,00000000
M ⁵	44,39918393	0,00000000
C ³ Y	41,38375380	0,00000000
Y	40,37442380	0,00000000
M ³ Y	38,03811129	0,00000000
C ² M	32,64086973	0,00000002
C ² Y	30,34875351	0,00000005
C ² M ² Y	30,07716854	0,00000005
CM ² Y ²	26,97520772	0,00000026
MY	24,74173302	0,00000079
C ² MY ²	23,24637248	0,00000168
M ² Y ²	21,94158959	0,00000326
M ³ Y ²	20,53939747	0,00000666
M	20,38762978	0,00000720
C ⁴	20,13686157	0,00000818
M ⁴ Y	19,45938401	0,00001157
CM ³ Y	18,63617151	0,00001765
C ⁵	18,63198959	0,00001769
C ² M ²	17,99765150	0,00002451
CMY	17,10982938	0,00003873
C ⁴ Y	16,45488912	0,00005433
Y ⁴ C	16,09622799	0,00006542
CM ² Y	15,96129831	0,00007016
Y ³	14,42541034	0,00015603
C ³ Y ²	14,23120904	0,00017269
C ³	13,96685829	0,00019830
Y ³ M	13,31374827	0,00027927
M ² Y	12,85646217	0,00035518
Y ⁴	11,60649407	0,00068756
M ³ C	10,89722048	0,00100257
Y ³ C	10,79355356	0,00105956
C ² Y ²	9,41437576	0,00222009
CMY ²	7,22041419	0,00734642
Y ²	6,62228814	0,01023676
CM	6,21992635	0,01281797
Y ⁵	4,12659976	0,04251972

C ³ MY	3,35010818	0,06754495
CY	3,06570913	0,08031514
M ² C	2,27097278	0,13218266
C ²	1,88577443	0,17003555
Odsječak	0,85617958	0,35506839
Y ² C	0,64072380	0,42366886

Korak 4: eliminacija člana Y²C

Y ³ M ²	121,34235738	0,00000000
C ³ M	74,40269041	0,00000000
CMY ³	72,30624212	0,00000000
M ³	70,03774801	0,00000000
Y	63,49289159	0,00000000
C ² MY	62,84949501	0,00000000
C ³ M ²	62,28274519	0,00000000
M ⁴	62,06234122	0,00000000
M ³ C ²	61,88473282	0,00000000
C	58,01944199	0,00000000
Y ⁴ M	56,17622268	0,00000000
M ⁴ C	55,04356547	0,00000000
M ²	51,82748623	0,00000000
Y ² M	48,35957371	0,00000000
C ³ Y	45,70691628	0,00000000
M ⁵	44,48678271	0,00000000
C ² Y	40,97046394	0,00000000
M ³ Y	37,05283564	0,00000000
C ² M	32,32834852	0,00000002
C ² M ² Y	30,11353228	0,00000005
CM ² Y ²	26,79722297	0,00000028
MY	25,18995488	0,00000063
C ² MY ²	22,87710069	0,00000203
C ⁴	22,64053633	0,00000229
Y ⁴ C	22,52483497	0,00000243
M ² Y ²	22,06568555	0,00000306
C ⁵	20,94172570	0,00000543
M	20,83816742	0,00000572
M ³ Y ²	20,56859778	0,00000656
C ³ Y ²	19,99011058	0,00000882
M ⁴ Y	19,19812564	0,00001323
CM ³ Y	18,52617912	0,00001867
C ² M ²	17,63401820	0,00002955
Y ³ C	17,41146234	0,00003314
C ² Y ²	17,24622852	0,00003609
C ⁴ Y	16,48796555	0,00005340

CMY	16,45417785	0,00005434
C ³	15,85700630	0,00007405
Y ³	15,66064393	0,00008200
CM ² Y	15,54663157	0,00008700
Y ³ M	13,34626177	0,00027452
CY	12,81429326	0,00036313
M ² Y	12,49362503	0,00043000
M ³ C	11,98032114	0,00056398
Y ⁴	11,74524900	0,00063876
Y ²	9,70560290	0,00189766
CMY ²	8,15399009	0,00439947
CM	5,82475055	0,01600910
Y ⁵	4,30504358	0,03829467
C ³ MY	3,65461752	0,05624415
M ² C	2,49824908	0,11433852
C ²	2,16366123	0,14167131
Odsječak	1,18348945	0,27694978

