Predviđanje trajanja servisnog razdoblja krava prema količini i sastavu mlijeka na početku laktacije

Solić, Dragan

Doctoral thesis / Disertacija

2015

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj:
Josip Juraj Strossmayer University of Osijek, Faculty of Agrobiotechical Sciences Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet agrobiotehničkih znanosti Osijek

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:151:708844

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-20**

Sveučilište Josipa Jurja Strossmayera u Osijeku
Fakultet agrobiotehničkih znanosti Osijek

Repository / Repozitorij:

Repository of the Faculty of Agrobiotechnical Sciences Osijek - Repository of the Faculty of Agrobiotechnical Sciences Osijek

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

REPUBLIKA HRVATSKA
SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA
U OSIJEKU
POLJOPRIVREDNI FAKULTET U OSIJEKU

Dragan Solić, dipl.ing.

PREDVIĐANJE TRAJANJA SERVISNOG RAZDOBLJA KRAVA PREMA KOLIČINI I SASTAVU MLIJEKA NA POČETKU LAKTACIJE

DOKTORSKI RAD

Osijek, 2015.

REPUBLIKA HRVATSKA
SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA
U OSIJEKU
POLJOPRIVREDNI FAKULTET U OSIJEKU

Dragan Solić, dipl.ing.

PREDVIĐANJE TRAJANJA SERVISNOG RAZDOBLJA KRAVA PREMA KOLIČINI I SASTAVU MLIJEKA NA POČETKU LAKTACIJE

- Doktorski rad -

Osijek, 2015.

REPUBLIKA HRVATSKA
SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA
U OSIJEKU
POLJOPRIVREDNI FAKULTET U OSIJEKU

Dragan Solić, dipl.ing.

PREDVIĐANJE TRAJANJA SERVISNOG RAZDOBLJA KRAVA PREMA KOLIČINI I SASTAVU MLIJEKA NA POČETKU LAKTACIJE

- Doktorski rad -

Mentor: izv.prof.dr.sc. Vesna Gantner

Povjerenstvo za ocjenu:

1. **dr.sc. Pero Mijić, redoviti profesor Poljoprivrednog fakulteta u Osijeku, predsjednik**
2. **dr.sc. Vesna Gantner, izvanredni profesor Poljoprivrednog fakulteta u Osijeku, mentor i član**
3. **dr.sc. Marcela Šperanda, redoviti profesor Poljoprivrednog fakulteta u Osijeku, član**

Osijek, 2015.

REPUBLIKA HRVATSKA
SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA
U OSIJEKU
POLJOPRIVREDNI FAKULTET U OSIJEKU

Dragan Solić, dipl.ing.

PREDVIĐANJE TRAJANJA SERVISNOG RAZDOBLJA KRAVA PREMA KOLIČINI I SASTAVU MLIJEKA NA POČETKU LAKTACIJE

- Doktorski rad -

Mentor: izv.prof.dr.sc. Vesna Gantner

Javna obrana doktorske disertacije je održana 6. veljače 2015. godine pred Povjerenstvom za obranu:

1. **dr.sc. Pero Mijić, redoviti profesor Poljoprivrednog fakulteta u Osijeku, predsjednik**
2. **dr.sc. Vesna Gantner, izvanredni profesor Poljoprivrednog fakulteta u Osijeku, mentor i član**
3. **dr.sc. Marcela Šperanda, redoviti profesor Poljoprivrednog fakulteta u Osijeku, član**

Osijek, 2015.

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište Josipa Jurja Strossmayera u Osijeku

Doktorski rad

Poljoprivredni fakultet u Osijeku
Poslijediplomski doktorski studij: Poljoprivredne znanosti
Smjer: Specijalno stočarstvo
UDK:
Znanstveno područje: Biotehničke znanosti
Znanstveno polje: Poljoprivreda
Grana: Stočarstvo

Predviđanje trajanja servisnog razdoblja krava prema količini i sastavu mlijeka na početku laktacije

Dragan Solić, dipl.ing.

Rad je izrađen na Poljoprivrednom fakultetu Sveučilišta Josipa Jurja Strossmayera u Osijeku
Mentor: izv.prof.dr.sc. Vesna Gantner

Sažetak

Ciljevi su ovoga istraživanja bili determinirati značajne utjecaje na trajanje razdoblja od teljenja do koncepcije (servis razdoblje), zatim utvrditi povezanost između trajanja servis razdoblja i svojstava rezultata provedbe kontrole mliječnosti te razviti sustav predviđanja trajanja servis razdoblje temeljem rezultata kontrole mliječnosti na početku laktacije (prve dvije kontrole) u populaciji holstein i simentalske pasmine krava. Statističkom obradom metodom analize preživljavanja i metodom logističke regresije obuhvaćeno je 14.864 krave holstein pasmine s ukupno 29.278 zapisa rezultata kontrole mliječnosti, te 18.708 krava simentalske pasmine s ukupno 37.416 zapisa rezultata kontrole mliječnosti. Vrijednosti koeficijenata korelacija između trajanja servis razdoblja i svojstava rezultata provedbe kontrole mliječnosti kretale su se unutar raspona ±0,00 do ±0,20 što upućuje na njihovu zanemarivu povezanost. Veća vjerojatnost koncepcije po svim razredima trajanja servis razdoblja u simentalske u odnosu na holstein pasminu utvrđena je analizom kretanja krivulje preživljavanja trajanja servis razdoblja. Provedbom logističke regresije izrađena su dva statistička modela. Model 1. koji uključuje varijable rezultata provedbe kontrole mliječnosti zasebno za svaku pasminu i svaki kontrolni dan. Model 2. koji pored varijabli iz prvog modela uključuje i utjecaje regije, sezone i veličine stada, rednog broja teljenja, sezone koncepcije i sezone teljenja. Ispitivanje snage modela za predviđanje događaja prikazano je pomoću indeksa konkordacije koji predstavlja sukladnost slaganja registriranih i predviđenih podataka unutar svakog modela. Utvrđeno je povećanje vrijednosti indeksa konkordacije za svaki model s većim rednim brojem u odnosu na početni model kao i povećanje vrijednosti indeksa konkordacije za kontrolni dani 2. u odnosu na kontrolni dan 1. kod obje promatrane pasmine.

Broj stranica: 147
Broj slika: 12
Broj tablica: 55
Broj grafikona: 25
Broj literaturnih navoda: 240
Jezik izvornika: hrvatski

Ključne riječi: servis razdoblje, rezultati kontrole mliječnosti, holstein i simentalska pasmina, predviđanje
Datum obrane: 6.veljače 2015

Povjerenstvo za obranu:
1. prof.dr.sc. Pero Mijić – predsjednik
2. izv.prof.dr.sc. Vesna Gantner – član i mentor
3. prof.dr.sc. Marcela Šperanda – član

Rad je pohranjen u: Sveučilište Josipa Jurja Strossmayera u Osijeku

BASIC DOCUMENTATION CARD

Josip Juraj Strossmayer , University in Osijek

PhD thesis

Faculty of Agriculture in Osijek
Postgraduate study: Agricultural sciences
Course: Animal of Science
UDK:
Scientific Area: Biotechnical Sciences
Scientific Field: Agriculture
Branch: Livestock husbandry

Prediction of service period duration of cows according to milk yield and composition in early lactation

Dragan Solić, dipl.ing.

Thesis was performed on Faculty of Agriculture in Osijek, Josip Juraj Strossmayer University in Osijek
Mentor: PhD Vesna Gantner, Associate Professor

Summary

The objectives of this research were to determine significant effects on the duration of the period from calving to conception (service period), then the relationship between the duration of the service periods and the traits recorded during the milk recording and develop a system of predicting the duration of service period based on the results milk recording in early lactation (the first two control) in a population of Holstein and Simmental cows, which would consequently increase competitiveness and financial performance of the farm. Statistical analysis using survival analysis and logistic regression method included 14,864 Holstein cows with a total of 29,278 milk recording records, and 18,708 Simmental cows with a total of 37,416 milk recording records. Correlation coefficient values were within the range ± 0.00 to ± 0.20 which indicates a negligible correlation between the duration of the service periods and the traits recorded during the milk recording. Higher conception probability at all classes of duration of service periods in the Simmental compared to the Holstein breed was determined using the analysis of movement survival curves for duration of service period. Based on results of logistic regression two statistical models were created. Model 1 includes traits recorded during the milk recording separately for each breed and each test day. Model 2 besides traits from model 1 also included effects of region, season of recording, herd size classes, parity, season of conception and season of calving. The power testing of models for prediction of incident was shown using the concordance index which represents the compliance agreement of recorded and predicted data within each model. The increase of the concordance index value was determined for each model with a higher number in comparison to the initial model. Additionally, the increase of the concordance index value was determined for control day 2 compared to the control day 1 for both analysed breeds.

Number of pages: 147
Number of figures: 12
Number of tables: 55
Number of charts: 25
Number of references: 240
Original in: Croatian

Key words: Service period, milk recording records, Holstein and Simmental breed, prediction

Date of thesis defence: February 6th, 2015

Reviewers:
1. PhD Pero Mijić, Full Professor – president
2. PhD Vesna Gantner, Associate Professor – member and mentor
3. PhD Marcela Šprenada, Full Professor – member

Thesis deposited in: Josip Juraj Strossmayer , University in Osijek

KAZALO

		Str.
Popis tablica		VI
Popis grafikona		IX
Popis slika		XI
1.	**UVOD**	**1**
1.1.	PREGLED LITERATURE	3
1.1.1.	KONTROLA PROIZVODNOSTI	3
1.1.2.	PRIKAZ STANJA GOVEDARSKE PROIZVODNJE U REPUBLICI HRVATSKOJ	11
1.1.3.	GRAĐA MLIJEČNE ŽLIJEZDE	20
1.1.4.	MLIJEČNA MAST	22
1.1.5.	MLIJEČNI PROTEIN	25
1.1.6.	UREJA U MLIJEKU	28
1.1.7.	LAKTOZA U MLIJEKU	31
1.1.8.	SOMATSKE STANICE	34
1.1.9.	TRANZICIJSKO RAZDOBLJE I NEGATIVNA ENERGETSKA RAVNOTEŽA	38
1.1.10.	LAKTACIJSKA KRIVULJA	42
1.1.11.	MJERILA REPRODUKCIJSKE USPJEŠNOSTI	45
1.2.	CILJ ISTRAŽIVANJA	49
2.	**MATERIJAL I METODE**	**50**
2.1.	MATERIJAL	50
2.2.	PRIPREMA PROIZVODNIH PODATAKA	50
2.3.	KONTROLA MLIJEČNOSTI	53
2.4.	ANALIZA UZORAKA MLIJEKA	54
2.5.	STATISTIČKA OBRADA PODATAKA	55
2.6.	STATISTIČKI MODELI	57

2.7. ISPITIVANJE SUKLADNOSTI ISPITVANIH MODELA 59

2.8. ISPITIVANJE MOGUĆNOSTI MODELA ZA PREDVIĐANJE 60

3. REZULTATI ISTRAŽIVANJA I RASPRAVA 61

3.1. VARIJABILNOST KOLIČINE I SASTAVA MLIJEKA PO KONTROLNOM DANU 61

3.1.1. OPISNA STATISTIKA ODNOSA MASTI I BJELANČEVINA U MLIJEKU 63

3.1.2. VARIJABILNOST ODNOSA BJELANČEVINA I UREJE U MLIJEKU 65

3.1.3. VARIJABILNOST KOLIČINE I SASTAVA MLIJEKA PO SEZONAMA 67

3.1.4. VARIJABILNOST TRAJANJA SERVIS RAZDOBLJA 72

3.1.5. VARIJABILNOST UDELA KONCEPCIJA I TELJENJA PO SEZONAMA 75

3.1.6. VARIJABILNOST UDJELA KRAVA PO RAZREDIMA VELIČINE STADA 76

3.1.7. VARIJABILNOST UDJELA KRAVA PO REGIJAMA 78

3.2. KORELACIJA TRAJANJA SERVIS RAZDOBLJA I REZULTATA PROVEDBE KONTROLE MLIJEČNOSTI 80

3.2.1 KORELACIJA TRAJANJA SERVIS RAZDOBLJA I REZULTATA PROVEDBE KONTROLE MLIJEČNOSTI 84

3.3. REZULTATI ANALIZE TRAJANJA SERVIS RAZDOBLJA METODOM LOGISTIČKE REGRESIJE 86

3.3.1. MODEL 1. – REZULTATI KONTROLE MLIJEČNOSTI 86

3.3.1.1. REZULTATI LOGISTIČKE REGRESIJE ZA MODEL 1. i KONTROLNI DAN 1. HOLSTEIN PASMINE 87

3.3.1.2. REZULTATI LOGISTIČKE REGRESIJE ZA MODEL1. i KONTROLNI DAN 2. HOLSTEIN PASMINE 88

3.3.1.3. REZULTATI LOGISTIČKE REGRESIJE ZA MODEL 1. i KONTROLNI DAN 1. SIMENTALSKE PASMINE 89

3.3.1.4. REZULTATI LOGISTIČKE REGRESIJE ZA MODEL 1. i KONTROLNI DAN 2. SIMENTALSKE PASMINE 91

3.3.2.. MODEL 2. – REZULTATI KONTROLE MLIJEČNOSTI UZ KLASIFIKACIJSKE VARIJABLE 92

3.3.2.1. REZULTATI LOGISTIČKE REGRESIJE ZA. MODEL 2 i KONTROLNI DAN 1. HOLSTEIN PASMINE 93

3.3.2.2. REZULTATI LOGISTIČKE REGRESIJE ZA MODEL 2 i KONTROLNI DAN 2. HOLSTEIN PASMINE 96

3.3.2.3. REZULTATI LOGISTIČKE REGRESIJE ZA MODEL 2. i KONTROLNI DAN 1. SIMENTALSKE PASMINE 98

3.3.2.4. REZULTATI LOGISTIČKE REGRESIJE ZA MODEL 2. i KONTROLNI DAN 2 SIMENTALSKE PASMINE 101

3.4. ANALIZA PREŽIVLJAVANJA TRAJANJA SERVIS RAZDOBLJA 106

3.4.1. ANALIZA PREŽIVLJAVANJA TRAJANJA SERVIS RAZDOBLJA PO PASMINAMA 106

3.4.2. ANALIZA PREŽIVLJAVANJA TRAJANJA SERVIS RAZDOBLJA PO REGIJAMA 108

3.4.3. ANALIZA PREŽIVLJAVANJA TRAJANJA SERVIS RAZDOBLJA PO VELIČINI STADA 111

3.4.4. ANALIZA PREŽIVLJAVANJA TRAJANJA SERVIS RAZDOBLJA PO SEZONI KONCEPCIJE 114

3.4.5. ANALIZA PREŽIVLJAVANJA TRAJANJA SERVIS RAZDOBLJA PO SEZONI TELJENJA 117

4. ZAKLJUČCI 120

5. LITERATURA 123

6. SAŽETAK 143

7. SUMMARY 145

8. ŽIVOTOPIS 147

POPIS TABLICA

Str.

Tablica 1.: Početak provedbe kontrole mliječnosti *(http://www.icar.org* ; HPA,2013) 5

Tablica 2.: Popis metoda kontrole mliječnosti (ICAR, 2012.) 6

Tablica 3.: Oznake broja mužnji tijekom dana (ICAR, 2012.) 7

Tablica 4.: Metode kontrole mliječnosti u odabranim članicama ICAR-a *(http://www.icar.org*) 7

Tablica 5.: Troškovi provedbe kontrole mliječnosti po odabranim zemljama članicama ICAR-a *(http://www.icar.org*) 8

Tablica 6.: Kretanje broja krava (HPA,2014.) 12

Tablica 7.: Količine otkupljenog mlijeka i distribucija broja krava po županijama (HPA, 2014.) 13

Tablica 8.: Broj krava po pasminama (HPA, 2014.) 15

Tablica 9.: Distribucija udjela gospodarstava i krava prema veličini stada (HPA, 2014.) 17

Tablica 10.: Struktura isporučenih količina mlijeka po isporučiteljima (HPA,2014.) 18

Tablica 11.: Brojno stanje mliječnih farmi, krava i otkupa mlijeka po farmi u odabranim zemljama i prosječan broj u Europskoj uniji *(http://epp.eurostat.ec.europa)* 19

Tablica 12.: Prikaz koncentracije proteinskih frakcija u mlijeku (Bylund,2003) 25

Tablica 13.: Distribucija laktacijskih krivulja (Gelebieewski i sur., 2011) 43

Tablica 14.: Prikaz čimbenika i njihovog utjecaja na reprodukcijske rezultate (Kumlu,2012.) 46

Tablica 15.: Prikaz vremenski definiranih reprodukcijskih pokazatelja (Wattiaux,1995.) 47

Tablica 16.: Prikaz ekonomski prihvatljivih pokazatelja reprodukcijske učinkovitosti (Inchraisry,2010.) 47

Tablica 17.: Kriteriji razvrstavanja u razrede omjera mliječne masti i bjelančevina 51

Tablica 18.: Kriteriji razvrstavanja u razrede odnosa mliječnih bjelančevina i ureje 51

Tablica 19.: Kriteriji razdiobe servis razdoblja 52

Tablica 20.: Razvrstavanje županija u proizvodne regije 52

Tablica 21.: Kriteriji razvrstavanja stada prema broju krava u stadu 53

Tablica 22.: Granice dnevnih vrijednosti (ICAR, 2012.) 54

Tablica 23.: Statistički modeli za procjenu trajanja servis razdoblja za holstein pasminu 57

Tablica 24.: Statistički modeli za procjenu trajanja servis razdoblja za simentalsku pasminu 58

Tablica 25.: AIC vrijednosti za modele po kontrolnim danima 59

Tablica 26.: Vrijednosti R^2 za modele po kontrolnim danima 59

Tablica 27.: Odnosa snage modela za predviđanje i stvarno utvrđenih događaja 60

Tablica 28.: Varijabilnost dnevne količine i sastava mlijeka krava ovisno o rednom broju kontrole za holstein pasminu 61

Tablica 29.: Varijabilnost dnevne količine i sastava mlijeka krava ovisno o rednom broju kontrole za simentalsku pasminu 62

Tablica 30.: Udio krava po pojedinim razredima omjera masti i bjelančevina (IMB) u mlijeku ovisno o kontrolnom danu i pasmini 63

Tablica 31.: Udio krava po pojedinim razredima omjera masti i bjelančevina (IMB) u mlijeku ovisno o sezoni i pasmini 64

Tablica 32.: Udio krava u pojedinom razredu odnosa bjelančevina i ureje (IBU) u mlijeku ovisno o kontrolnom dani i pasmini 65

Tablica 33.: Udio krava u pojedinom razredu odnosa bjelančevina i ureje (IBU) u mlijeku ovisno o sezoni i pasmini 66

Tablica 34.: Varijabilnost dnevne količine i sastava mlijeka krava ovisno o sezoni za ovisno o sezoni za holstein pasminu 68

Tablica 35.: Varijabilnost dnevne količine i sastava mlijeka krava ovisno o sezoni za simentalsku pasminu 70

Tablica 36.: Broj i udio krava po razredima trajanja servis razdoblja za holstein pasminu 72

Tablica 37.: Broj i udio krava po razredima trajanja servis razdoblja za simentalsku pasminu 73

Tablica 38.: Broj i udio stada i krava po razredima veličine stada za holstein pasminu 77

Tablica 39.: Broj i udio stada i krava po razredima veličine stada za simentalsku pasminu 77

Tablica 40.: Broj i udio stada i krava po regijama za holstein pasminu 79

Tablica 41.: Broj i udio stada i krava po regijama za simentalsku pasminu 79

Tablica 42.: Korelacija trajanja servis razdoblja i svojstava mliječnosti za holstein pasminu 80

Tablica 43.: Korelacija trajanja servis razdoblja i svojstava mliječnosti za simentalsku pasminu 81

Tablica 44.: Korelacija između pojedinih svojstava mliječnosti za holstein pasminu 84

Tablica 45.: Korelacija između pojedinih svojstava mliječnosti za simentalsku pasminu 85

Tablica 46.: Odabrane varijable po pasminama i kontrolnim danima za model 1. 86

Tablica 47.: Rezultati logističke regresije za model 1. i kontrolni dan 1. holstein pasmine 87

Tablica 48.: Rezultati logističke regresije za model 1. i kontrolni dan 2. holstein pasmine 88

Tablica 49.: Rezultati logističke regresije za model 1. i kontrolni dan 1. simentalske pasmine 90

Tablica 50.: Rezultati logističke regresije za model 1. i kontrolni dan 2. simentalske pasmine 91

Tablica 51.: Odabrane varijable po pasminama i kontrolnim danima za model 2. 93

Tablica 52.: Rezultati logističke regresije za model 2. i kontrolni dan 1. holstein pasmine 94

Tablica 53.: Rezultati logističke regresije za model 2. i kontrolni dan 2. holstein pasmine 96

Tablica 54.: Rezultati logističke regresije za model 2. i kontrolni dan 1. simentalske pasmine 99

Tablica 55.: Rezultati logističke regresije za model 2. I kontrolni dan 2. simentalske pasmine 101

POPIS GRAFIKONA

Grafikon 1.: Kretanje broja goveda *(http://www.dzs.hr)* 11

Grafikon 2.: Proizvodnja mlijeka po pasminama u razdoblju 2005. – 2013. (HPA, 2014) 14

Grafikon 3.: Kretanja broja isporučitelja i otkupljenih količina mlijeka (HPA, 2014.) 16

Grafikon 4.: Varijabilnost količine i kvalitete mlijeka ovisno o stanju i redoslijedu laktacije (Madousse, 2009) 43

Grafikon 5.: Distribucija trajanja servis razdoblja za holstein pasminu 73

Grafikon 6.: Distribucija trajanja servis razdoblja za simentalsku pasminu 74

Grafikon 7.: Udio koncepcija i teljenja za holstein pasminu 75

Grafikon 8.: Udio koncepcija i teljenja za simentalsku pasminu 76

Grafikon 9.: Prikaz omjera vjerojatnosti s 95% Waldovim intervalom povjerenja za model 1. kontrolni dan 1. holstein pasmine 88

Grafikon 10.: Prikaz omjera vjerojatnosti s 95% Waldovim intervalom povjerenja za model 1. i kontrolni dan 2. holstein pasmine 89

Grafikon 11.: Prikaz omjera vjerojatnosti s 95% Waldovim intervalom povjerenja za model 1.i kontrolni dan 1. simentalske pasmine 90

Grafikon 12.: Prikaz omjera vjerojatnosti s 95% Waldovim intervalom povjerenja za model 1. i kontrolni dan 2. simentalske pasmine 92

Grafikon 13.: Prikaz omjera vjerojatnosti s 95% Waldovim intervalom povjerenja za model 2. i kontrolni dan 1. holstein pasmine 95

Grafikon 14.: Prikaz omjera vjerojatnosti s 95% Waldovim intervalom povjerenja za model 2 i kontrolni dan 2. holstein pasmine 97

Grafikon 15.: Prikaz omjera vjerojatnosti s 95% Waldovim intervalom povjerenja za model 2. i kontrolni dan 1. simentalske pasmine 100

Grafikon 16.: Prikaz omjera vjerojatnosti s 95% Waldovim intervalom povjerenja za model 2. i kontrolni dan 2. simentalske pasmine 102

Grafikon 17.: Kaplan Meirova krivulja preživljavanja trajanja servis razdoblja po pasminama 107

Grafikon 18.: Kaplan Meirova krivulja preživljavanja trajanja servis razdoblja po regijama za holstein pasminu 108

Grafikon 19.: Kaplan Meirova krivulja preživljavanja trajanja servis razdoblja po regijama za simentalsku pasminu 109

Grafikon 20.: Kaplan Meirova krivulja preživljavanja trajanja servis razdoblja po razredima veličine stada za holstein pasminu 111

Grafikon 21.: Kaplan Meirova krivulja preživljavanja trajanja servis razdoblja po razredima veličine stada za simentalsku pasminu 112

Grafikon 22.: Kaplan Meirova krivulja preživljavanja trajanja servis razdoblja po sezonama koncepcije za holstein pasminu 114

Grafikon 23.: Kaplan Meirova krivulja preživljavanja trajanja servis razdoblja po sezonama koncepcije za simentalsku pasminu 115

Grafikon 24.: Kaplan Meirova krivulja preživljavanja trajanja servis razdoblja po sezonama teljenja za holstein pasminu 117

Grafikon 25.: Kaplan Meirova krivulja preživljavanja trajanja servis razdoblja po sezonama teljenja za simentalsku pasminu 118

POPIS SLIKA

Slika 1.: Potporni sustav vimena (Bačić, 2009.) 20

Slika 2.: Presjek četvrti vimena (Bačić, 2009.) 21

Slika 3.: Prikaz strukture mliječne masti (Tratnik, 2012.) 22

Slika 4.: Sinteza masnih kiselina (Grubić, 2007.) 23

Slika 5.: Prikaz biosinteze bjelančevina *(http://www.pmfst.hr)* 26

Slika 6.: Prikaz micele kazeina (Byllund, 2003.) 26

Slika 7.: Prikaz metabolizma dušika (Kohn, 2003.) 29

Slika 8.: Prikaz sinteze laktoze (Stelwagen, 2011.) 31

Slika 9.: Pregled regulacije izlučivanja mlijeka. (Wattiaux, 1995.) 33

Slika 10.: Prikaz neutrofila *(http://www.sciencephoto.com)* 34

Slika 11.: Obrana vimena (Wattiaux, 1995.) 35

Slika 12.: Prikaz tranzicijskog razdoblja (Prema Drackley, 2011) 38

Iskreno se zahvaljujem na pruženoj potpori tijekom trajanja cjelokupnog doktorskog studija , a posebice prilikom odabire teme te pisanja doktorskog rada mentorici izv. prof. dr.sc. Vesni Gantner.

Zahvaljujem se članovima povjerenstva za ocjenu i obranu doktorskog rada, prof.dr.sc. Marceli Špreandi i prof.dr.sc. Peri Mijiću na susretljivosti i pruženim savjetima.

Zahvaljujem se djelatnicima Hrvatske poljoprivredne agencije koji su sudjelovali u provedbi terenskih istraživanja i laboratorijskoj analitici te svim vlasnicima poljoprivrednih gospodarstava na čijim gospodarstvima su provođena istraživanja.

Zahvaljujem se kolegici Mariji Špehar u pripremi podataka za statističku obradu, no posebnu zahvalnost iskazujem kolegici Maji Dražić koja je nesebično darovala vrijeme i strpljivost pomažući mi u statističkoj obradi podataka.

Zahvaljujem se kolegi Dragi Bagariću na dugogodišnjoj podršci u primjeni rezultata kontrole mliječnosti kod uzgajivača goveda.

Zahvaljujem se svojim roditeljima Marku i Ani na bezgraničnoj podršci tijekom studiranja. Nažalost, moj otac nije doživio ovaj trenutak, ali znam….

I na kraju, bezgranično veliko hvala mojoj obitelji: supruzi Ivani, kćeri Petri i sinu Blažu na ljubavi i strpljivosti pruženoj kroz sve vrijeme izrade doktorskog rada.

Dragan Solić

1. UVOD

Govedarska proizvodnja u Republici Hrvatskoj se danas nalazi pred nekoliko naizgled teško spojivih i ostvarivih činjenica: sniženje cijena proizvoda, povećani izdaci za osiguranje uvjeta smještaja vezanih za dobrobit životinja, povećani izdaci zbog očuvanja okoliša te sve veći pritisak javnosti na sigurnost proizvodnje i zaštitu potrošača. Pored toga proizvodnja mlijeka izložena je dodatnom pritisku nepovoljnih odnosa ulaznih troškova i promjenama u sustavu potpora što dovodi do stalnog smanjenja broja krava.

Smanjenje broja goveda u Republici Hrvatskoj, a posebice broja krava kontinuirano traje već trideset godina. U razdoblju od 1980. godine do 2014. godine broj goveda je smanjen za dvostruko odnosno sa početnih 977 tisuća na sadašnjih 442 tisuća. Posebice se ističe pad broja goveda u 1991. i 1992. godini kao posljedica ratnih razaranja koja su zahvatila Republiku Hrvatsku. Najveći pad broja krava dogodio se u razdoblju od 1990. godine do 1995. godine, kada je s 830 tisuća broj goveda smanjen na 493 tisuće.

Govedarska proizvodnja u Hrvatskoj temelji se na uzgoju mliječnih (holstein) i kombiniranih pasmina (simentalska i smeđa) koje čine 90% svih krava u Hrvatskoj. Holstein pasmina ima veću proizvodnju mlijeka u standardnoj laktaciji, a onda slijedi smeđa i simentalska pasmina.

Nekoliko je nepovoljnih značajki proizvodnje mlijeka u Hrvatskoj koje imaju utjecaj na njenu ekonomsku uspješnost. Naglašen utjecaj ima neadekvatna struktura, odnosno niska prosječna veličina stada od 6 krava uz isporuku 40.497 kg mlijeka po farmi. Primjerice oko 76% gospodarstava drži do 5 krava što je svega 27,2 % ukupnog broja krava dok se 12% krava nalazi na svega 0,3% gospodarstava.

Posljednjih desetljeća došlo je do značajnog povećanja proizvodnje mlijeka po kravi. Povećanje proizvodnje mlijeka po kravi rezultat je selekcijskog napretka, hranidbe, smještaja te modernog sustava upravljanja cjelokupnom proizvodnjom na mliječnim farmama. Produkcija mlijeka i reproduktivne karakteristike mliječnih krava od fundamentalne su važnosti za profitabilno poslovanje mliječne farme. Međutim, istovremeno s povećanjem prosječne proizvodnje mlijeka po kravi dogodilo se i narušavanje rezultata u reprodukcijskoj uspješnosti. Dugi niz godina smatralo se da je upravo visoka proizvodnja mlijeka po kravi u antagonizmu s reprodukcijskim uspjehom. Istraživanja provedena unazad nekoliko godina osporavaju ovu, donedavno, opće prihvaćenu činjenicu te su dokazala da krave s visokom proizvodnjom mlijeka mogu imati

dobre reprodukcijske rezultate. Ovime je dovedeno u pitanje opće prihvaćena činjenica o povezanosti visoke proizvodnje mlijeka i loših reprodukcijskih rezultata grla.

Uspješnost reprodukcije na mliječnim farmama očituje se u učinkovitom generiranju dovoljnog broja bređih krava kako bi se zadržala proizvodnja na željenom nivou ili stvorile pretpostavke za povećanje postojeće proizvodnje. Pored same činjenice o nužnosti nove bređosti za buduću proizvodnju mlijeka, s ekonomskog stajališta iznimno je bitno trajanje razdoblja od teljenja do slijedeće koncepcije ili servis razdoblja. Produženjem trajanja servis razdoblja izvan optimalnih granica povećavaju se troškovi i smanjuju prihodi po kravi na dnevnoj razini, čime se dovodi cjelokupna proizvodnja mlijeka u upitnu ekonomska opravdanost. Američki istraživanja utvrdila su povećanje dnevnog gubitaka zbog produženog servis razdoblja i do 4,95 USA dolara (French i Nebel, 2013.).

Ciljevi su ovoga istraživanja bili determinirati značajne utjecaje na trajanje razdoblja od teljenja do koncepcije (servis razdoblje), zatim utvrditi povezanost između trajanja servis razdoblja i svojstava rezultata provedbe kontrole mliječnosti te razviti sustav predviđanja trajanja servis razdoblje temeljem rezultata kontrole mliječnosti na početku laktacije (prve dvije kontrole) u populaciji holstein i simentalske pasmine krava čime bi se u konačnici povećala konkurentnost i financijski učinak farme.

Utvrđivanje i procjenjivanje trajanja dužine servis razdoblja u vrijeme dok krava još nije bređa, a na osnovu već dostupnih podataka o proizvodnji i sastavu mlijeka u razdoblju tranzicije i početku laktacije, značajno bi poboljšalo upravljanje proizvodnjom mlijeka i podizanje profitabilnosti mliječnih farmi.

1.1. PREGLED LITERATURE

1.1.1. Kontrola proizvodnosti

Kontrola proizvodnosti podrazumijeva utvrđivanje proizvodnih osobina domaćih životinja s ciljem unapređenja njihovog uzgoja. Prema Pravilniku o metodama za ispitivanje osobina i procjenu uzgojnih vrijednosti uzgojno valjanih goveda (NN 134/2005) mjerenje i ocjenjivanje proizvodnih i drugih osobina provodi se zbog utvrđivanja mliječnosti, prirasta, iskorištavanja hrane, kakvoće mesa, vanjštine, plodnosti, dugovječnosti i drugih osobina važnih za genetsku izgradnju goveda. Proizvodni podaci se izražavaju u količini i kvaliteti proizvedenih proizvoda. Kontrola proizvodnosti sastoji se od propisanih metoda mjerenja i obrade dobivenih podataka. Proizvodni podaci su osnova za donošenje te mjerilo uspješnosti provedbe uzgojnih programa.

Podaci dobiveni kontrolom proizvodnosti uz podatke o podrijetlu koriste se pri izračunu uzgojne vrijednosti pojedinog grla. Pored toga, podaci dobiveni kontrolom proizvodnosti sve više se koriste kao pokazatelji upravljanja proizvodnjom cjelokupnog stada.

Proizvodni podaci kod goveda podrazumijevaju informacije o proizvodnji mlijeka i mesa, ovisno o namjeni pasmine (mliječna, mesna ili kombinirana). Međunarodni komitet za kontrolu proizvodnosti (International Committee for Animal Recording – ICAR) preporuča i prikupljanje podataka o funkcionalnim (plodnost, dugovječnost, zdravlje vimena, muznost, tijek teljenja) te eksterijernim osobinama (osobine vanjštine).

Uspostavom "European Committee on Milk-Butterfat Recording" u Hagu u Nizozemskoj (1951.) započelo je međunarodno povezivanje organizacija za kontrolu proizvodnosti. U početnom razdoblju razvijale su se procedure i postupci provedbe kontrole proizvodnosti kod goveda, a nakon toga su obuhvaćene ovce i koze. Proširivanjem provedbe kontrole proizvodnosti na sve životinje držane u farmskim uvjetima prišlo se 1990. godine osnivanju svjetske organizacije pod nazivom International Committee for Animal Recording (ICAR). Godine 1992. objavljuju se prve procedure provedbe kontrole proizvodnosti (International Agreement of Recording Practices) koje su obvezujuće za sve zemlje članice i koje se kontinuirano osuvremenjuju (Crettenand, 1999.).

ICAR je danas međunarodna organizacija za standardizaciju kontrole proizvodnosti i procjene osobina bitnih za gospodarski značaj proizvodnje mlijeka ili mesa. Cilj ICAR-a je promicanje razvoja i unaprjeđenje metoda kontrole proizvodnosti i metoda procjene uzgojnih vrijednosti domaćih životinja, kroz uspostavu definicija i standarda za mjerenje obilježja koje imaju gospodarski značaj. ICAR utvrđuje pravila, standarde i specifične smjernice vezane uz označavanje, evidenciju predaka i potomaka, kontrolu i procjenu proizvodnih osobina te za javnu objavu dobivenih podataka.

Hrvatska je punopravna članica ICAR-a od 1992. godine, a od 2004. godine u potpunosti provodi kontrolu proizvodnosti i procjene uzgojnih vrijednosti prema ICAR-ovim normama. Navedeno se potvrđuje s pravom isticanja ICAR Special Stamp u razdoblju do 2009. godine te ICAR Certificate u razdoblju nakon 2009.

Prvotno se kvaliteta provedbe propisanih normi ocjenjivala kroz usklađenost provedbe sustava označavanja, kontrole proizvodnosti, laboratorijske analitike i metoda izračuna uzgojnih vrijednosti s ICAR-ovim propisima (ICAR Special Stamp). Od 2009. godine ICAR je uveo certificiranje pojedinačnih postupaka praćenja proizvodnosti domaćih životinja.

Područja koja se certificiraju su: označavanje i registracija grla, kontrola mliječnosti, kontrola tovnosti, laboratorijska analitika, obrada podataka i genetske procjene odnosno izračun uzgojnih vrijednosti (ICAR Certificate of Quality).

Kontrola mliječnosti podrazumijeva prikupljanje proizvodnih podataka o mliječnim životinjama (Gantner, 2007.) pomoću kojih se procjenjuje genetska vrijednost pojedinih životinja te upravlja proizvodnjom mlijeka na razini stada (Kompan i sur., 2006.). Hrvatska poljoprivredna agencija provodi kontrolu mliječnosti poštujući propisane norme te ostvaruje pravo na isticanje ICAR-ovog Certifikata kvalitete (Certificate of Quality).

Povijest kontrole mliječnosti seže na kraj 19. stoljeća, ali većina zemalja s naprednim stočarstvom započela je s kontrolom mliječnosti početkom 20. stoljeća (tablica 1.). Kontrola mliječnosti prema ICAR-u započela je u SAD-u 1883. godine, dok je na europskom kontinentu najprije uvedena u Danskoj 1895. Godine.

Početak kontrole mliječnosti u Hrvatskoj veže se uz 1907. godinu, premda je sustavna kontrola započela (1913. godina) nakon osnivanja Saveza marvogojskih udruga (HPA, 2013.). Skori početak prvog svjetskog rata prekinuo je provedbu kontrole

mliječnosti sve do obnove rada Saveza 1929. godine koji ponovno pokreće kontrolu mliječnosti kroz područne udruge uzgajivača. Kontrolu mliječnosti dva puta mjesečno provodili su udruženi povjerenici (stočari) i kontrolni asistenti do 1937. godine, a nakon toga kontrola mliječnosti se radi jednom mjesečno i obavljaju je samo kontrolni asistenti (HPA, 2013.).

Tablica 1.: Početak provedbe kontrole mliječnosti (http://www.icar.org ;HPA,2013.)

Godina početka	**Zemlja**	**Godina početka**	**Zemlja**
1883.	SAD	1909.	Estonija
1895.	Danska	1910.	Irska
1897.	Njemačka	1911.	Argentina
1897.	Mađarska	1911.	Kanada
1898.	Finska	1914.	Engleska i Wells
1898.	Norveška	1917.	Južna Afrika
1899.	Švedska	1919.	Belgija
1900.	Nizozemska	1921.	Sjeverna Irska
1903.	Austrija	1922.	Italija
1903.	Škotska	1922.	Švicarska
1904.	Letonija	1923.	Litva
1904.	Poljska	1925.	Slovačka
1905.	Francuska	1929.	Zimbabve
1905.	Češka	1930.	Rumunjska
1907.	HRVATSKA	1933.	Luksemburg
1909.	Australija	1933.	Španjolska

ICAR dopušta slobodu izbora metode kontrole mliječnosti ovlaštenim organizacijama u zemljama članicama. Osnovana podjela metoda kontrole mliječnosti učinjena je prema osoblju koje provodi kontrolu mliječnosti:

- ✓ **A kontrola** – Svi kontrolni postupci su provedeni od strane službenog predstavnika ovlaštene organizacije.
- ✓ **B kontrola** – Svi kontrolni postupci su provedeni od strane uzgajivača ili osobe koju je uzgajivač ovlastio.
- ✓ **C kontrola** – Sve kontrolne postupke provode uzgajivač ili osoba koju je uzgajivač ovlastio i službeni predstavnik ovlaštene organizacije.

Utvrđivanje količine proizvedenog mlijeka i uzimanje reprezentativnog uzorka iz ukupno proizvedenog mlijeka mora se obaviti opremom koja je odobrena od strane ICAR-a. Oprema za mjerenje količina proizvedenog mlijeka i uzimanje reprezentativnog uzorka mora se umjeravatiti u propisanim vremenskim razmacima i na način kako je propisano ICAR – ovim normama. Analiza kemijskog sastava mlijeka obavlja se na uzorku koji predstavlja 24 satno razdoblje mužnje ili na uzorku koji je korigiran na 24 satno razdoblje mužnje metodama odobrenim od ICAR-a. Kao standardna metoda kontrole mliječnosti postavljena je A4 metoda. Ova metoda propisuje mjerenje količine mlijeka na svakoj mužnji tijekom kontrolnog dana te uzimanje proporcionalnog uzorka mlijeka od svih provedenih mužnji. Dopušteno razdoblje između dvije kontrola je od 22 do 37 dana. Sagledavajući kontrolu mliječnosti na razini stada potrebno je tijekom godine dana obaviti najmanje 11 kontrola. Pored referentne metode moguće je primijeniti druge metode uz uvjet da se dobiveni rezultati korigiraju na rezultate referentne metode (tablica 2.)

Tablica 2.: Popis metoda kontrole mliječnosti (ICAR, 2012.)

Metode kontrole	**Razmak između kontroli (tjedni)**	**Dozvoljeni razmak između kontrola**		**Najmanji broj kontrola na stadu**
		najmanji	**najveći**	
A1	1	4	10	44
A2	2	10	18	22
A3	3	16	26	15
A4 (REFERENTNA)	**4**	**22**	**37**	**11**
A5	5	32	46	9
A6	6	38	53	8
A7	7	44	60	7
A8	8	50	70	6
A9	9	55	75	5
Dnevna	-	1	3	310

Kontrola mliječnosti može biti obavljena tijekom jedne ili više kontrolnih mužnji ovisno o odabranoj metodi (tablica 3.). Prema ICAR-u (2012.) referentnom se smatra metoda od dvije kontrolirane mužnje (2X) tijekom kontrolnog dana. Ako je broj kontroliranih mužnji veći ili manji od dvije, tada se uz oznaku vrste kontrole mora naznačiti i broj kontroliranih mužnji tijekom kontrolnog dana.