Korak 5: eliminacija člana C²

C	254,38417445	0,00000000
Y ³ M ²	120,91711886	0,00000000
C ³ M	78,42714699	0,00000000
C ³ Y	73,54581583	0,00000000
CMY ³	73,01045932	0,00000000
M ³	72,41032559	0,00000000
C ² Y	63,74868230	0,00000000
Y	63,17734913	0,00000000
M ⁴	63,03071848	0,00000000
C ³ M ²	62,80153729	0,00000000
C ³	62,17962339	0,00000000
C ² MY	61,94350154	0,00000000
M ³ C ²	61,85586996	0,00000000
M ⁴ C	59,83380752	0,00000000
M ²	55,42952641	0,00000000
Y ⁴ M	50,15628580	0,00000000
Y ² M	49,15273312	0,00000000
C ⁴	45,46455724	0,00000000
M ⁵	44,67220585	0,00000000
M ³ Y	36,52594596	0,00000000
C ² M	35,43215622	0,00000000
C ⁵	30,77008671	0,00000004
C ² M ² Y	29,98867594	0,00000006
Y ⁴ C	27,68850821	0,00000018
CM ² Y ²	26,50939188	0,00000032

C ⁴ Y	25,72266150	0,00000048
MY	24,39120165	0,00000094
C ² MY ²	22,56647897	0,00000238
Y ³ C	21,77394534	0,00000355
M	21,47716322	0,00000413
CY	21,38226166	0,00000434
C ³ Y ²	21,32173403	0,00000447
M ³ Y ²	21,21062589	0,00000473
M ² Y ²	20,75353087	0,00000597
C ² Y ²	18,98641286	0,00001474
M ⁴ Y	18,34116714	0,00002053
C ² M ²	18,31862825	0,00002077
Y ³	17,71016829	0,00002841
CM ³ Y	17,19922929	0,00003697
CMY	15,24683611	0,00010167
Y ⁴	13,56373239	0,00024490
M ³ C	12,89269051	0,00034842
CM ² Y	12,75236354	0,00037515
M ² Y	12,45062504	0,00043984
Y ³ M	12,11845510	0,00052421
Y ²	10,71579772	0,00110435
CMY ²	8,89298689	0,00294290
CM	6,75373890	0,00951422
Y ⁵	5,40332977	0,02032881
C ³ MY	2,84577967	0,09197428
M ² C	1,91567204	0,16669114
Odsječak	0,57173329	0,44977660
Korak 6: eliminacija člana M²C		

Tabela B.6, Odstupanje reduciranog modela od empirijskih podataka, proces D

	N - broj polja	dEab	Min	Medijan	Maks	Int. pouz. 95%
RGB->D	918	2,46	0,12	2,24	8,82	0,18

Reducirani model:

1 C M Y CM MY CY M² Y² CMY C²M M²Y C²Y Y²M C³ M³ Y³ C²MY
 CM²Y CMY² C²M² M²Y² C²Y² C³M M³Y Y³C C³Y M³C Y³M C⁴ M⁴ Y⁴ C²M²Y
 C²MY² CM²Y² C³MY CM³Y CMY³ C³M² M³Y² C³Y² M³C² Y³M² M⁴Y Y⁴C C⁴Y
 M⁴C Y⁴M C⁵ M⁵ Y⁵

Životopis

Davor Donevski rođen je 1982.g. u Zagrebu gdje je pohađao osnovnu i srednju školu. Diplomirao je 2006.g. na Grafičkom fakultetu Sveučilišta u Zagrebu. Iste je godine zaposlen na Grafičkom fakultetu Sveučilišta u Zagrebu kao asistent na Katedri za tiskarne tehnologije. Od 2007.g. zaposlen je na Grafičkom fakultetu Sveučilišta u Zagrebu kao znanstveni novak na projektu Ministarstva znanosti, obrazovanja i športa Republike Hrvatske. Objavio je šesnaest znanstvenih radova od kojih je trinaest objavljeno na međunarodnim znanstvenim skupovima i tri u znanstvenim časopisima. Dvije je godine sudjelovao u organizaciji međunarodne konferencije Management of Technology – Step to Sustainable Production, MOTSP 2009 i MOTSP 2010 kao član organizacijskog odbora. Njegovo područje interesa obuhvaća kontrolu, osiguranje i upravljanje kvalitetom u grafičkoj proizvodnji.