Tablica 3.: Oznake broja mužnji tijekom dana (ICAR, 2012.)

Dodatna oznaka kontrole mliječnosti	**Broj mužnji u kontrolnom danu**
1x	Jedna
2X (REFERENTNA)	**Dvije**
3x	Tri
4x	Četiri
Rx	Kontinuirana (robotizirana mužnja)
1.4.x	Regularne mužnje nisu u isto vrijeme svaki dan
SX	Kombiniranje mužnji i sisanja teleta

Prema ICAR-u (2012.) moguće je kontrolirati samo jednu mužnju tijekom kontrolnog dana na način da se izmjenjuje jutarnja i večernja mužnja (alternativna metoda „AT“) ili se uvijek kontrolira ista mužnja (korigirana metoda „C“).

Tablica 4. Metode kontrole mliječnosti u odabranim članicama ICAR-a (http://www.icar.org)

Država	Broj krava u kontroli	% od ukupnog broja krava	% od ukupnog broja stada	Prosječan broj grla u kontroli	% stada po metodama			
					A4	AT	B	ostale
Australija	910.388	46	54	192			91	9
Austrija	401.263	77	52	18		100		
Hrvatska	102.390	54	58	15	62		38	
Danska	520.306	90	88	156	10		90	
Estonija	88.984	93	25	96			100	
Grčka	43.610	30	5	103	100			
Litva	140.170	43	6	32	1	54	27	18
Norveška	200.583	98	99	24			100	
Njemačka	3.548.441	85	65	62	39,9	26,1	31,3	2,7
Slovačka	126.332	80		225	1,7	98,3		
Slovenija	83.450	80	59	19		100		
Španjolska	516.943	61	34	65	9,88	90	0.22	
Švedska	286.840	84	76	72			100	
Švicarska	459.249	100	100	19	43,7	56,3		

Odabir metode kontrole mliječnosti prepušten je svakoj zemlji članici uz mogućnost odabira više različitih metoda (tablica 4.). Troškovi kontrole mliječnosti su prevladavajući čimbenik pri izboru metode na razini države ili razini stada (tablica 5.).

Tablica 5. Troškovi provedbe kontrole mliječnosti po odabranim zemljama članicama ICAR-a (http://www.icar.org)

Država	**Troškovi kontrole po kravi godišnje**		**Udio uzgajivača u troškovima kontrole (%)**
	kg mlijeka	**novčani iznos**	
Austrija		AT = 50 €	60,3
Australija	B4 = 44; C4 = 60 kg		100
Kanada		A4 = 37$ B = 21$	88
Hrvatska	AT = 35; BT = 20		50
Češka	A4 = 49; AT = 43		A4= 88%; AT=100%
Danska	A4 = 73; B4 = 49		100
Estonija	B = 17,4		80
Francuska		AT = 47€; B = 36€	100
Njemačka	A4 = 50; AT = 40		24-43
Mađarska	A4 =34		100
Norveška	B = 70		100
Slovačka	A4 = 64; AT = 48		30
Slovenija	AT= 110		20
Švedska	B4= 45		100
Švicarska	A4 = 66; AT = 46		32

U Hrvatskoj se od 1989. godine započelo s primjenom AT4 i BT4 metode kontrole mliječnosti. Kod AT4 metode kontrole mliječnosti kontrolu obavlja kontrolor Hrvatske poljoprivredne agencije, a kod BT4 metode kontrolu obavlja sam uzgajivač.

Osnovna razlika između provedbe referentne A4 metode kontrole mliječnosti i alternativne kontrola mliječnosti (AT4 i BT4) je u broju kontroliranih mužnji tijekom kontrolnog dana. Prema ICAR-u alternativna kontrola mliječnosti podrazumijeva mjerenje proizvedenih količina mlijeka pri jednoj mužnji uz uzimanje reprezentativnog uzorka

mlijeka iste mužnje. Kontrole se provode naizmjenično (jutarnja ili večernja mužnja) u propisanim vremenskim razdobljima (22-37 dana). Prilikom provođenja kontrole potrebno je točno evidentirati vrijeme mužnje i vrijeme prethodne mužnje. Za procjenu dnevnih vrijednosti (količine i sastava mlijeka) pri alternativnoj metodi kontrole mliječnosti od strane ICAR-a (2012.) preporučene su metoda po DeLorenzu i Wiggansu (1986.), te metoda po Liu i sur. (2000.).

Procjena dnevnih količina mlijeka (DKM) i dnevnog sadržaja masti (DSM) u Hrvatskoj se provodi prema metodi DeLorenzo i Wiggans - u (1986). Vrijednosti sadržaja bjelančevina i suhe tvari bez masti dobivenih pri kontroliranoj mužnji preuzimaju se kao dnevne vrijednosti bez dodatnih korekcija, jer je isključen utjecaj razmaka između mužnji na njihov sadržaj. Izračun se obavlja na temelju vrijednosti izmjerenih pri jutarnjoj ili večernjoj kontrolnoj mužnji. Prema ICAR-u (2012.) u slučaju korištenja metode DeLorenzo i Wiggans (1986.) procjena proizvedene dnevne količine mlijeka (DKM) i pripadajućeg sadržaj mliječne masti u kontroliranom danu (DKM) provodi se na osnovu utvrđenih količina proizvedenog mlijeka i učestalosti mužnji tijekom kontroliranog dana. Usklađenje različitih dužina razmaka između kontrolne i mužnje koja prethodi kontrolnoj mužnji obavlja se pomoću korekcijskih faktora za izračun utjecaja dužine razmaka između mužnji na proizvedene količine mlijeka i mliječne masti.

Visoka cijena troškova provedbe referentne A4 metode uz povećanje broja stada i mliječnih krava obuhvaćenih kontrolom mliječnosti glavni je razlog uvođenja alternativnih metoda kontrole mliječnosti. Primjena alternativnih metode kontrole mliječnosti snizila je troškove provedbe kontrole mliječnosti od 15 do 25 % (Everett i Carter, 1968.; Sechrist, 1981.; Majeskie, 1981.; Jakopović, 1989.; Aleandri i sur., 2003.).

Uslijed povećanog pritiska na cijenu provedbe kontrole mliječnosti sve je raširenija primjena B metodi kontrole mliječnosti . U Hrvatskoj se na velikim mliječnim farmama primjenjuje BT4 metoda kontrole mliječnosti. Prema Ižaković i sur. (2011.) cijena koštanja provedbe AT4 metode kontrole mliječnosti po kravi iznosi 479,78 kn (64 €) za simentalska grla te 486,95 kn (65 €) za grla holstein pasmine. Cijena koštanja provedbe BT4 metode kontrole mliječnosti po kravi simentalske pasmine iznosi 436,08 kn (58 €) te 486,95 kn (65 €) za krave holstein pasmine. Razlika u cijeni između pasmina nastaje zbog dužeg trajanja laktacije kod holstein pasmine te posljedično tome većeg broja laboratorijskih uzoraka po kontroliranoj kravi, a razlika u cijeni između vrste kontrola nastaje zbog smanjenih

troškova prijevoza na obavljanje kontrole mliječnosti i smanjenja troškova vezanih uz plaće kontrolora.

Provedba kontrole mliječnosti s obzirom na način mjerenja proizvedene količine mlijeka i način uzorkovanja reprezentativnog uzorka u Republici Hrvatskoj se dijeli na:

1. Mjerenje pokretnom elektronskom vagom uz upotrebu pribora za uzorkovanje.

Sustav mužnje u kante koji se primjenjuje kod farmi koje drže krave na vezu ne omogućuje ugradnju mehaničkih uređaja za mjerenje i uzorkovanje proizvedenih količina mlijeka . Na ovim farmama se primjenjuju elektronske vage za mjerenje proizvedenih količina mlijeka, uzimanje reprezentativnog uzorka mlijeka uzima se pomoću pribora za uzorkovanje.

2. Mjerenje i uzorkovanje protočnim mjerenim uređajima.

Sustav mužnje u mljekovode (krave na vezu) ili u mehaničkim izmuzištima omogućuje upotrebu mehaničkih protočnih mjernih uređaja (tipa waikatoo) s kojima se obavlja i uzorkovanje reprezentativnog uzorka.

3. Automatsko mjerenje i uzorkovanje.

Suvremene mliječne farme opremljene su stabilnim mjernim uređajima za utvrđivanje proizvedene količine mlijeka uz automatsko uzimanje reprezentativnog uzorka od ukupno proizvedene količine mlijeka.

1.1.2. Prikaz stanja govedarske proizvodnje u Republici Hrvatskoj

Smanjenje broja goveda, a posebice broja krava kontinuirano traje već trideset godina. U razdoblju od 1980. godine do 2014. godine broj goveda je smanjen za dvostruko odnosno sa početnih 977 tisuća na sadašnjih 442 tisuća. Najveći pad broja krava dogodio se u razdoblju od 1990. godine do 1995. godine, kada je s 830 tisuća broj goveda smanjen na 493 tisuće. Posebice se ističe pad broja goveda u 1991. i 1992. godini kao posljedica ratnih razaranja koja su zahvatila Republiku Hrvatsku (grafikon 1).

Prema Denešu (1997.) razlozi za smanjivanje broja goveda su pored ratnog razaranja i sve izrazitije starenje stanovništva sela te nedostatak sredstava za organizaciju proizvodnje na gospodarstvima s 20 do 50 krava. U pojedinim godinama dolazilo je do blagog povećanja broja goveda kao rezultat iznimno povoljnih uvjeta na tržištu mlijeka i mesa te određenih mjera financijskih potpora od strane države.

Posljednji takav primjer je utjecaj ***„referentne 2011. godine“*** na proizvodnju mlijeka i tov junadi. Na osnovu postignute proizvodnje u 2011. proizvođači mlijeka i junadi stekli su uvećana prava na plaćanje koja se prenose na poljoprivredne površine. Nažalost, već u slijedećoj, 2012. godini ponovno bilježimo pad broja krava. Povećanje broja goveda u određenim razdobljima posljedica je promjena u sustavima potpora i uglavnom je vezan uz tov junadi.

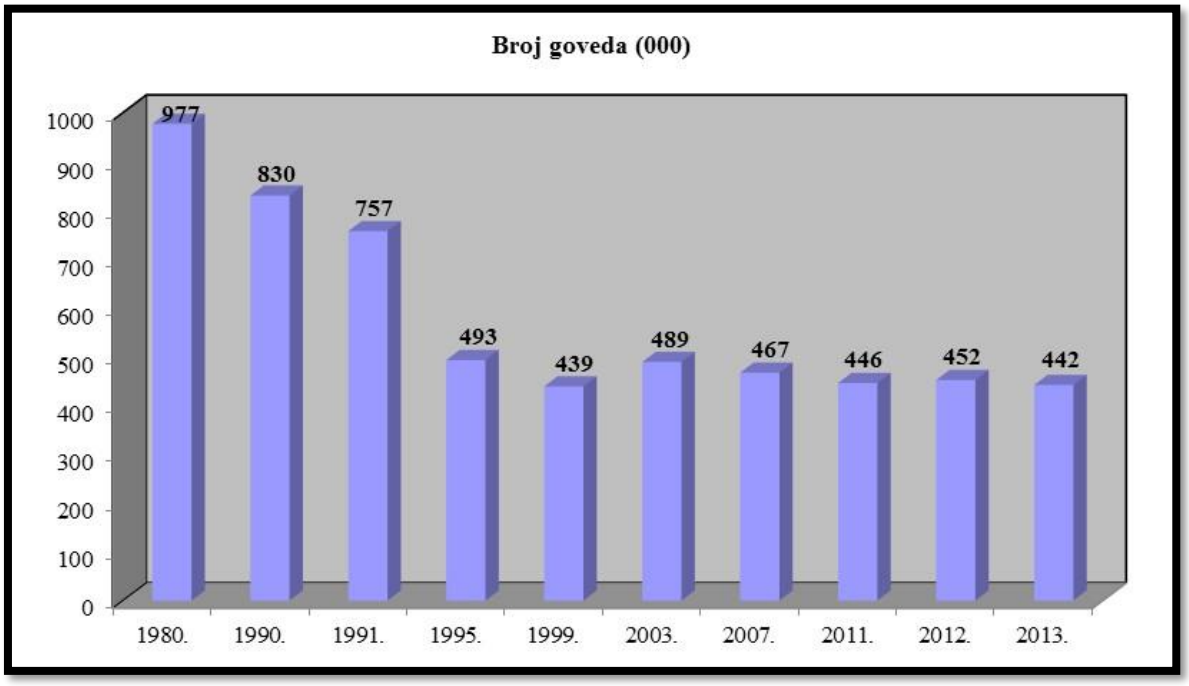

Grafikon 1. Kretanje broja goveda (http://www.dzs.hr)

Govedarska proizvodnja u Republici Hrvatskoj se danas nalazi pred nekoliko naizgled teško spojivih i ostvarivih činjenica: sniženje cijena proizvoda, povećani izdaci za osiguranje uvjeta smještaja vezanih za dobrobit životinja, povećani izdaci zbog očuvanja okoliša, te sve veći pritisak javnosti na sigurnost proizvodnje i zaštitu potrošača.

Proizvodnja mlijeka izložena je dodatnom pritisku nepovoljnih odnosa ulaznih troškova, snižavanja cijene mlijeka i promjenama u sustavu potpora što dovodi do stalnog smanjenja broja krava. Usporedo sa smanjivanjem ukupnog broja krava dolazi i do smanjivanja broja krava mliječnih i kombiniranih pasmina (tablica 6.).

Tablica 6. Kretanje broja krava (HPA, 2014.)

Godina	**Broj krava (000)**	**Broj mliječnih i kombiniranih krava (000)**	**Udio mliječnih i kombiniranih u ukupnom broju**
2005.	232	229	99
2006.	241	239	99
2007.	235	232	99
2008.	226	223	99
2009.	225	220	98
2010.	209	199	95
2011.	206	194	94
2012.	191	178	93
2013.	181	168	93

Broj isporučitelja mlijeka u prikazanom razdoblju smanjen je za 66% što je smanjenje broja farmi po godišnjoj stopi od 9,5% . Proizvodnja mlijeka dostigla je najveće količine u 2009. godini (675 miliona kg) uslijed iznimno povoljnih odnosa za proizvodnju (visoka otkupna cijena mlijeka, niske cijene stočne hrane, državne potpore po kg otkupljenog mlijeka, provedba operativnog programa razvoja govedarske proizvodnje).

Nažalost vrlo brzo uslijedilo je snižavanje otkupne cijene mlijeka u europskim zemljama što se vrlo brzo odrazilo na stanje otkupa u Hrvatskoj (u 2013. otkupljeno je oko 504 milijuna kg). Neravnomjerna regionalna distribucija govedarske proizvodnje u Republici Hrvatskoj očituje se u prikazu broja i postotnog udjela krava po županijama (tablica 7.). Hrvatska je teritorijalno podijeljena na 20 županija i Grad Zagreb.

Tablica 7. Količine otkupljenog mlijeka i distribucija broja krava po županijama (HPA,2014.)

Županija	**Otkupljeno mlijeka u 2013. (kg)**	**Udio u 2013 (%)**	**Ukupno krava**	**Udio krava u ukupnom broju**	**Ukupno mliječnih i kombiniranih krava**	**Udio mliječnih i kombiniranih krava**
Osječko-baranjska	124.108.922	24,6	25.699	13,4	23.999	12,54
Bjelovarsko-bilogorska	79.607.921	15,8	26.957	14,1	26.296	13,74
Koprivničko-križevačka	62.084.947	12,3	24.545	12,8	24.308	12,70
Vukovarsko-srijemska	59.749.601	11,9	12.631	6,6	12.387	6,47
Zagrebačka	30.686.699	6,1	15.439	8,1	15.196	7,94
Sisačko-moslavačka	21.810.989	4,3	15.036	7,9	14.052	7,34
Karlovačka	17.480.699	3,5	7.763	4,1	7.451	3,89
Virovitičko-podravska	17.409.281	3,5	6.332	3,3	5.516	2,88
Brodsko-posavska	15.209.567	3,0	6.402	3,4	5.807	3,04
Međimurska	16.544.062	3,3	4.141	2,2	4.122	2,15
Požeško-slavonska	12.547.199	2,5	4.763	2,5	4.371	2,28
Varaždinska	12.043.473	2,4	4.617	2,4	4.569	2,39
Istarska	9.234.786	1,8	4.039	2,1	3.250	1,7
Krapinsko-zagorska	9.357.546	1,9	6.275	3,3	6.172	3,23
Ličko-senjska	6.132.509	1,2	5.728	3,1	4.519	2,36
Zadarska	6.266.791	1,2	2.406	1,3	1.474	0,77
Grad Zagreb	1.762.796	0,3	1.275	0,7	1.270	0,66
Splitsko-dalmatinska	833.987	0,2	2.957	1,5	1.027	0,54
Šibensko-kninska	624.584	0,1	2.261	1,2	887	0,46
Primorsko-goranska	355.485	0,1	829	0,4	535	0,28
Dubrovačko-neretvanska	0	0	851	0,5	283	0,15
Ukupno	*503.851.844*	*100*	180.946	100	167.491	87,51

Od ukupnog broja krava 61 % se nalazi u 6 županija i u tim županijama je broj krava veći od 10 tisuća. Na području tih županija uzgaja se slijedeći udio od ukupnog broja krava: Bjelovarsko-bilogorska (12,54%), Osječko-baranjska (13,74%), Koprivničko-križevačka (12,70%), Zagrebačka (7,94%), Sisačko-moslavačka (7,3%) i Vukovarsko-srijemska (6,47%). Broj krava veći od 10.000 je u samo šest županija, u pet županija se uzgaja od 5-10.000 krava, dok se manje od 5.000 krava uzgaja u preostalih deset županija i na području Grada Zagreba. Vrlo mali broj krava (manje od 1000) imaju Primorsko-goranska i Dubrovačko-neretvanska.

Uspoređujući udio broja krava po županijama s udjelom otkupljenih količina mlijeka po županijama vidljiv je nerazmjer između ovih pokazatelja na području tri županije s najvećim brojem krava i najvećom isporukom mlijeka. Unatoč približno jednakom broju krava (Osječko baranjska, Bjelovarsko bilogorska i Koprivničko križevačka županija) na području Osječko baranjske županije otkupljene su gotovo dvostruko veće količine mlijeka. Razlog ovakvoj disproporciji je pasminski sastav (veći udio holstein pasmine) i te veći broj specijaliziranih mliječnih farmi na području Osječko baranjske županije. Na području istočne Hrvatske (Osječko baranjska i Vukovarsko srijemska županija) otkupljeno je 36,5% od ukupnih količina mlijeka od 20,00 % od ukupnog broja krava. Na području ostalih županija odnos odjela broja krava i otkupljenih količina je jednakomjeran ili je udio broja krava veći od udjela otkupljenih količina mlijeka.

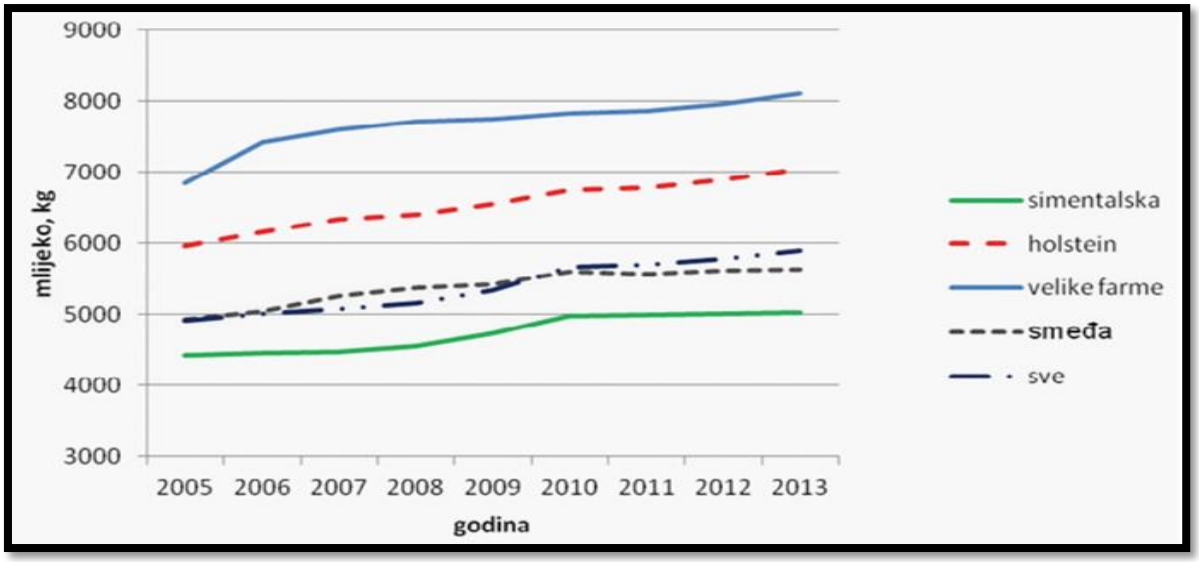

Grafikon 2. Proizvodnja mlijeka po pasminama u razdoblju 2005. – 2013. (HPA,2014.)

Holstein pasmina ima najveću proizvodnju mlijeka u standardnoj laktaciji, a onda slijedi smeđa i simentalska pasmina (grafikon 2.). U promatranom razdoblju rasla je proizvodnja po kravi po stopi od 2% na godišnjoj razini. Posebno je značajna razlika između visine proizvodnje po kravi na specijaliziranim mliječnim farmama i farmama u okviru obiteljskih gospodarstava. Ova razlika (više od 1000 kg) ukazuje na različitost u uspješnosti upravljanja cjelokupnom proizvodnjom mlijeka na farmi (management) te je razvidno da problem niske proizvodnje mlijeka nije u genetskim kapacitetima, već u nedovoljnom iskorištavanju postojećih genetskih kapaciteta (Petrač i sur., 2002). Govedarska proizvodnja u Hrvatskoj temelji se na uzgoju mliječnih (holstein) i kombiniranih pasmina (simentalska i smeđa) koje čine 90% svih krava u Hrvatskoj (tablica 8.).

Tablica 8. Broj krava po pasminama (HPA, 2014.)

Pasmina	**Ukupno**	**Udio od svih krava**
Simentalska	118.262	65,36
Holstein	44.305	24,49
Smeđa	4.603	2,54
Crveno Švedsko	158	0,09
Siva	163	0,09
Charolais	1334	0,74
Hereford	866	0,48
Angus	1481	0,82
Limousin	302	0,17
Highlander	21	0,01
Blonde D'Aquitain	31	0,02
Salers	97	0,05
Aubrac	129	0,07
Buša	461	0,25
Istarsko	721	0,40
Slavonsko srijemski	171	0,09
Križanci	7.841	4,33
Ukupno	**180.946**	**100,00**

Najbrojnija je simentalska pasmina s ukupno 118.262 krava ili 65,36 % od ukupnog broja krava. Vrlo česta pojava je križanje simentalske pasmine s drugim pasminama (udio krvi druge pasmine kreće se između 12,5 i 50 %).

Uzgojno područje simentalca je središnja, sjeverozapadna i istočna Hrvatska. U prošlom periodu bilo je uobičajeno križanje simentalske pasmine s holstein pasminom

zbog povećanja proizvodnje mlijeka, ali u današnje vrijeme simentalska pasmina se sve češće koristi u križanjima s mesnim pasminama zbog proizvodnje teladi za tov. Holstein pasmine je specijalizirana pasmina za proizvodnju mlijeka, ali se telad često stavljaju u tov uslijed nedostatka simentalske teladi i teladi mesnih pasmina. Po broju krava holstein pasmina zauzima drugo mjesto s ukupno 44.305 krava ili 24,49% od ukupnog broja krava. Holstein pasmina prevladava na specijaliziranim mliječnim farmama u Slavoniji, Baranji i okolici Zadra. Smeđa pasmina je najmalobrojnija od navedenih pasmina, te broji svega 4.603 krava.

Broj krava mesnih pasmina je u zadnjem desetljeću porastao te trenutno iznosi 4.261 grla. Glavne mesne pasmine su: Charolais, Hereford, Angus i Limousin. Krave ovih pasmina se u nas uglavnom uzgajaju u sustavu krava-tele, gdje životinje gotovo cijele godine borave na paši, a samo ih se tijekom zimskih mjeseci drži u stajama (dio simentalske populacije se drži na ovaj način) pri čemu je glavni cilj dobiti tele za tov. U Hrvatskoj se uzgaja 1.353 krava izvornih i zaštićenih pasmina. Najbrojnija je pasmina istarsko govedo, zatim slijedi buša te slavonsko-srijemski podolac.

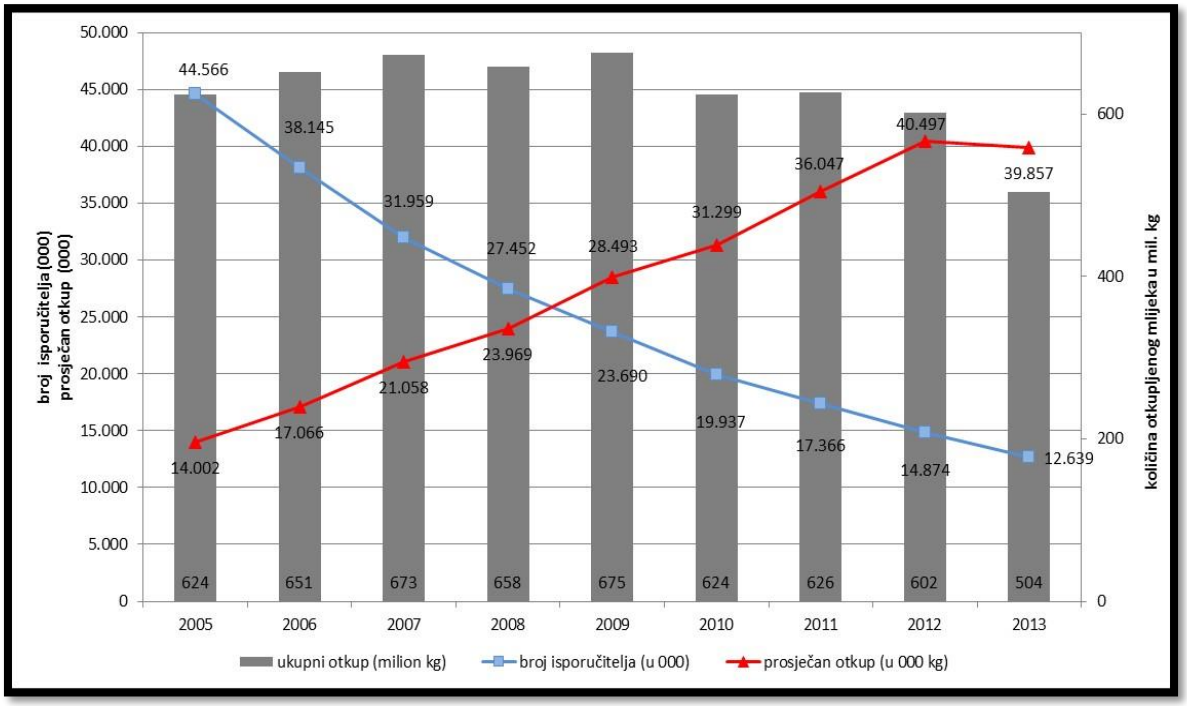

Grafikon 3. Kretanje broja isporučitelja i otkupljenih količina mlijeka (HPA,2014.)

Kretanja broja isporučitelja i otkupljenih količina mlijeka u Republici Hrvatskoj u proteklom razdoblju prikazano je na grafikonu 3. U Republici Hrvatskoj je u razdoblju od 2005 do 2013 godine prestalo s isporukom mlijeka prema mljekarama 31.927

gospodarstva ili 72% od početnog broja od 44.556 gospodarstava. Odustajanje od proizvodnje mlijeka događa se i u zemljama Europske unije ali u daleko manjem obimu. U razdoblju do 2011. godine glavni razlozi odustajanja od proizvodnje bili su veličina stada s kojom se nije moglo ostvariti značajniji prihod po gospodarstvu. Nakon toga je uslijedilo snižavanje otkupne cijene mlijeka, prestanak isplate potpora po isporučenoj količini mlijeka, povećanje cijene stočne hrane što je zajednički dovelo do stvaranja nepovoljnog okružja za održavanje dostignutog nivoa proizvodnje. U vremenu koje dolazi slijedi ukidanje sustava mliječnih kvota što će dovesti do daljnje liberalizacije formiranja cijene mlijeka i usmjeravanja proizvodnje mlijeka na gospodarstva s većim brojem krava. Isporučene količine mlijeka po proizvođačima u promatranom razdoblju su porasle s 14 tisuća kg na 40 tisuća kg na godišnjoj razini ili za gotovo 300%. Distribucija broja krava po gospodarstvu (tablica 9.) odražava nepovoljnu situaciju o odnosu na ekonomsku isplativost govedarske proizvodnje. Primjerice oko 76 % gospodarstava ima manje od 5 krava što je svega 27,2 % od ukupnog broja krava. U stadima veličine od 6 do 10 krava nalazi se 16,14 % krava na 12,57 % gospodarstava. Stada od 11 do 20 krava se nalaze na 7,73 % gospodarstava, a u njima je 19 % svih krava. Stada od 20 do 49 krava se nalaze na 3,14 % gospodarstava, a u njima je 15,7 % krava. U stadima veličine od 50 do 99 krava nalazi se 6,5 % svih krava, a udio gospodarstava je samo 0,57 %. Stada od 100 do 1.000 krava se nalaze na svega 0,27 % gospodarstava, ali se u njima uzgaja 12,15 % svih krava. Gospodarstava sa 1.000 i više krava čine 0,01 % od ukupnog broja gospodarstava, a u njima nalazi 3,21 % od ukupnog broja krava

Tablica 9. Distribucija udjela gospodarstava i stada prema veličini stada (HPA,2014.)

Veličina stada	**Broj krava**	**% krava**	**Broj stada**	**% stada**
1-5	48.656	27,22	22.982	75,71
6-10	28.854	16,14	3.817	12,57
11-15	19.326	10,82	1.520	5,01
16-20	14.718	8,23	829	2,73
21-25	8.368	4,68	369	1,22
26-30	6.494	3,63	233	0,77
31-50	13.249	7,41	348	1,15
51-100	11.637	6,51	174	0,57
101-250	7.097	3,97	47	0,16
251-1000	14.613	8,18	33	0,11
>1000	5.739	3,21	4	0,01
Ukupno	178.751	100,0	30.356	100,0

Prikaz proizvođača mlijeka prema godišnjim količinama isporučenog mlijeka jasno ocrtava nepovoljnu strukturu stada s obzirom na količinu isporučenog mlijeka (tablica 10). U razredu do 6.000 kg ukupno je čak 30% proizvođača koji su isporučili svega 2,1 % od ukupno isporučenog mlijeka. Najviše proizvođača (55,08 %) nalazi se u razredu od 6.000 do 50.000 kg, a isporučili su 26,02 % od ukupno isporučenog mlijeka. U razredu od 50.000 do 100.000 kg nalazi se 16,17 % proizvođača s 12,3 % ukupno isporučenih količina. Posebice su znakoviti razredi iznad 100.000 kg jer je svega 5,9 % proizvođača isporučilo 56% ukupno isporučenog mlijeka.

Tablica 10. Struktura isporučenih količina mlijeka po isporučiteljima (HPA, 2014.)

Količinski razred (kg./god.)	**2013. godina**			
	Broj isporučitelja	**% od ukupnog broja isporučitelja**	**Isporučeno mlijeko (kg)**	**% od ukupno isporučenog mlijeka**
< 6.000	3.821	30,23	10.717.545	2,13
6.000-50.000	7.073	55,96	132.771.698	26,35
50.000-100.000	1.107	8,76	76.069.026	15,10
100.000 -200.000	439	3,47	59.254.496	11,76
≥ 200.000	269	2,13	225.039.079	44,66
Ukupno:	12.639	100	503.851.844	100

Prosječna veličina stada u Hrvatskoj je oko 6 krava uz isporuku 40.497 kg mlijeka po farmi dok je to u zemljama Europske unije 216.292 kg mlijeka po farmi. Uspoređujući pojedine zemlje uočavaju se velike razlike u broju farmi, broju krava na farmi te otkupljenim količinama mlijeka s farme (tablica 11). Premda se smanjuje broj farmi u zemljama Europske Unije po prosječnoj godišnjoj stopi od 7 % to ipak nije dovelo do značajnijeg pada broja krava (1%). Povećanje prosječnog broja krava po farmi za 40 % (od 2009. – 2014.) usporilo je opadanje i započelo je blago povećanje broja krava u Europskoj Uniji. Primjetna je velika razlika u prosječnoj veličini stada između pojedinih zemalja članica Europske unije pa je tako u Danskoj prosječno 149 krava po farmi, a u Poljskoj je to 15 krava po farmi. Zemlje s najvećim brojem krava po gospodarstvu i s najvećim isporukama po gospodarstvu u promatranom razdoblju imaju povećanje ukupnog broja krava na razini države i povećanje ukupnih količina isporučenog mlijeka. Prosječna godišnja isporuka mlijeka (EU 25) po farmi je 241.024 kg uz ogromne razlike između pojedinih zemalja članica. Prosječna isporuka mlijeka s jednog gospodarstva u Danskoj je

1.322.368 kg, , dok je to u Poljskoj 64.843. Nerazmjer između prikazanih brojki po pojedinim zemljama članicama koje ocrtavaju stanje govedarske proizvodnje, a posebice proizvodnje mlijeka ukazuje na ugrožavanje ekonomski opravdane proizvodnje mlijeka u zemljama s malim brojem krava i manjim količinama isporučenog mlijeka po farmi.

Tablica 11. Brojno stanje mliječnih farmi, krava i otkupa mlijeka po farmi u nekim zemljama i prosječan broj u Europskoj uniji (http://epp.eurostat.ec.europa)

Država	**Parametri**	**Godina**			
		2006.	2010.	2012.	2013.
Danska	Broj farmi (.000)	5,9	4,3	4,0	3,8
	Broj krava (.000)	555	573	579	567
	Broj krava po farmi	94	133	145	149
	Otkup mlijeka po farmi	761.356	1.123.256	1.229.000	1.322.368
Njemačka	Broj farmi (.000)	109,9	91,6	83,9	80,8
	Broj krava (.000)	4,054	4,182	4,19	4,268
	Broj krava po farmi	37	46	50	53
	Otkup mlijeka po farmi	244.550	317.424	354.016	375.012
Poljska	Broj farmi (.000)	337,3	185,7	162,1	153
	Broj krava (.000)	2,637	2,529	2,346	2,239
	Broj krava po farmi	8	14	15	15
	Otkup mlijeka po farmi	26.167	48.476	60.721	64.843
Eu 25	Broj farmi (.000)	986,5	671,2	604,4	576,1
	Broj krava (.000)	22,304	21,635	21,555	21,825
	Broj krava po farmi	23	32	36	38
	Otkup mlijeka po farmi	132.457	200.831	227.859	241.024

U 2015. godini, slijedi ukidanje sustava mliječnih kvota što će povećati liberalizaciju otkupnih cijena mlijeka. Prema prikazanim podacima vjerojatno je povećanje proizvodnje mlijeka u zemljama u kojima ona već poprima značajke industrijske proizvodnje što će neminovno dovesti do destabilizacije tržne cijene mlijeka.

1.1.3. Građa mliječne žlijezde

Mliječna žlijezda (lat. *glandula lactifera*) odnosno vime je kožna, znojna žlijezda specijalizirana za proizvodnju mlijeka (Jovanović, 1988.; Havranek i Rupić, 2003.). Unutrašnju strukturu vimena čine potporni sustav, krv, limfa, živci te sekretorno tkivo sa sustavom za skladištenje i ispuštanje mlijeka. Vime krava se sastoji od četiri funkcionalno odvojena žljezdana dijela koja se zovu četvrti. S obzirom na veličinu i težinu vimena postoji snažan potporni (suspenzorni) sustav koji se sastoji od kože, brojnih ligamenata i mišića koji ga povezuju s kostima zdjelice i trbušnim zidom (Mitić i sur., 1987.).

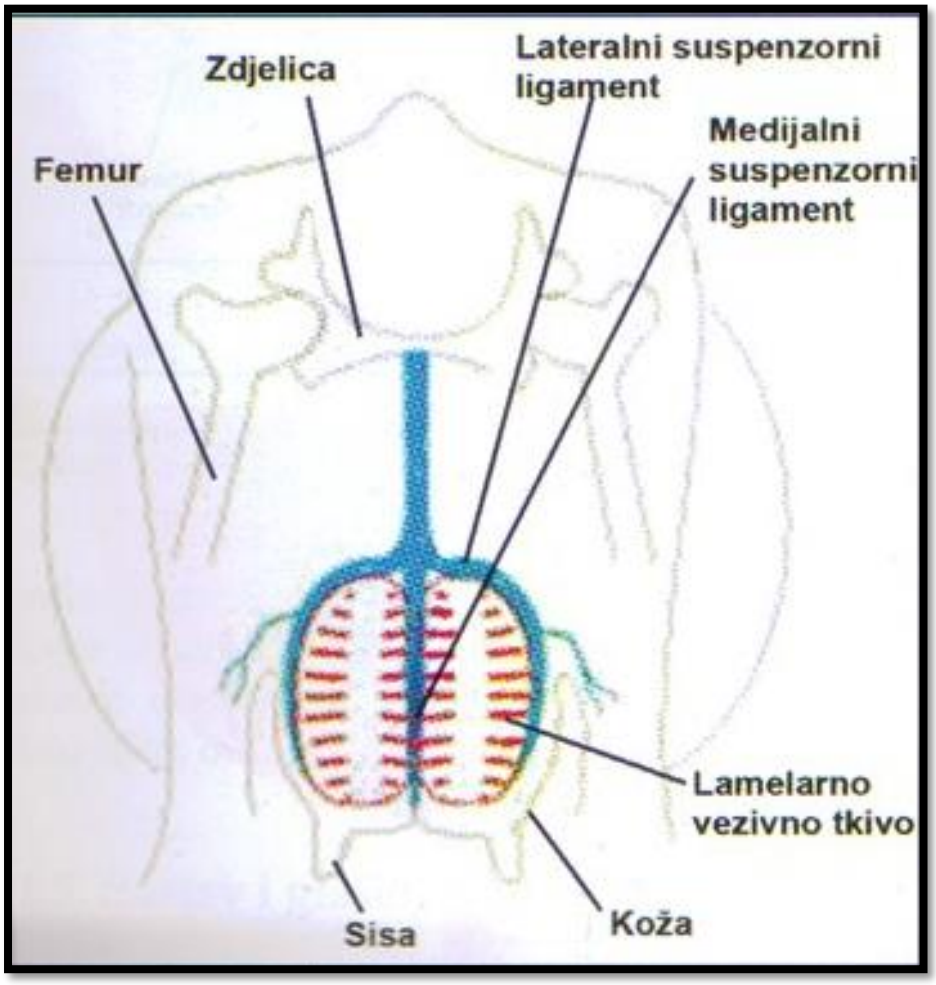

Slika 1.: Potporni sustav vimena (Bačić, 2009.)

Osnovni suspenzorni ligamenti su lateralni i medijalni koji dijele vime na lijevu i desnu polovicu te četvrti prednje i stražnje (slika 1.). Kao što je prikazano na slici 2., pojedinačno gledajući svaka četvrt vimena se sastoji od sise, sisne cisterne, žljezdane cisterne, mliječnih kanalića i sekretornog tkiva (Bačić, 2009.).

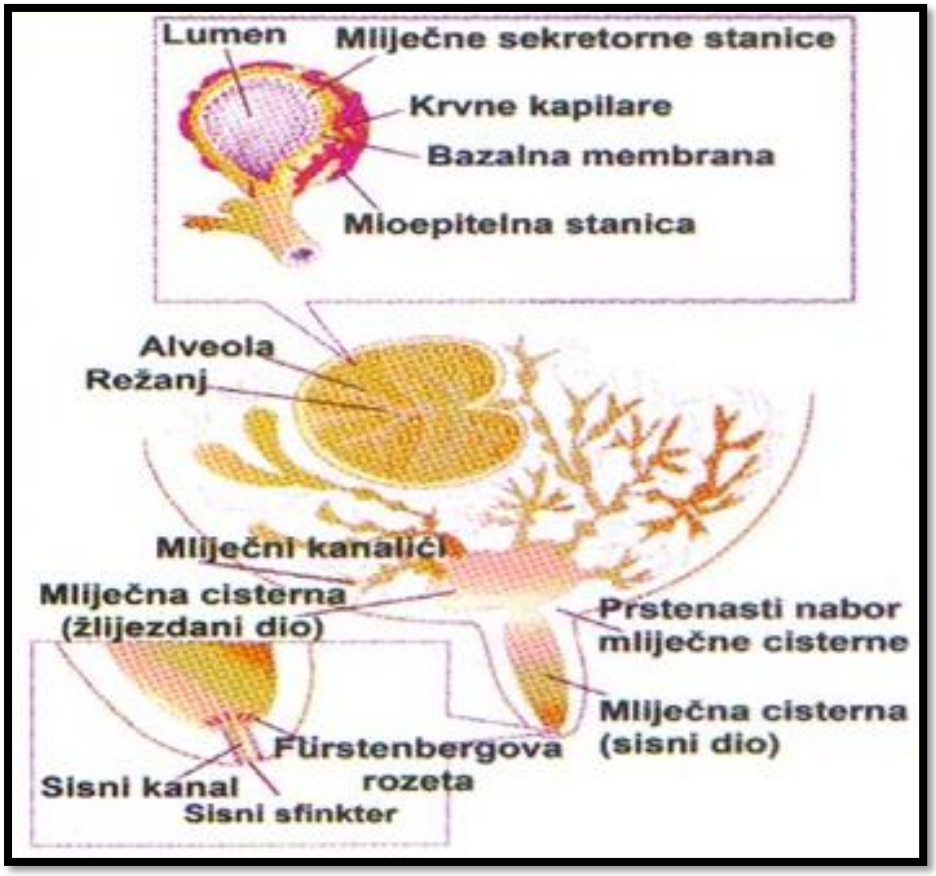

Slika 2.: Presjek četvrti vimena (Bačić, 2009.)