Popis objavljenih radova

Poglavlja u knjizi

Milčić, Diana; Donevski, Davor; Bota, Josip.

Quality Assessment of JPEG Compressed Images // DAAAM International Scientific Book 2009 /

Katalinić, Branko (ur.).

Beč : DAAAM International Vienna, 2009. Str. 127-134.

Časopisi

1. Donevski, Davor; Milčić, Diana; Banić, Dubravko.

Effect of data scaling on color device model fitting. // *Journal of Industrial Engineering and Management.* **3** (2010) ; 399-407 (članak, znanstveni).

2. Donevski, Davor; Milčić, Diana; Banić, Dubravko.

Model for Implementing TQM in the Graphic Arts Industry. // *Tehnički vjesnik.* **16** (2009) , 1; 31-34 (pregledni rad, znanstveni).

3. Milčić, Diana; Donevski, Davor; Banić, Dubravko.

Integrirani sustavi upravljanja u grafičkoj industriji. // *Poslovna izvrsnost.* **2** (2008) , 1; 63-71 (pregledni rad, znanstveni).

Međunarodni skupovi

1. Donevski, Davor.

The Selection of Optimal Polynomial Device Model // *The CREATE 2010 Conference* / Simone, Gabriele ; Hardeberg, Jon Yngve ; Farup, Ivar (ur.). Gjovik, Norveška, 2010. 99-101 (poster,međunarodna recenzija,objavljeni rad,znanstveni).

2. Donevski, Davor; Milčić, Diana; Anić, Dominik.

A STUDY OF SAMPLE CHOICE INFLUENCE ON THE ESTIMATED COLOR REPRODUCTION SYSTEM

- ACCURACY // Proceedings / 5th International Symposium on Graphic Engineering and Design /**
Nivaković, Dragoljub (ur.).
Novi Sad : Faculty of Technical Sciences, 2010. 187-190 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).
3. Donevski, Davor; Milčić, Diana; Banić, Dubravko.
- DATA ANALYSIS FOR OPTIMAL PRINTER CHARACTERIZATION // MOTSP 2010 Conference Proceedings /** Barić, Gordana ; Đukić, Goran (ur.).
Zagreb : Fakultet strojarstva i brodogradnje Sveučilišta u Zagrebu, 2010. (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).
4. Milčić, Diana; Banić, Dubravko; Donevski, Davor.
Application of Logistics Methods in Print Production // Proceedings ICIL'2010 / Fogliatti de Sinay, Maria Cristina ; Fae, Maria Ines ; Canen, Alberto G. (ur.).
Rio de Janeiro, 2010. 103-109 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).
5. Milčić, Diana; Vučina, Adisa; Donevski, Davor.
Integrating Industrial Ecology into the Print Production Processes // DESIGN 2010 Proceedings / Milčić, D ; Žiljak, V (ur.).
Zagreb, 2010. 1887-1890 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).
6. Donevski, Davor; Milčić, Diana; Banić, Dubravko.
Optimizacija modela izlaznih uređaja u grafičkoj proizvodnji // TMT 2009 Proceedings / Ekinović, S ; Vivancos, J ; Yalcin, S (ur.).
Zenica, 2009. 393-396 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).
7. Milčić, Diana; Donevski, Davor; Banić, Dubravko.
Choosing a Suitable Printer Model // MOTSP 2009 Conference Proceedings / Dolinšek, Slavko ; Đukić, Goran ; Barić, Gordana (ur.).
Zagreb : Faculty of Mechanical Engineering and Naval Architecture Zagreb, Croatia ; Faculty of Management, University of Primorska, Koper, Slovenia, 2009. 50-54 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).
8. Bota, Josip; Milčić, Diana; Donevski, Davor.
Analysis of the Subjective Quality Estimation of Photo Prints With Reduced JPEG Quality // Annals of DAAAM for 2008 & Proceedings / Katalinić, B (ur.).
Beč : DAAAM International Vienna, 2008. 149-150 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).
9. Donevski, Davor; Banić, Dubravko; Milčić, Diana.
PRIMJENA METODA STATISIČKE KONTROLE PROCESA NA PROCESE GRAFIČKE PROIZVODNJE // GRID '08 zbornik radova / Novaković, D (ur.).
Novi Sad : FAKULTET TEHNIČKIH NAUKA GRAFIČKO INŽENJERSTVO I DIZAJN, 2008. 223-226 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).
10. Majnarić, Igor; Cigula, Tomislav; Donevski, Davor.
Influence of the Electrophotographic Printing Units Arrangement on Back-trap Mottling // Proceedings of the 12th International Conference on Printing, Design and Graphic Communications Blaž Baromić / Bolanča, Zdenka (ur.).
Zagreb ; Ljubljana ; Senj : University of Zagreb Faculty of Graphic Arts ; University of Ljubljana,