Krvožilni sustav vimena sastoji se od arterijskog i venskog. Venski sustav ima za 50% veći volumni kapacitet od arterijskog čime se omogućuje duže zadržavanja krvi u vimenu radi sinteze mliječnih komponenti. Krv u vime najvećim dijelom dovodi *a. v. pudendalis externa* i *v. subcutaneous abdominis* koje čine „venozni prsten. Limfni sustav vimena se sastoji od limfnih čvorova i limfnih žila, koji imaju zadatak odstranjivanja štetnih produkata iz vimena.

Živčani sustav vimena sastoji se od živaca koji obavljaju inervaciju krvnih žila i glatkih mišića oko kolektora i sfinktera i uzrokuju vazokonstrikcije te aferentni živci koji se nalaze u koži i registriraju na vanjske podražaje (Caput, 1996.).

Funkcionalni dio vimena je sekretorno tkivo odnosno žljezdani parenhim koji se sastoji od grozdastih nakupina mliječnih alveola u kojima se proizvodi mlijeko i iz kojih se putem mliječnih kanalića spušta u žljezdanu i sisnu cisternu (Bačić, 2009.).

1.1.4. Mliječna mast

Mliječna mast predstavlja kompleks različitih lipidnih tvari. Najveći udio mliječne masti u goveda čine triacilgliceroli kojih je 97-98% (Varnam i Sutherland, 1994.). Osim toga mliječna mast sadrži oko 2 % diacilglicerola, male količine fosfolipida (1%) i kolesterola (0,5%) te nešto slobodnih masnih kiselina (0,1%) (Jensen i Newberg, 1995.). Mansson (2008.) navodi da mliječna mast sadrži oko 400 različitih masnih kiselina (10-12% čine masne kiseline kraćeg lanca C-4,…, C-12). U mliječnoj masti krava najviše je zasićenih (70%) i mononezasićenih (27%) masnih kiselina. U mlijeku se mliječna mast nalazi u obliku globula obavijenih adsorpcijskim slojem ili membranom (Tratnik i Božanić, 2012.). Distribucija te građa globula mliječne masti prikazana je na slici 3.

Slika 3.: Prikaz strukture mliječne masti (Tratnik i Božanić, 2012.)

Količina mliječne masti koja se izlučuje u mlijeko je dvostruko veća od količine masti koja se nalazi u hrani koje krave pojedu. Od ukupno unesenih masti u organizam preko hrane 18-25% iskoristi za sintezu masti.

Tijekom mikrobioloških procesa u buragu najvećim dijelom nastaju octena (81%), propionska (13%) i maslačna kiselina (4,3%) koje služe kao osnovni materijal za sintezu mliječne masti ili za sintezu novih masnih kiselina. Đorđević (1987.) navodi da za sintezu mliječne masti postoje četiri izvora masnih kiselina i to:

1. masne kiseline iz hrane
2. masne kiseline iz tjelesnih rezervi masti
3. masne kiseline koje nastaju u buragu
4. masne kiseline koje nastaju u mliječnoj žlijezdi.

Barber i sur. (1997.) navode da se obzirom na nastanak masne kiseline dijele na masne kiseline sintetizirane *de novo* u mliječnim stanicama te masne kiseline koje krvotokom dolaze u mliječnu žlijezdu, a porijeklom su iz hrane ili su mobilizirane iz tjelesnih rezervi. Za sintezu mliječne masti u samoj mliječnoj žlijezdi odgovorna je prvenstveno octena kiselina i u nešto manjoj mjeri ostale hlapive masne kiseline i kiseline dužih lanaca podrijetlom iz predželudaca, gdje su nastale mikrobnom razgradnjom ugljikohidrata i sirove vlaknine. Acetati i butirati proizvedeni u buragu koriste se kao građevne jedinice masnih kiselina kratkih lanaca. Wattiaux (2011.) navodi da je oko 17-45% od masti u mlijeku je izgrađen od acetata i 8-25% od butirata. Prema Baumannu i Griinariju (2003.) masne kiseline kraćeg lanca (C-4 – C-14) su isključivo de novo sintetizirane u mliječnoj žlijezdi; masne kiseline dužeg lanca (> C-16) porijeklom su iz cirkulacije, dok su masne kiseline C-16 porijeklom iz oba dva izvora (slika 4.).

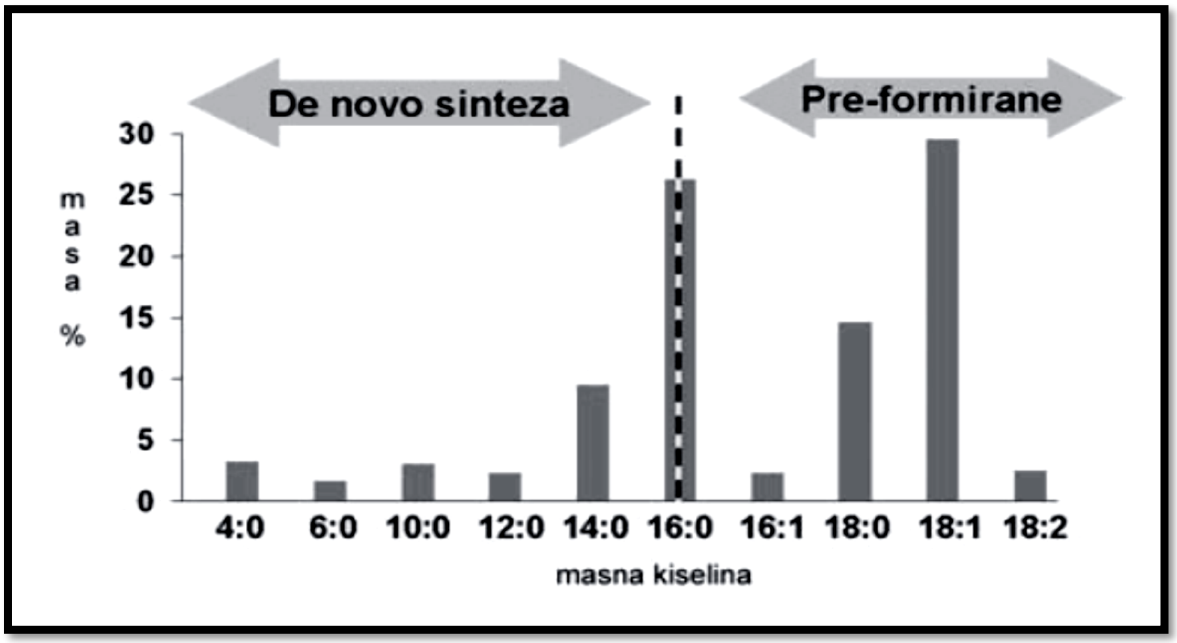

Slika 4.: Sinteza masnih kiselina (Grubić i sur., 2007.)

Masne kiseline dužeg lanca, koje nalazimo u mlijeku, porijeklom su iz tjelesnih skladišta odnosno masnog tkiva ili su sintetizirane u jetri odakle se krvlju prenose u mliječnu žlijezdu. No, u cjelini, samo polovica količina masnih kiselina u mliječnoj masti se sintetizira u vimenu, dok druga polovica prvenstveno dolazi iz masnih kiselina dužeg lanca porijeklom iz konzumirane hrane. Upravo ta činjenica omogućuje utjecaj na sadržaj mliječne masti putem hranidbenog managementa (Wattiaux, 2011.). Havranek i Rupić (2003.) navode da količina mliječne masti ovisi o hranidbi i to o količini masti u hrani,

energetskoj vrijednosti obroka, količini ugljikohidrata i sirove vlaknine u obroku, zatim stadiju laktacije, vremenu proteklom od posljednje mužnje te zdravstvenom stanju vimena.

Količina masti u mlijeku je pod utjecajem fizioloških i okolišnih čimbenika. Fiziološki čimbenici obično uključuju promjene u energetskoj ravnoteži (tj. fazi laktacije) i nemaju veliki potencijal kao praktično sredstvo u promjenama količine mliječne masti. Obzirom na navedeno hranidba je predominantni okolišni čimbenik koji utječe na količinu i sastav mliječne masti i predstavlja praktičan alat za promijene količine i sastava mliječne masti (Bauman, i sur., 2011.). Povezanost promjena u količini mliječne masti i utvrđivanje negativne energetske ravnoteže na osnovu rezultata kontrole mliječnosti na kontrolirani dan otvorilo je mogućnost pravovremene intervencije u hranidbu s ciljem dovođenja krave u energetsku ravnotežu i poboljšanja reprodukcijske učinkovitosti.

Kristula i sur. (1995.) temeljem istraživanja provedenog na 1.640 krava uzgajanih na 22 mliječne farme u SAD-u identificirali su negativnu povezanost između uspješnosti koncepcije pri prvoj inseminaciji te postotnog i težinskog udjela mliječne masti u prvoj kontroli mliječnosti. Povećanje ili smanjenje količine mliječne masti zavisi od nutritivne vrijednosti obroka. Nije neuobičajeno da se dva suprotna metabolička poremećaja i / ili hranidbena problema pojavljuju unutar iste grupe krava. Primjerice krave u početku laktacije imaju tendenciju mobilizirati tjelesne rezerve uz istovremeno nedovoljnu konzumaciju vlaknine. De Vries i Weerkamp (2000.) su nakon istraživanja 140 laktacija prvotelki došli do saznanja da dnevni manjak od 10 MJ/NEL ispod najniže točke energetske ravnoteže odgovara odgođenoj ovulaciji od 1,25 dana. Razmjerno snažno smanjenje postotka mliječne masti na početku laktacije značajno je povezano s povećanjem energetskog deficita te dugotrajnijim povratkom ka pozitivnoj energetskoj ravnoteži. Također su utvrdili vrlo značajnu korelaciju između najniže točke energetske ravnoteže i smanjenja postotka mliječne masti. Nakon povećanog postotka mliječne masti na samom početku laktacije uslijedilo je značajno snižavanje sadržaja mliječne masti te zadržavanje nešto nižih postotaka mliječne masti tijekom kasnijih faza laktacije. Na osnovu ovih činjenica zaključili su da snižavanje postotka mliječne masti tijekom početka laktacije može poslužiti kao pokazatelj energetske ravnoteže.

Eicher (2004.) navodi da mobilizacija rezerve tjelesne masti uzrokuje povećanje količine mliječne masti međutim manjak probavljivih vlakana u obroku će istovremeno utjecati na smanjenje količine mliječne masti. Madouasse i sur. (2010.) u svojoj su studiji

za predviđanje servisnog razdoblja koristili količine mliječne masti utvrđene u kontroli mliječnosti kojom je obuhvaćeno 2.128 gospodarstava u Engleskoj i Walesu između 2004. i 2006. Utvrdili su da se vjerojatnost koncepcije prije 145 dana laktacije smanjivala s povećanjem postotka mliječne masti u prvom kontrolnom danu. Gledano sa selekcijskog aspekta, visoka i negativna genetska korelacija između količine mliječne masti i količine proizvedenog mlijeka i drugih mliječnih komponenti značajno otežava povećanje sadržaja mliječne masti bez promjena ostalih mliječnih komponenata provedbom selekcijskih postupaka.

1.1.5. Bjelančevine

Cerbulis i Farrell (1975.) navode sa se dušik u mlijeku nalazi u tri frakcije i to su: kazein, bjelančevine sirutke i nebjelančevinasti dušik (tablica 12.). Navedene frakcije nalaze se u mlijeku u sljedećem udjelu oko 77,9, 17,2 i 4,9%. U nebjelančevinaste dušične tvari mlijeka ubrajaju se uglavnom peptidi, slobodne aminokiseline, amonijak, aminošećeri, kreatin, kreatinin, ureja, ureinska kiselina i druge (Tratnik i Božanić, 2012.).

Tablica 12. Prikaz koncentracije frakcija bjelančevina u mlijeku, Bylund (1995.)

BJELANČEVINE	**Sadržaj u mlijeku (g/kg)**	**% od ukupnih bjelančevina**
α_{s1}- kazein	10	30,6
α_{s2}- kazein	2,6	8
β- kazein	10,1	30,8
κ - kazein	3,3	10,1
Ukupni kazein	26	79,5
β - laktoglobulin	1,2	3,7
α - laktalbumin	3,2	9,8
Albumin krvnog seruma	0,4	1,2
Imunoglobulini	0,7	2,1
Proteoze – peptoni	0,8	2,4
Ukupne bjelančevine sirutke	6,3	19,3
Bjelančevine membrane masnih kapljica	0,4	1,2
Ukupne bjelančevine	**32,7**	**100**

Dok su neki od bjelančevina sirutke, kao što su imunoglobulini i albumin u serumu porijeklom iz krvotoka, većina mliječnih bjelančevina sintetizira se u mliječnoj žlijezdi. Aminokiseline koje se koriste za ove sinteze su ili dobivene iz krvi ili sintetizirane u

mliječnoj žlijezdi (Akers, 2002.). Osnovni proces sinteze bjelančevina iz aminokiselina u mliječnoj žlijezdi istovjetan je sintezi bjelančevina u drugim tkivima u tijelu (slika 5.). Mliječne bjelančevine , kao i bilo koje druge bjelančevine kodirane su različitim genima koji tvore genom. Biosinteza bjelančevina pokrenuta je od određenih čimbenika (primjerice, hormona) koji potiču ekspresiju gena. Stelwagen (2011.) navodi da je genska ekspresija kombinirani proces koji obuhvaća transkripciju gena u mRNA, obradu mRNA i njenu translaciju u bjelančevinu.

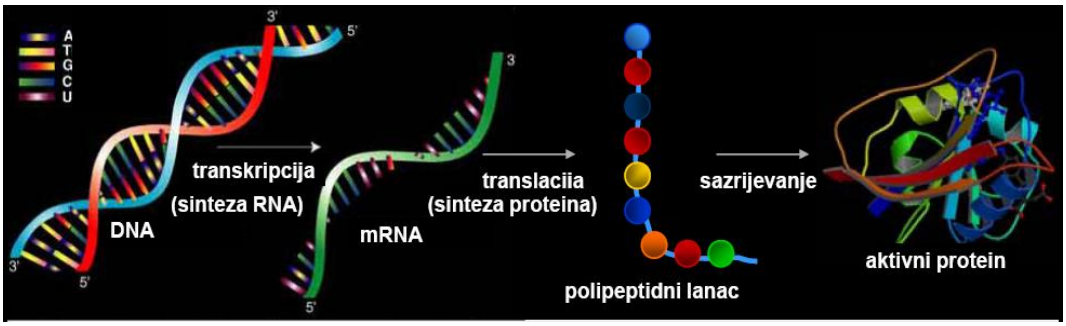

Slika 5.:Prikaz biosinteze bjelančevina (http://www.pmfst.hr)

Mliječna žlijezda sintetizira glavne bjelančevine mlijeka kazeine. Dio aminokiselina potječe od slobodnih aminokiselina iz krvne plazme, a dio odnosno neesencijalne nastaju u mliječnoj žlijezdi, uglavnom od glukoze i acetata. Glukoza osigurava znatan dio ugljika, serina i alanina. Preteča fosfora u kazeinu je anorganski fosfor iz krvi. Poslije biosinteze taj se fosfor uključuje u polipeptidni lanac (Miletić, 1994.).

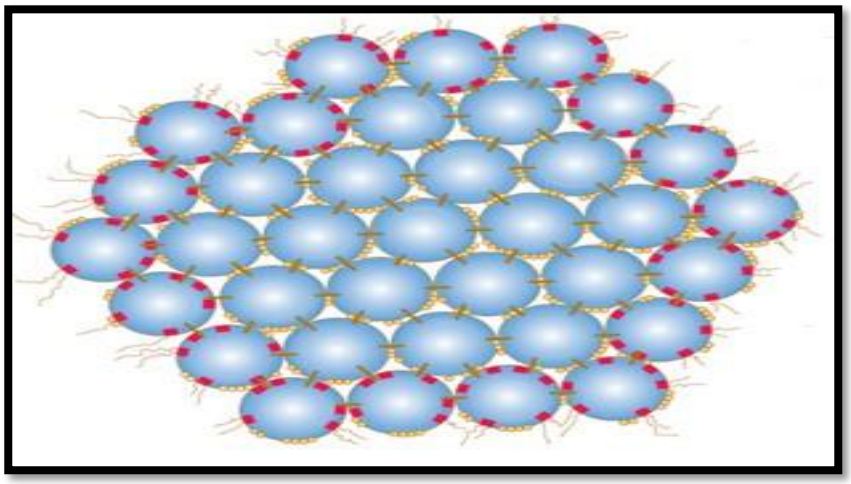

Slika 6.: Prikaz micele kazeina (Byllund, 1995.)

Molekule kazeina pojavljuju se kao micele (slika 6.), koje su kuglaste strukture i sastoje od više tisuća međusobno povezanih pojedinačnih molekula kazeina te značajne

količine kalcija i fosfata te u manjoj mjeri citrata. Stelwagen (2011.) navodi da mlijeko preživača sadrži četiri različita kazeina: α-kazein, β-kazein, κ-kazein i γ-kazein. Prva tri kazeina su produkti ekspresije različitih gena, a različite krave mogu nositi različite genetske varijante svakog od kazeina, dok je γ-kazein rezultat proteolize β-kazeina.

Bjelančevine sirutke obuhvaćaju nekazeinske bjelančevine albumin i globulin, te proteoze peptonske frakcije. Miletić (1994.) navodi da albuminsku frakciju bjelančevina mlijeka sačinjavaju β-laktoglobulin, α-laktalbumin i serum albumin. Na sadržaj bjelančevina u mlijeku utječe pasmina, dob, stadij laktacije, endokrini čimbenici, učestalost dnevnih mužnji, temperatura okoliša i hranidba (Linn ,1988.).

Patton i sur. (2007.) su ispitivali povezanost između plodnosti kod 96 holstein krava u SAD-u i pojedinih indikatora energetske ravnoteže na početku laktacije (uključujući sadržaj bjelančevina u mlijeku). Autori su utvrdili da postoji pozitivna povezanost između energetske ravnoteže, unosa suhe tvari i sadržaja bjelančevina u mlijeku u prvih 28 dana laktacije i uspješnosti koncepcije kod prvog osjemenjivanja. Isto tako utvrđena je pozitivna povezanost između energetske ravnoteže, sadržaja bjelančevina u mlijeku, unosa suhe tvari i kraćeg intervala lutealne aktivnosti.

Morton (2001.) je utvrdio da krave s većim sadržajem bjelančevina u početku laktacije prije ostaju bređe, a istovremeno nije pronašao vezu između količine proizvedenog mlijeka i plodnosti. Međusobnu povezanost između reprodukcijske uspješnosti i količine i sastava mlijeka istraživali su Buckley i sur. (2003.) kod 6.433 krave u 74 stada. Utvrdili su da je veći sadržaj bjelančevina u prvih 200 dana laktacije utjecao na bolje rezultate plodnosti, za razliku od krava koje su kroz laktaciju imale niži sadržaj bjelančevina. Povezanost između sadržaja bjelančevina i plodnosti istraživali su i Yang i sur. (2009.) na 584 laktacije holstein krava u Irskoj. Utvrdili su pozitivnu povezanost između povećanja sadržaja bjelančevina na početku laktacije i mogućnosti koncepcije kod prvog osjemenjivanja. Također su utvrdili da povećani sadržaj bjelančevina tijekom cijele laktacije ima pozitivnu povezanost s mogućnošću koncepcije. Rezultati ukazuju da negativna energetska ravnoteža u početku laktacije ili tijekom cijele laktacije uzrokuje manjak glukoze u vimenu, što dovodi do reducirane sinteze bjelančevina u vimenu te smanjuje postotak bjelančevina u mlijeku.

1.1.6. Ureja u mlijeku

Ureja je organska molekula sastavljena od ugljika, dušika, kisika i vodika. Biokemijski proces sinteze ureja odvija se u Krebs-Heinseleitovom ciklusu u mitohondrijima stanica jetre. Marenjak i sur. (2004.) navode da se amonijak pomoću enzima ureageneze prevodi umanje toksičan spoj – ureju.

Ureja je uobičajeni sastojak krvi i drugih tjelesnih tekućina. Ureja se smatra normalnim sastojkom kravljeg mlijeka kao dio nebjelančevinastog dušika (NPN) budući da lagano difundira kroz tjelesne tekućine pa tako brzo prelazi iz krvi u mlijeko (Ferguson, 1999.). Pri razgradnji sirovih bjelančevina hrane u rumino-retikularnom prostoru zbiva se deaminacija aminokiselina, pri čemu se oslobađa amonijak koji koriste mikroorganizmi buraga za sintezu svojih aminokiselina i bjelančevina, ali isključivo u slučaju dovoljne količine lako probavljivih ugljikohidrata, odnosno energije. U protivnom se višak stvorenog toksičnog amonijaka u jetri pretvara u ureju (Symonds i sur., 1981.; Prpić i sur., 2005.).

Amonijak nastao degradacijom proteina hrane djelomično se ugrađuje u stanice mikroorganizama. Njegovo fiksiranje od strane mikroorganizama buraga odvija se u procesu suprotnom od deaminacije aminokiselina. Nasuprot velikom značaju amonijaka za porast mikroorganizama buraga, oni nikada u potpunosti ne mogu iskoristiti amonijak prisutan u buragu, jer postoji limit za količinu amonijaka koji mogu fiksirati mikroorganizmi. Višak amonijaka iznad potreba mikroorganizama s krvlju dolazi u jetru, gdje se transformira u ureju (Jovanović i sur., 2001.). Jetra sintetiziranu ureju otpušta u krv i tjelesne tekućine (uključujući mlijeko). Apsorbiran N u krvotoku je posljedica difuzije amonijaka kroz zid buraga i transport aminokiselina i peptida iz tankog crijeva. Amonijak koji je otrovan za krave brzo se pretvara u ureju u jetri. Apsorbirane aminokiseline i peptidi koji se ne iskoriste za sintezu mlijeka bivaju deaminirane u jetri i N prelazi u ureju.

Ureja ima tri moguća puta: recikliranje, izlučivanje u mlijeko ili izlučivanje u mokraću. Recikliranje ureje putem sline, a preko buragovog zida, može biti važan izvor N za mikrobiološke sintezu bjelančevina u preživača. Swensen i Reece (1993.) navode da se ureja filtrira iz krvi putem bubrega, a izlučuje iz tijela putem urina. S obzirom da se mlijeko izlučuje u mliječnoj žlijezdi, ureja difundira u i iz mliječne žlijezde, te je u ravnoteži s urejom u krvi. Zbog ovog procesa, ureja u mlijeku je proporcionalna s urejom u krvi (Roseler i sur., 1993.; Broderick i Clayton, 1997.). Isto tako je utvrđena povezanost

ukupno izlučenog dušika putem mokraće s urejom u mlijeku (Ciszuk i Gebregziabher, 1994.; Jonker i sur., 1998.).

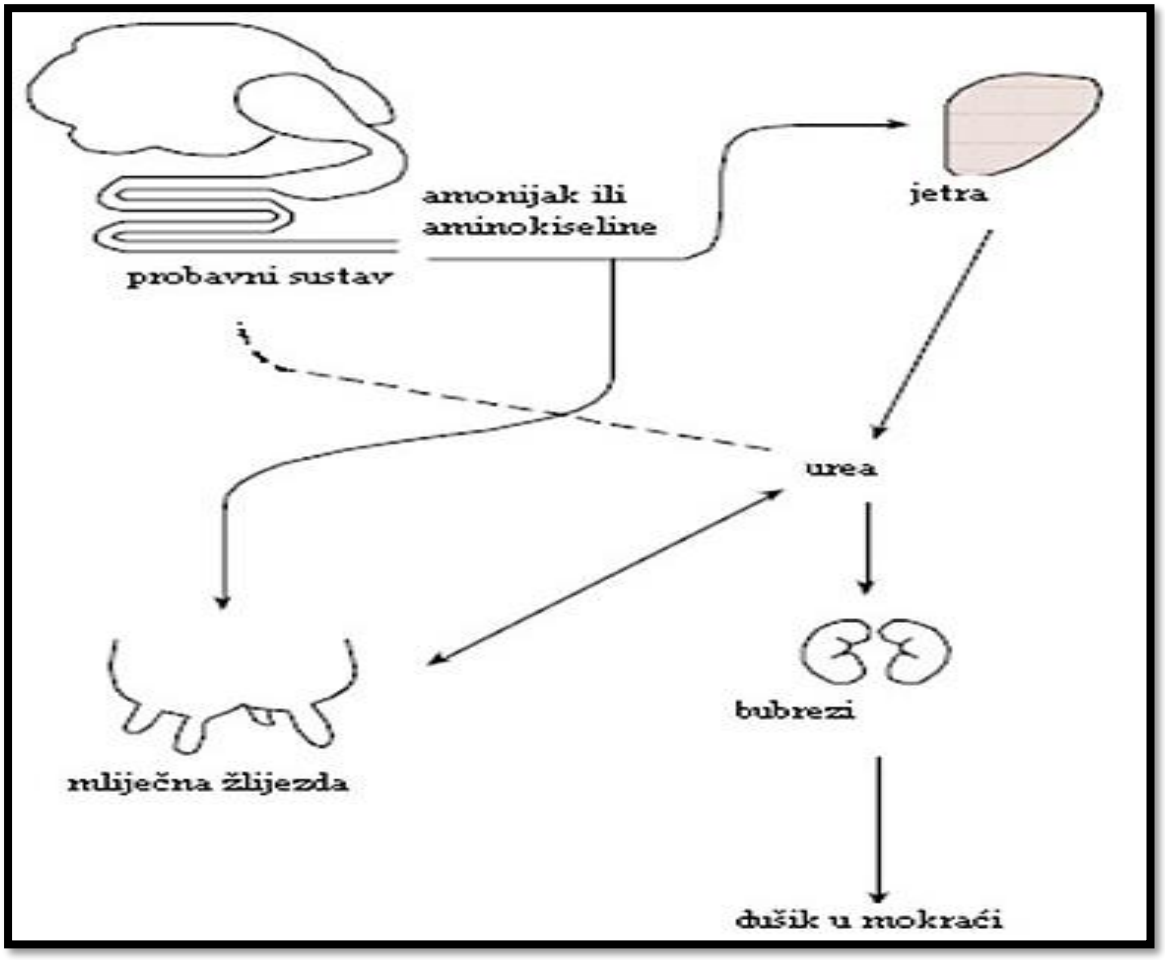

Slika 7.: Prikaz metabolizma dušika (Kohn, 2007.)

Koncentracija ureje u mlijeku pokazatelj je uravnoteženosti obroka energijom i bjelančevinama. Veća koncentracija ureje u mlijeku upozorava na preveliku količinu bjelančevina, ali i drugih dušikovih spojeva (aminokiselina, amina) što uz istovremeni energetski nedostatak dovodi do porasta sinteze ureje u jetri. Povećana koncentracija ureje u mlijeku je pokazatelje neučinkovite upotrebe bjelančevina uslijed poremećene ravnoteže između bjelančevina i energije unesene hranom (De Petres i Ferguson, 1992.; Broderick i Clayton, 1997.; Marenjak, 2004.; Bendelja i sur., 2009.). Stoga se sadržaj ureje u mlijeku sve više koristi kao praktičan parametar praćenja unosa sirovih bjelančevina i energije obrokom, odnosno provjera učinkovitosti iskorištavanja dušika (N) iz hrane u mliječnih krava (Prpić i sur., 2005.).

Mnogobrojni istraživači su utvrdili povezanost visoke vrijednosti sirovih bjelančevina u obroku i posljedično tome smanjene plodnosti. Gubitak energije putem metaboličke pretvorbe i izlučivanja suviška dušika, a koja je potrebna za proizvodnju mlijeka u razdoblju rane laktacije, podmiruje se iz tjelesnih rezervi (Marenjak i sur., 2004.). Melendez i sur. (2000.) temeljem istraživanja na 1.073 krave na Floridi (SAD) došli do saznanja da će krave s visokim sadržajem ureje u mlijeku (17-25 mg/dl) koje se osjemenjuju tijekom ljeta imati 18 puta manju vjerojatnost koncepcije od krava s niskim sadržajem ureje (6-16 mg/dl) koje se osjemenjuju tijekom zime. Rajala-Shultz (2001.) analizirali su podatke o sadržaju ureje u mlijeku i bređosti krava u 24 stada u Kanadi. Temeljem provedenog istraživanja utvrdili su da su krave koje su imale sadržaj ureje ispod 10 mg/dl imale 2,4 puta veću vjerojatnost koncepcije, a krave koje su imale sadržaj ureje između 10 i 12,7 mg/dl imale 1,4 puta veću vjerojatnost koncepcije nego li krave koje su imale sadržaj ureja iznad 15,4 mg/dl. U istraživanju koje su proveli Řehák i sur. (2009.) na 1.333 krava holstein pasmine u Češkoj nije utvrđena značajna povezanost između sadržaja ureje u mlijeku i vjerojatnosti koncepcije nakon prvog osjemenjivanja poslije teljenja. Guo i sur. (2004.) su u istraživanju koje je obuhvatilo 10.271 kravu u ukupno 713 stada pokazali neznatnu negativnu povezanosti uspješne koncepcije pri prvom osjemenjivanju nakon teljenja unutar stada. Međutim, kada je obavljena analiza sadržaja ureje i uspješnosti koncepcije između pojedinih stada nije se pokazala povezanost između ova dva čimbenika. Hojman i sur. (2004.) su proveli istraživanje povezanosti između sadržaja ureje i plodnosti krava kod 36.073 krave iz 42 stada u Izraelu. Utvrdili su nisku povezanost između sadržaja ureje i rezultata reprodukcijske uspješnosti, premda su utvrdili značajno negativnu povezanost između sadržaja ureje u mlijeku i plodnosti krava nakon prvog osjemenjivanja.

Rhoads i sur. (2006.) u istraživanju koje je obuhvatilo 23 holstein krave koje su bile donori embrija utvrđivali su utjecaj povišenih razina ureje i embrionalnog preživljavanja. Povećane koncentracije ureje u krava donora smanjile su preživljavanje embrija kod junica koje su bile primateljice. Butler (1998.) navodi da povećanje sadržaja ureje u mlijeku iznad 19 mg/dl uzrokuje smanjenje pH vrijednosti u maternici te posljedično tome i smanjenje plodnosti u mliječnih krava. Goddenn i sur. (2001.) su proveli istraživanje koje je obuhvatilo 60 mliječnih stada holstein pasmine u Kanadi u razdoblju od 13 mjeseci. Interpretirajući vrijednosti sadržaja ureje u mlijeku na razini svake krave pojedinačno nisu pronašli povezanost između povišenih sadržaja ureja i uspjeha osjemenjivanja koje se dogodilo u okviru 45 dana od prethodne kontrole sadržaja ureje. Međutim negativna

povezanost je pronađena između sadržaja ureje ispod 4,5 mmol/litri ili iznad 6,49 mmol/litri (uspoređujući s vrijednostima u intervalu 4,5-6,45 mmol/litri) i uspješnog osjemenjivanja koje se događa u okviru od 45 dana nakon obavljene kontrole sadržaja ureja.

1.1.7. Laktoza u mlijeku

Laktoza je mliječni šećer, disaharid sastavljen od molekula α-D-glukoze i β-D-galaktoze (Tratinik, 2012.). Laktoza se sintetizira u mliječnoj žlijezdi iz glukoze. Mliječna žlijezda sama ne proizvodi glukozu jer nema glukoza-6-fosfatazu (Stelwagen, 2011.). Glukoza potječe prvenstveno iz jetre. U predželucima se hranjive tvari (ugljikohidrati, sirova vlaknina, sirove bjelančevine) pod djelovanjem mikroorganizama razgrađuju do hlapljivih masnih kiselina i to mravlje, octene, propionske, maslačne i mliječne. U jetri se iz propionske kiseline, a u manjoj mjeri iz mliječne kiseline i aminokiselina alanina, sintetizira glukoza koju će usisati iz krvi žljezdane stanice mliječnih alveola i iskoristiti za sintezu mliječnog šećera laktoze (Havranek i Rupić, 2009.). Sinteza laktoze (slika 8.) započinje fosforilacijom glukoze pri čemu nastaje glukoza-6-fosfat. U fosforilaciji glukoze sudjeluje enzim heksokinaza, dok fosfat potječe iz ATP koji prelazi u ADP.

Glukoza-6-fosfat prelazi u glukoza-1-fosfat uz djelovanje enzima fosfoglukomutaze. Glukoza-1-fosfat s UTP prelazi u uridin difosfoglukozu uz djelovanje UDP-glukoza pirofosforilaze. UDP-glukoza prelazi u UDP-gakatozu uz djelovanje enzima UDP galaktoza-4-epimeraze. Završni korak spajanja glukoze i galaktoze u laktozu odvija se u Golgijevom aparatu uz djelovanje enzima laktoza sintetaza (Stelwagen, 2011.).

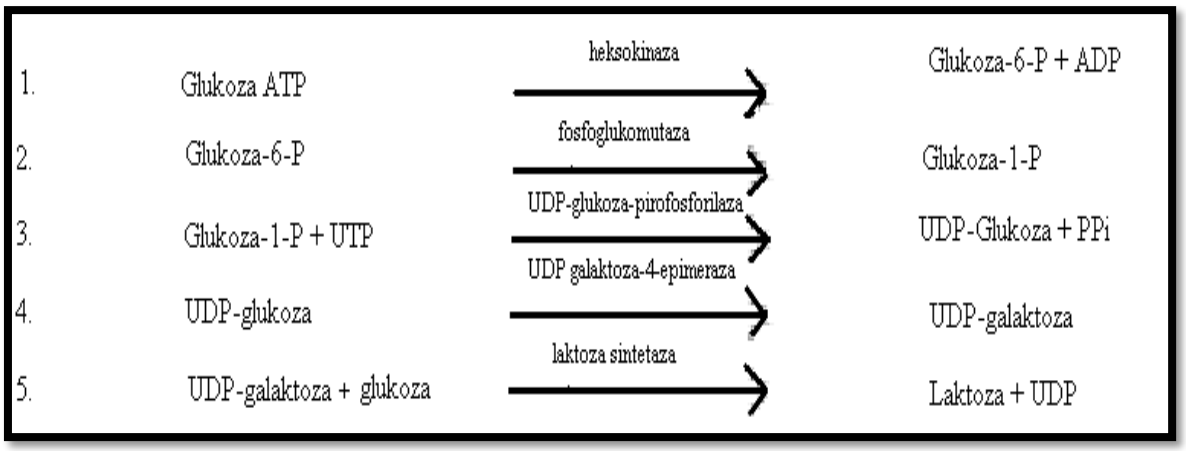

Slika 8.: Prikaz sinteze laktoze (Stelwagen, 2011.)

Koncentracija laktoze je u inverznom odnosu prema koncentraciji mliječne masti i kazeina (Jenness i Sloan, 1970.), te osmolarnosti (Holt, 1985.). Tijekom mastitisa ili pri kraju laktacije cjelovitost stanične membrane mliječne stanice je oštećena i prisutan je dotok krvnih sastojaka u mlijeko što posljedično dovodi do smanjenja koncentracije laktoze. Mlijeko koje ima nizak sadržaj laktoze ima povećanu koncentraciju anorganskih soli zbog održavanja osmotskog tlaka na željenoj razini (Fox, 2011). Navedene činjenice koriste se kao indikatori otkrivanja mastitisa. Uslijed poremećaja opskrbe žljezdanih stanica krvlju, primjerice zbog razvoja upalnog procesa u žljezdanom tkivu (parenhimu), smanjit će se opskrba tih stanica glukozom, pa će se poremetiti i sinteza mliječnog šećera. Smanjenje sinteze laktoze događa se mnogo ranije od pojave prvih kliničkih znakova mastitisa (Havranek i Rupić, 2003.; Stelwagen, 2011.).

Povećanje broja somatskih stanica dovodi do smanjenja količine laktoze za 10 do 20%. Prosječna količina laktoze u mlijeku zdravog vimena je oko 4,8%, dok snižavanje količine laktoze ispod 4,5% upućuje na upalne procese u vimenu (Antunac i sur., 2007.).

Utjecaj hranidbe na sintezu laktoze je sljedeći (Wattiaux, 2011.):

1) količina energije (koncentrata) u hranidbi utječe na proizvodnju propionata u buragu

2) propionati određuju količinu glukoze sintetiziranu u jetri

3) količina proizvede glukoze utječe na količinu laktoze sintetizirane u mliječnoj žlijezdi

4) količina laktoze utječe na količinu dnevne proizvodnje mlijeka.

Tijekom laktacije čak 85% glukoze iz krvi može se iskoristiti za sintezu laktoze (Stelwagen, 2011.). Sinteza laktoze ravnomjerno se odvija tijekom laktacije ali se sadržaj laktoze smanjuje sa svakom slijedećom laktacijom (Miglior i sur., 2006.).

Značajna je uloga laktoze u regulaciji proizvedene količine mlijeka (slika 9. – precrtani krugovi su ključna mjesta regulacije). Količina proizvedenog mlijeka je pod kontrolom prije svega s količinom sintetizirane laktoze u vimenu. Laktoza koja je izlučena u šupljinu mliječnih alveola povećava koncentraciju otopljenih tvari (osmotski tlak) u odnosu prema vanjskoj strani s koje prolazi krv. Kao rezultat toga, koncentracija otopljenih tvari na svakoj strani sekretornih stanica balansira se izvlačenjem vode iz krvi i miješanjem s drugim sastojcima iz mlijeka u šupljinu alveola.

U mlijeku zdravih krava ravnoteža je postignut kada je 4,5-5% laktoze u mlijeku. Tako proizvodnja laktoza djeluje kao "ventil" koji regulira količinu vode u alveolama, a time i količinu proizvedenog mlijeka (Wattiaux, 2011.).

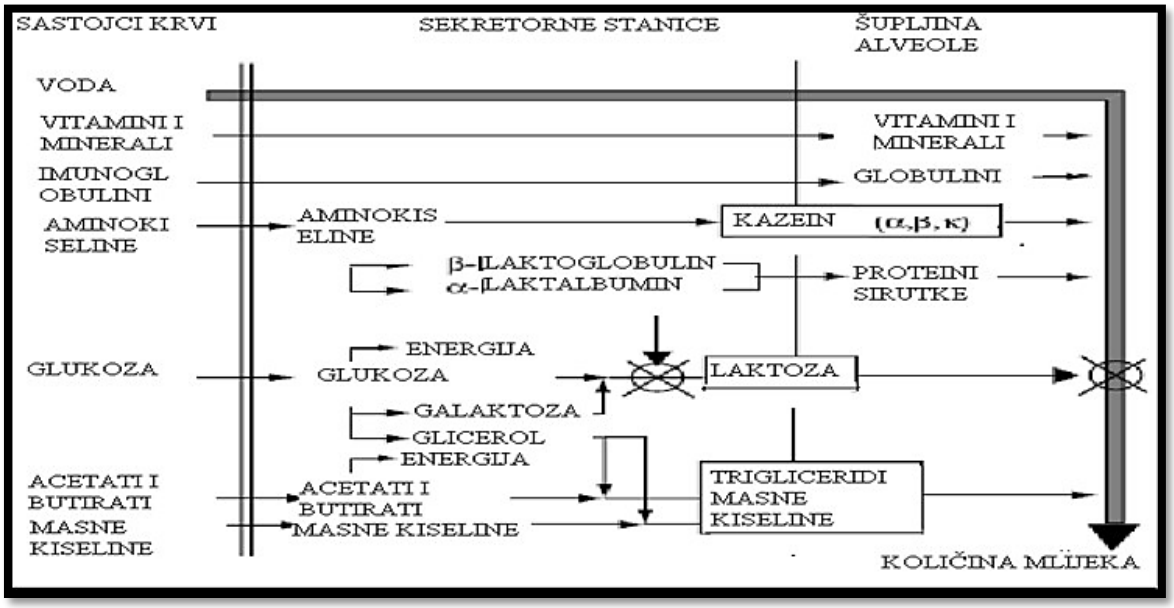

Slika 9.: Pregled regulacije izlučivanja mlijeka. (Wattiaux, 1995.)