Faculty of Natural Science and Engineering ; Pulp and Paper Institute ; Ogranak Matice hrvatske Senj, 2008. 121-125 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).

11. Milčić, Diana; Banić Dubravko; Donevski Davor.

The Effective vibration speed of web offset press // IMEKO 20th TC3, 3rd TC 16 and 1st TC International Conference.

(poster,međunarodna recenzija,objavljeni rad,znanstveni).

12. Bota, Josip; Milčić, Diana; Donevski, Davor.

QUALITY OF PHOTOGRAPHIC REPRODUCTION AND COMPARISON OF DIGITAL PHOTO STUDIOS

// 11th INTERNATIONAL CONFERENCE OF PRINTING, DESIGN AND GRAPHIC COMMUNICATIONS

Blaž Baromić / Prof. Zdenka Bolanča Ph.D. (ur.).

Zagreb : Faculty of Graphic Arts, 2007. 167-171 (poster,međunarodna recenzija,objavljeni rad,znanstveni).

13. Donevski, Davor; Milčić, Diana; Golubović, Kristijan.

ANALYSIS OF MODERN PROCESS MANAGEMENT SYSTEMS IN THE PRINTING INDUSTRY // 11th

INTERNATIONAL CONFERENCE OF PRINTING, DESIGN AND GRAPHIC COMMUNICATIONS Blaž

Baromić / Prof. Zdenka Bolanča Ph.D. (ur.).

Zagreb : Faculty of Graphic Arts, 2007. 43-45 (poster,međunarodna recenzija,objavljeni rad,znanstveni).

Sažeci u zbornicima skupova

1. Donevski, Davor; Milčić, Diana; Banić, Dubravko; Čosić, Predrag.

Implementation of tqm in the print production processes // International Conference on Industrial Logistics (ICIL 2008) : abstracts / Menipaz, Ehud ; Ben-Gal, Irad ; Bukchin, Yossi (ur.).

Tel Aviv, 2008. 298-298 (predavanje,međunarodna recenzija,sažetak,znanstveni).

2. Majnarić, Igor; Golubović, Kristijan; Donevski, Davor.

THE INFLUENCE OF ELECTROPHOTOGRAPHIC DIODE LASER ON DURABILITY OF ORGANIC

PHOTOCONDUCTORS // Abstracts Book the International Conference MATRIB 2007 / Grilec, Krešimir (ur.).

Zagreb : Hrvatsko društvo za materijale i tribologiju, 2007. 313-322 (poster,međunarodna recenzija,sažetak,znanstveni).

Druge vrste radova

Milčić, Diana; Borković, Jakov; Donevski, Davor.

Program i aktivnosti implementacije sustava upravljanja kvalitete u tiskaru, 2009. (elaborat).