Masilo i sur. (1992.) u istraživanju koje je obuhvaćalo krave različitih pasmina (26 krava holstein pasmine, 13 krava simentalske i 12 angus pasmine) nisu pronašli povezanost između sadržaja laktoze i pojave prve ovulacije nakon teljenja. Nasuprot njih, Reksen i sur. (2002.) su u istraživanju koje je obuhvatilo 162 laktacije u Norveškoj pronašli da povećani sadržaj laktoze u prvih osam tjedana nakon teljenja povećava lutealnu aktivnost kod krava u drugoj laktaciji. Utvrđeni sadržaj laktoze bio je veći kod holstein pasmine nego kod simentalske i angus pasmine.

Mogućnost upotrebe laktoze u predviđanju ovulacije nakon teljenja istraživali su i Francisco i sur. (2003.) kod 19 krava holstein pasmine na početku laktacije. U svom istraživanju su potvrdili značaj uključivanja sadržaja laktoze pored ostalih mjera negativne energetske ravnoteže u bolju predvidivost pojave ovulacije nakon teljenja.

Buckley i sur. (2003.) su istraživanjem na 6.433 krave holstein pasmine utvrdili da veći sadržaj laktoze u mlijeku (iznad 4,6%) povećava rezultate reprodukcijske uspješnosti. Temeljem provedenog istraživanja zaključili su da je moguće koristiti sadržaj laktoze kao pokazatelj negativne energetske ravnoteže i posljedično tome mjerilo reprodukcijske uspješnosti.

1.1.8. Somatske stanice

Somatske stanice najvećim dijelom čine leukociti ili bijele krvne stanice kao dio obrambenog mehanizma organizma, a prema Sordillo i sur. (1997.) prisutne su u zdravim četvrtima (80%) i zaraženim četvrtima (99%).

U mlijeku zdravih četvrti, BSS je manji od 200.000 stanica/ml. Kelly i sur. (2000.) su utvrdili da su makrofagi (60%) i limfociti (28%) s nešto polimorfonuklearnih stanica – neutrofila (5-12%) većina leukocita u četvrti koja nije inficirana. Nakon pojave infekcije makrofagi signaliziraju imunološkom sustavu da aktivira neutrofilne leukocite nakon čega dolazi do značajnog povećanja njihovog udjela koji može iznositi i do 90% (Kehrli i Shuster, 1994.; Saad, 1987.). Neutrofili zaokružuju bakterije i nakon toga ih fagocitiraju.

Antunac i sur. (1997.) navode da se pored leukocita u somatske stanice ubrajaju i odumrle epitelne stanice podrijetlom iz vimena (alveole, mliječni kanalići i cisterna) koje se troše u procesu sinteze mlijeka.

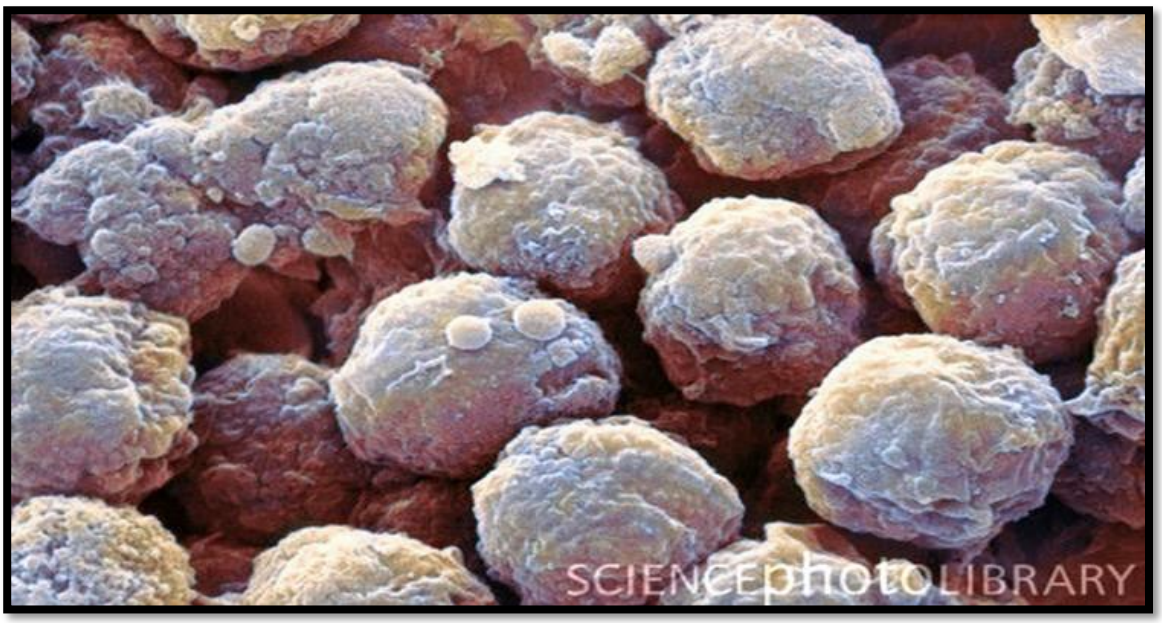

Slika 10.: Prikaz neutrofila (http://www.sciencephoto.com)

Prva linija obrane vimena je sisni kanal jer kroz njega mlijeko izlazi iz vimena, odnosno sise, ali isto tako kroz njega ulaze bakterije u vime (slika 11.). Kraći i širi sisni kanal lakše propušta veći broj bakterija pa lakše dolazi do infekcija. Unutrašnjost sisnog kanala obložena je slojevima keratina koji pomaže zatvaranje sisnog kanala kada mlijeko

ne istječe van iz vimena te onemogućuje ulazak bakterija u mliječnu cisternu. Tijekom svake mužnje određeni broj keratinskih stanica evakuira zajedno s bakterijama koje su vezale na sebe (Bačić, 2009.).

Sisni sfinkter (kružni mišić) omogućava zatvaranje ulaza u sisni kanal. Budući da sfinkter zatvara sisni kanal izvan razdoblja mužnje, većina infekcija događa se upravo tijekom same mužnje kada je ulaz u sisni kanal otvoren. Nepoželjni mikroorganizmi tijekom mužnje ulaze u sisni kanal najčešće uslijed pogrešaka tijekom mužnje vezanih uz rad muzne opreme (pad sisnih čaša tijekom mužnje i usisavanje zraka iz okoliša u sustav). Nakon mužnje, sisni kanal ostaje otvoren jedan do dva sata, međutim, u slučaju oštećenja sfinktera ulaz u sisni kanal ostaje djelomično ili potpuno otvoren i nakon navedenog razdoblja. Mikroorganizmi iz okoline (gnoj, stelja i slično) ili oni koji se nalaze na oštećenoj koži na vrhu sise u tom slučaju lako ulaze u sisni kanal. Bakterije se mogu nastaviti kretati kroz vime te obavljati kolonizaciju zdravog tkiva.

Nakon ulaska u vime bakterije prvo izazivaju oštećenje velikih mliječnih kanalića. Bakterije koje se pomoću mlijeka kreću kroz vime ostvaruju svoj prvi kontakt s leukocitima, koji su prirodno (u manjem broju) prisutni u mlijeku. U tom slučaju leukociti uništavaju prisutne bakterije te iniciraju dolazak novih leukocita iz krvi u mlijeko. Ovo je druga linija obrane vimena od upalnih procesa.

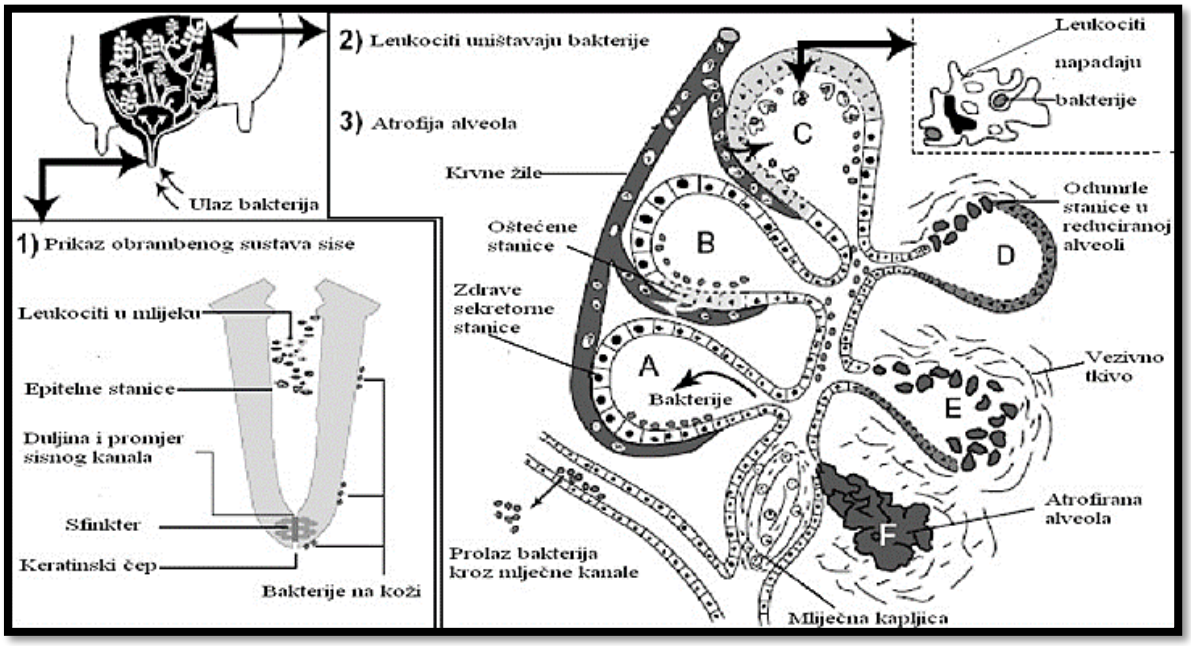

Slika 11.: Obrana vimena (Wattiaux, 1995.)

Ako bakterije nisu u potpunosti uništene, tada se vrlo brzo višestruko povećava njihov broj i započinje invazija manjih mliječnih kanalića i područja mliječnih alveola (Slika 11. - A). Seketorne stanice koje su oštećene bakterijskim toksinima oslobađaju tvari koje dovode do povećane propusnosti krvnih žila (Slika 11. - B). Povećava se broj leukocita koji dospijevaju na mjesto infekcije i oni ulaze u alveolarno tkivo između uništenih sekretornih stanica (slika 11. - C). U ovo područje dospijevaju tekućina, minerali i čimbenici zgrušavanja te dolazi do koagulacije mlijeka koje može zatvoriti kanale i tako izolirati zaraženo područje (Wattiaux, 2011.).

Povezanost između povećanog broja somatskih stanica i lošijih reprodukcijskih rezultata utvrđena je prilikom više istraživanja. Barker i sur. (1998.) utvrdili su kod 102 krave Jersey pasmine za vrijeme prvih 150 dana laktacije negativan učinak kliničkog mastitisa na početku laktacije na osobine plodnosti. Autori su utvrdili da pojave kliničkih mastitisa prije prvog osjemenjivanja povećavaju broj dana do prvog osjemenjivanja, što povećava broj dana servis razdoblja uz povećanje broja osjemenjivanja za koncepciju.

Miller i sur. (2001.) u istraživanju provedenom kod 284.450 krava u SAD-u nisu utvrdili značajnu povezanost između broja somatskih stanica i uspješnosti koncepcije nakon osjemenjivanja, ali su pokazali značajnu povezanost između broja somatskih stanica i trajanja razdoblja nakon teljenja do prvog osjemenjivanja. Morek-Kopeć i sur. (2008.) su utvrdili produženje intervala od teljenja do prvog osjemenjivanja s povećanim brojem somatskih stanica tijekom istraživanja provedenog na 190.279 prvih i drugih laktacija holstein krava u Poljskoj.

Mogućnost korištenja povećanog broja somatskih stanica na procjenu dužine trajanja servis perioda na 2.128 stada u Engleskoj i Walesu istraživali su Madousse i sur. (2010.). Prilikom istraživanja utvrdili da povećanje broja somatskih stanica do 65. dana laktacije produžuje trajanje servis perioda. U istraživanjima Nguyen i sur. (2011.) provedenim u Japanu na uzorku od 447 krava u 6 stada promatran je broj somatskih stanica i obnova ciklusa jajnika nakon teljenja. Krave s većim brojem somatskih stanica (200.000 do 500.000) imale su dužu lutealnu fazu od krava s nižim brojem somatskih stanica (100.000). Krave koje su imale broj somatskih stanica iznad 500.000 imale su odgođenu prvu ovulaciju nakon teljenja za razliku od krava koje su imale niži broj somatskih stanica (≤500.000). Krave koje su imale broj somatskih stanica iznad 200.000 imale su duže trajanje servis razdoblja te je bio potreban veći broj osjemenjivanja za koncepciju.

Povezanost između većeg broja somatskih stanica i slabijeg uspjeha koncepcije pri prvom osjemenjivanju nakon teljenja te većeg broja potrebnih osjemenjivanja za koncepciju utvrdili su Lomander i sur. (2013.) u Švedskoj prilikom istraživanja na 63.561 krave u 759 stada.

Lavon i sur. (2011.) u Izraelu su postavili granicu od 150.000 somatskih stanica kod 287.192 analiziranih prvih osjemenjivanja nakon teljenja te pokazali povezanost povećanja broja somatskih stanica u vrijeme prvog osjemenjivanja nakon teljenja na uspješnost koncepcije.

Hudson i sur. (2012.) su istražujući povezanost između zdravlja vimena i reprodukcijske uspješnosti na uzorku od 80 stada u Velikoj Britaniji utvrdili negativnu povezanost između povećanja broja somatskih stanica i vjerojatnosti koncepcije. Posebice je izražena negativna povezanost iznad granice od 390.000 somatskih stanica.

1.1.9. Tranzicijsko razdoblje i negativna energetska ravnoteža

Tranzicijsko razdoblje obuhvaća tri tjedna prije teljenja i tri tjedna nakon teljenja. Pojam tranzicija se koristi zbog naglašavanja važnosti fizioloških, metaboličkih i hranidbenih promjena koje se javljaju u tom vremenskom okviru.

Tranzicijsko razdoblje predstavlja prekretnicu u proizvodnom ciklusu krave jer se iz jedne laktacije prelazi u slijedeću. Način na koji će se te promjene dogoditi i kako će uspjeti je od presudne važnosti jer od toga zavisi buduća proizvodnja mlijeka, pojava bolesti i reprodukcijska učinkovitost (Block, 2010.).

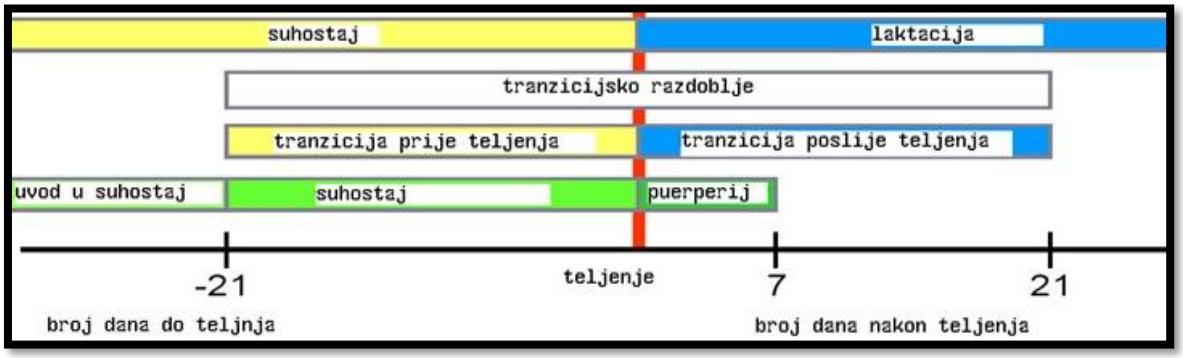

Slika 12.: Prikaz tranzicijskog razdoblja (Prema Drackley, 2011.)

U vrijeme tranzicijskog razdoblja događaju se najvažnije metaboličke promjene jer se organizam krava priprema za početak proizvodnje mlijeka te doživljava stres koji sa sobom donosi samo teljenje. To je razdoblje u kojem mliječna krava mora mijenjati svoje metaboličke prioritete prema dostupnim hranjivim tvarima zbog fetalnog rasta, skladištenja energije za proizvodnju mlijeka, mobilizaciju tjelesnih rezervi nakon teljenja i početka laktacije. Grummer (1995.) navodi da u slučajevima kada se mliječna krava ne može brzo prilagoditi ovim izazovima ona ulazi u stanje negativne energetske ravnoteže u kojem potrošnja energije prelazi unos energije. Pored toga događaju se promjene vezane uz management farme kao što su promjena mjesta boravka i promjena obroka. Tako su Schirmann i sur. (2011.) u istraživanju koje je obuhvatilo 48 krava holstein pasmine u razdoblju prije teljenja pokazali da premještanje krava tijekom suhostaja u nove grupe i nove prostore dovodi do značajnih promjena u ponašanju krava i smanjenja unosa hrane do 9%. U tranzicijskom razdoblju nakon teljenja prema Le Blancu (2010.) gotovo sve mliječne krave dožive period inzulinske rezistencije, smanjene konzumacije hrane, negativne energetske ravnoteže, lipolize, gubitka na težini i hipokalcemije.

Zdravstveno stanje krava tijekom tranzicijskog razdoblja glavna je odrednica reprodukcijske uspješnosti. Slabljenje imuniteta događa se najčešće jedan do dva tjedna prije i dva do tri tjedna nakon teljenja, a bakterijske infekcije maternice događaju se dva do tri tjedna nakon teljenja. Jedna trećina krava obično je pogođena nekim oblikom metaboličkih poremećaja ili nekom infekcijom. Uslijed neadekvatne prilagodbe zahtjevima u razdoblju tranzicije događa se 75% ukupnog broja bolesti koje prate mliječne krave (Le Blanc i sur., 2006.), uz više od 25% svih izlučenja u prvih 60 dana laktacije (Godden i sur., 2003.) što sa sobom nosi ogromne ekonomske gubitke u proizvodnji mlijeka (Burhans i sur., 2003.). Uspješno provedeno tranzicijsko razdoblje podrazumijeva usklađen unos hrane i opskrbu energijom kojom se mogu podmiriti proizvodne potrebe bez značajnijeg gubitka na težini i bez pojave bolesti vezanih uz metabolizam (Overton, 2012.).

Energetska ravnoteža odražava odnos između energije dobivene kroz unesenu hranu i potrošene energije za održavanje, rast, reprodukciju i proizvodnju mlijeka (Olson i sur., 2010.). Smanjenje unosa hrane i narušavanje energetske ravnoteže započinje prije teljenja te rezultira mobilizacijom masnog tkiva kao nezasićenih masnih kiseline u krv (Butler i sur., 2006.). Unos suhe tvari smanjuje se za 32% u posljednja tri tjedna graviditeta, a najznačajnije smanjenje događa se u tjednu prije teljenja (Hayirli i sur., 2002.), dok većina krava brzo povećava unos suhe tvari u prva tri tjedna nakon teljenja (Ingvartsen i Andersen, 2000.).

Ingvartsen i Anderson (2000.) su sagledavali metaboličke čimbenike koji utječu na unos suhe tvari uključujući razne izravne i neizravne signale vezane za okoliš, imunološki sustav, masno tkivo, crijeva i gušteraču te energetski značaj jetre u odnosu na ukupne energetske potrebe. Zaključili su da su promjene izražajnosti ovih podražaja uzrok promjenama u unosu suhe tvari te da se na njih može utjecati managementom u razdoblju tranzicije.

Istražujući čimbenike koji određuju unos hrane u organizam Allen i sur. (2009.) su utvrdili da je energetski status jetre koji je pod utjecajem oksidacije propionata dobivenih iz ruminalne fermentacije i nezasićenih masnih kiselina ključan za regulaciju konzumacije hrane. U razdobljima kada oksidacijski metabolizam jetre premašuje njene energetske zahtjeve, šalje se poruka mozgu za smanjenjem konzumacije hrane.

Mliječne krave ulaze u negativnu energetsku ravnotežu u početku laktacije jer se unosom hrane ne mogu podmiriti rastuće potrebe za energijom. Tranzicija sa suhostaja na

početak laktacije u mliječnih krava rezultira naglim te vrlo velikim porastom potreba za energijom (Bauman i Currie, 1980.). U ovoj fazi, apetit mliječnih grla je limitiran, količina energije eksportirana u mlijeko ne može biti pokrivena unosom suhe tvari što u većine grla rezultira periodom negativne energetske ravnoteže koji traje i do 12 tjedana (de Vries i Veerkamp, 2000.; Butler, 2003.).

Krave koje se nalaze u negativnoj energetskoj ravnoteži mobiliziraju rezerve tjelesnih masti jer nedovoljna konzumacija suhe tvari ne može pokriti hranidbene potrebe (Bauman i Currie, 1980.). Uslijed navedenoga krave počinju koristiti glicerol kao izvor energije što dovodi do povećanja koncentracije nezasićenih masnih kiselina u krvi. Povećane koncentracije nezasićenih masnih kiselina se u jetri oksidiraju i postaju izvor energije ili se esterficiraju u trigliceride što dovodi do ketoze ili bolesti vezanih uz zamašćenje jetre (de Vries i Veerkamp, 2000.). Krave s prekomjernom mobilizacijom masti mogu ostati u fazi negativne energetske ravnoteže do 20 tjedana nakon teljenja (Taylor i sur., 2003.).

Ozbiljnost posljedica povećanja negativne energetske ravnoteže raste s povećanjem produkcije mlijeka. Osim toga, utvrđena je i negativna korelacija između količine mlijeka i nastavka lutealne aktivnosti (Veerkamp i sur., 2000.), izražajnosti estrusa (Cutullic i sur., 2009.), te trajanja servis perioda (Abdallah i McDaniel, 2000.; Haile-Mariam i sur., 2003.). Pored toga Coffey i sur. (2004.) su utvrdili da visoko proizvodne mliječne krave imaju predispoziciju prema korištenju tjelesnih rezervi zbog održanja proizvodnje mlijeka. Overton i Waldron (2004.) navode da tijekom tranzicijskog razdoblja mliječne krave prolaze kroz velike promjene u metabolizmu glukoze, masnih kiselina i minerala s ciljem održavanja proizvodnje mlijeka i izbjegavanja metaboličkih disfunkcija.

Lucy i sur. (1992.) su utvrdili da nije nužno da visoko proizvodne krave ulaze u ekstremnu negativnu energetsku ravnotežu i pad tjelesne kondicije ukoliko se uspije izbjeći velika neravnoteža između konzumacije suhe tvari i visoke proizvodnje mlijeka, što u konačnici dovodi do loših rezultata reprodukcije. Recentna istraživanja sugeriraju da konzumacija suhe tvari ima veći značaj na izražajnost negativne energetske ravnoteže od visine proizvodnje mlijeka pojedine krave (Santos i sur., 2009.; Grummer i sur., 2010.).

Produženo trajanje negativne energetske ravnoteže može dovesti do zdravstvenih problema, lošijih reprodukcijskih rezultata, smanjenja proizvodnje, ranijeg izlučivanja ili uginuća (Collard i sur., 2000.; De Vries i Veerkamp, 2000.; Coffey i sur., 2004.). Premda

se konzumacija suhe tvari počinje povećavati nakon teljenja, isto nije dovoljno za podmirenje rastućih energetskih potreba što dovodi do povećanja ketonskih tijela u krvi i nezasićenih masnih kiselina te većoj podložnosti prema bolesti (Grummer i Mashek, 2004.). Nakon teljenja značajno su povećane potrebe za glukozom kao posljedica povećane proizvodnje laktoze. Najvažniji izvor glukoze su propionati proizvedeni od buragovih mikroorganizmima koji u jetri prelaze u glukozu. Međutim, nakon teljenja razina propionata je niska jer je nedovoljna konzumacija hrane i krave moraju pronalaziti alternativni izvore za glukozu i energiju, primarno razgradnjom tjelesnih proteina i masti. Krave koje se ne mogu brzo prilagoditi prema povećanim potrebama za glukozom i energijom ulaze u metaboličke poremećaje uključujući ketozu (Gressley, 2008.).

Tijekom tranzicijskog razdoblja oslabljen je imunitet organizma kao posljedica hormonalnih promjena i negativne energetske ravnoteže. Učestalost pojave bolesti tijekom razdoblja puerperija povezana je sa smanjenjem imuniteta koje se prirodno događa upravo oko teljenja. Burton i sur. (2005.) utvrdili su značajnu redukciju sposobnosti neutrofila u borbi protiv infekcija za vrijeme razdoblja tranzicije, a osobito u razdoblju neposredno nakon teljenja.

Butler (2003.) u radu o povezanosti energetske ravnoteže i reprodukcijske učinkovitosti zaključuje da je upravo energetska ravnoteža poveznica između visoke proizvodnje mlijeka i slabih reprodukcijskih rezultata. Metabolički zahtjevi zbog visoke proizvodnje mlijeka rezultiraju u većoj negativnoj energetskoj ravnoteži. Umanjena kakvoća oocita i sposobnosti preživljavanja embrija povezuje se s negativnom energetskom ravnotežom. Također negativna energetska ravnoteža uz gubitak na ocjeni tjelesne kondicije (Body Condition Score – BCS) povezuje se sa smanjenjem koncentracije progesterona tijekom ciklusa.

Bello i sur. (2012.) navode da se temeljem rezultata istraživanja unazad nekoliko godina (Peters i Pursley, 2002.; López-Gatius i sur., 2006.; Le Blanc, 2010.; Löf i sur., 2007.) mijenja percepcija o univerzalnom antagonizmu između visine proizvodnje mlijeka i uspjeha u reprodukciji krava. Prema ovim istraživanjima značajan utjecaj na reprodukcijski uspjeh leži u ravnoteži energetskog statusa u periodu nakon teljenja i postizanja najveće proizvodnje mlijeka u početku laktacije.

1.1.10. Laktacijska krivulja

Laktacija predstavlja razdoblje proizvodnje mlijeka od teljenja do zasušenja. Standardna laktacija traje 305 dana ili 10 mjeseci. Trajanje laktacije ovisi o pasmini, dobi, kondiciji, plodnosti, hranidbi, zdravstvenom stanju i drugim utjecajima. Tijek laktacije prikazuje se laktacijskom krivuljom kojom se prikazuje kretanje razine proizvodnje tijekom laktacije. (Uremović, 2002.) Osnovica za izračun laktacijske proizvodnje su dnevna količina i sastav mlijeka utvrđeni na dan provedbe kontrole mliječnosti. Laktacijska proizvodnja pojedinog grla osnova je izračuna uzgojne vrijednosti, odnosno provedbe selekcije na svojstva mliječnosti u skladu s prihvaćenim uzgojnim programom za pojedinu pasminu (Gantner, 2009.).

Prikaz kretanja proizvedenih količina i sastava mlijeka izražava se laktacijskom krivuljom. Kretanje laktacijske krivulje u suvremenoj proizvodnji mlijeka pruža dragocjenu informaciju o uspješnosti upravljanja cjelokupnom proizvodnjom mlijeka na farmi. Predviđanje kretanja laktacijske krivulje postalo je osnovica suvremenog upravljanja proizvodnjom mlijeka. Krave s vrlo izraženim vrhom proizvodnje nisu u mogućnosti konzumirati dostatnu količinu krmiva tijekom prve faze laktacije te ulaze u negativnu energetsku ravnotežu koja ima za posljedicu pojavu metaboličkih bolesti i slabljenje reprodukcijske učinkovitosti (Gantner, 2010.)

Količina i sastav mlijeka uglavnom su pod utjecajem faze laktacije. Količina proizvedenog mlijeka na dnevnoj razini povećava se nakon teljenja do 6. – 8. tjedna i zatim se počinje smanjivati. Maksimalna proizvodnja mlijeka predstavlja vrh laktacijske krivulje. Kretanje konstitutivnih elemenata mlijeka (mliječna mast, bjelančevine i somatske stanice) ima inverzni oblik u odnosu na kretanje laktacijske krivulje jer se njihov sadržaj u mlijeku smanjuje od teljenja do postizanja maksimalne proizvodnje (vrh laktacije), a zatim se povećava sve do zasušenja (Madouasse, 2009., Silvestre i sur., 2009.; Caccamo i sur., 2008., Gelebiewski i sur. 2011.).

Madouasse (2009.) je u istraživanju koje je obuhvatilo 2.128 stada u Velikoj Britaniji utvrdio postojanje signifikantne razlike u obliku laktacijske krivulje za količinu mlijeka i broj somatskih stanica između prve laktacije i ostalih laktacija. Maksimalna mliječnost dostignuta je oko 50. dana laktacije za prvotelke te 40. dana laktacije za ostale krave. Nakon dostizanja maksimalne mliječnosti uslijedio je blaži pad u proizvodnji kod prvotelki nego kod ostalih krava. Najniže koncentracije mliječne masti su oko 50 dana

laktacije (3,7%) a za bjelančevine oko 35 do 40 dana (3%). Ukupna količina proizvedene mliječne mast i mliječnog proteina je najveća na početku laktacije i nije se smanjivala sve do postizanja maksimalne mliječnosti u vrhu laktacije.

Broj somatskih stanica smanjuje se u razdoblju od teljenja do postizanja maksimalne mliječnosti, a zatim se počinje povećavati prema kraju laktacije. Broj somatskih stanica se sa svakom slijedećom laktacijom povećava u odnosu na prethodnu.

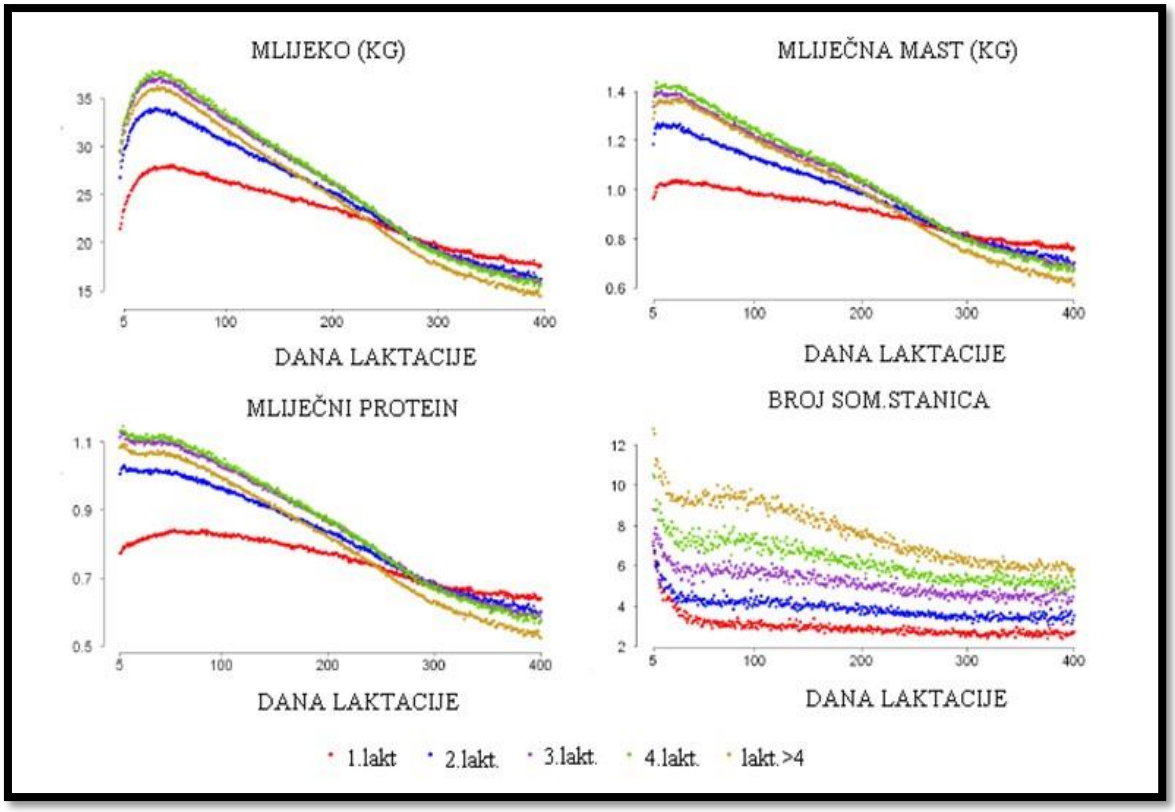

Grafikon 4: Varijabilnost količine i kvalitete mlijeka ovisno o stadiju i redoslijedu laktacije (Madousse, 2009.)

Tablica 13.: Distribucija laktacijskih krivulja (Gelebieewski i sur., 2011.)

Tip laktacije	**Količina mlijeka, %**	**Mast, %**	**Protein. %**	**Laktoza. %**	**Suha tvar, %**	**Somatske stanice**	**Ureja**
C1	76,59	21,12	22,11	58,55	17,05	38,48	66,34
C2	0,6	6,86	12,23	2,23	7,47	7,97	6,36
C3	15,63	3,15	0,00	9,26	3,95	3,95	4,26
C4	7,72	68,87	65,66	29,96	49,60	49,60	23,04
Ukupno	100	100	100	100	100	100	100

Gelebiewski i sur. (2011.) su na osnovu istraživanja u Poljskoj na 1.619 krava utvrdili četiri osnovna oblika laktacijske krivulje s obzirom na kretanje količine proizvedenog mlijeka i kretanje konstitutivnih elemenata u mlijeku (tablica 13.).

Tip C1 predstavlja oblik tipične krivulje dnevne količine mlijeka, a C2 i C3 odgovaraju kontinuiranom povećanju ili smanjenju krivulje. Tip C4 odnosi se na oblik obrnute standardne krivulje, sa silaznim kretanjem u početnoj fazi laktacije i uzlaznim kretanjem nakon dostizanja minimalnih vrijednosti. U istom istraživanju su utvrdili značajno negativnu korelaciju između količine mlijeka i mliječne masti, mliječnog proteina, suhe tvari, kao i broja somatskih stanica. Isto tako su utvrdili značajno pozitivnu snažnu korelaciju između količine mlijeka i ureja. Količina ureja u mlijeku je negativno povezana sa svim ispitivanim svojstvima, osim količine proizvedenog mlijeka. Viša razina laktoze uzrokovala je značajan, ali ne i brzi pad mliječne masti.

1.1.11. Mjerila reprodukcijske uspješnosti

Uspješnost reprodukcije na mliječnim farmama očituje se u učinkovitom generiranju dovoljnog broja bređih krava u stadu kako bi se zadržala proizvodnja na željenom nivou ili stvorile pretpostavke za povećanje postojeće proizvodnje (Royal i sur., 2002.; Walsh i sur., 2011.; Lucy, 2007.) Reprodukcijska uspješnost je biološka osnova proizvodnje mlijeka. Redovitom reprodukcijom goveda se određuje vremenski ritam proizvodnje (Caput, 1996.). Količina proizvedenog mlijeka i reprodukcijska uspješnost su glavne odrednice ekonomske opravdanosti mliječnog govedarstava (Le Blanc, 2010.).

Mnogobrojna istraživanja povezala su pad plodnosti mliječnih krava uz istovremeno povećanje proizvodnje mlijeka po kravi (Butler, 1998.; Royal i sur., 2000.; Lucy, 2001.; LeBlanc, 2010.; Roche i sur., 2000.; Macmillan i sur., 1996.; López-Gatius, 2003.; Butler, 1998.). Ekonomski zahtjevi za profitabilnu proizvodnju mlijeka su potaknuli povećani selekcijski pritisak (Royal i sur.; 2002.) koji je uz promjene načina držanja, hranidbe te cjelokupnog sustav upravljanja proizvodnjom mlijeka doveo do povećanja proizvodnje što je posredno izazvalo nepovoljan utjecaj na plodnost (Walsh i sur., 2011.; Lucy, 2007.)

Suvremene selekcijske metode usmjerene na veću proizvodnju, zbog negativne genetske korelacije sa svojstvima plodnosti dovele su do visokog udjela ponovnih osjemenjivanja, prolongiranih laktacija te na kraju rezultirale ranijim izlučivanjem krava (Špehar i sur., 2012.; Pryce i sur., 1999.; Royal i sur., 1999.; Washburn i sur., 2002.). U posljednjih 40 tak godina proizvodnja mlijeka po kravi se gotovo udvostručila, ali je u istom periodu došlo i do produženja trajanja servis razdoblja za 40 dana po laktaciji. Budući da postoji pozitivna korelacija (približno +0.35) između mliječnosti i trajanja servis razdoblja, vrlo je teško održati plodnost uz povećanje proizvodnje mlijeka (Washburn i sur., 2002.). Prema Rodriguez-Martinez i sur. (2008.) povećanje proizvodnje mlijeka po kravi u posljednjim desetljećima popraćeno je sve lošijim rezultatima plodnosti.

Međutim, posljednjih nekoliko godina sve veći broj istraživača dokazuje da ipak visoka proizvodnja mlijeka, nužno ne dovodi do loših reprodukcijskih rezultata. Bello i sur. (2012.) navode da se uslijed rezultata istraživanja unazad nekoliko godina (Peters i Pursley, 2002.; López-Gatius i sur., 2003.; Le Blanc, 2010.; Löf i sur., 2007.) mijenja percepcija o univerzalnom antagonizmu između visine proizvodnje mlijeka i uspjeha u reprodukciji krava.

Prema Bello (2012.) usprkos općenitom stajalištu u mliječno govedarskom sektoru, kako postoji antagonistički odnos između produkcije mlijeka te reproduktivnih karakteristika mliječnih krava to se ne može smatrati univerzalnim pravilom. Isto tako se navodi primjer Švedske u kojoj je zabilježen najveći napredak proizvodnje mlijeka po kravi uz zadržavanje zadovoljavajućih rezultata plodnosti mliječnih krava kao posljedica zadržavanja dobrog zdravstvenog stanja krava. Kako bi se postigli najbolji mogući reprodukcijski rezultati, neophodne su dobre sposobnosti upravljanja (Zagorec, 2009.).

Uspješnost reprodukcije se izražava u broju živo oteljene teladi po kravi godišnje uz činjenicu da su goveda u 97 – 99% slučajeva uniparna. Varijacije u više reprodukcijskih osobina najvećim dijelom proizlaze iz okolišnih čimbenika, a manjim dijelom su genetski uvjetovane (tablica 14.). Prema tome, usklađeno upravljanje mliječnom farmom koje uključuje uvjete smještaja i hranidbe omogućuje postizanje dobrih reprodukcijski rezultata.

Tablica 14.: Prikaz čimbenika i njihovog utjecaja na reprodukcijske rezultate (Kumlu, 2012.)

Čimbenik	**Udio (%)**
Upravljanje proizvodnjom (management)	40
Hranidba	30
Higijenski uvjeti i bolesti	10
Smještaj	5
Genetika	15

U svrhu upravljanja reprodukcijom na mliječnim farmama koristi se niz mjerila i svojstava kojima se određuje aktualno i/ ili proteklo stanje reprodukcije stada. U procjenjivanju uspješnosti reprodukcije potrebno je sagledati što veći broj mjerila zbog izbjegavanja donošenja pogrešnih zaključaka te utvrditi odstupanja od optimalnih ili preporučenih vrijednosti sa stanjem na promatranoj populaciji.

Općenito se može napraviti podjela na vremenski definirana mjerila i mjerila koja iskazuju uspješnost reprodukcijskih postupaka odnosno osjemenjivanje, zdravlje reprodukcijskih organa, te zdravstveni nadzor prije i poslije teljenja (tablica 15.).

Tablica 15. Prikaz vremenski definiranih reprodukcijskih pokazatelja (Wattiaux, 1995.)

Reprodukcijski pokazatelj (vremenski određeni)	**Vrijednost**	
	Optimalna	**Problematična**
Prosječni servis period	85 - 110 dana	> 140 dana
Razdoblje do prvog estrusa	< 40 dana	> 60 dana
Prosječno dana do 1. osjemenjivanja	45 - 60 dana	> 60 dana
Utvrđeno grla u estrusu unutar 60 dana nakon teljenja	> 90%	< 90%
Međutelidbeno razdoblje	12,5 - 13 mjeseci	> 14 mjeseci
Prosječna dob pri 1. teljenju	24 mjeseca	< 24; > 30 mjeseci
Reprodukcijski pokazatelji (relativni)	**Vrijednost**	
	Optimalna	**Problematična**
Utvrđeno grla u estrusu unutar 60 dana nakon teljenja	> 90%	< 90%
Osjemenjivanja po koncepciji	< 1,7	> 2,5
Uspješnost prvog osjemenjivanja (junice)	65 - 70%	< 55%
Uspješnost prvog osjemenjivanja (krave u laktaciji)	50 - 60%	< 40%
Učestalost abortusa	< 5%	> 10%
Učestalost izlučivanja uslijed reprodukcijskih problema	< 10%	> 10%

Tablica 16. Prikaz ekonomski prihvatljivih pokazatelja reprodukcijske učinkovitosti (Inchraisry, 2010.)

Pokazatelji reprodukcijske učinkovitosti	Vrijednost	
	Optimalna	Preporučena
Dana do 1. osjemenjivanja	74	63 – 91
Servis razdoblje	83	67 – 130
Međutelidbeno razdoblje	362	342 – 408
Broj osjemenjivanja po kravi	1,16	1 – 2
Broj teladi po kravi godišnje	1,02	0,9 – 1,08

Ekonomski gubici u proizvodnji mlijeka kao posljedica reprodukcijskih rezultata izvan preporučenih granica najčešće se izražavaju za svaki dan produženog servis razdoblja odnosno optimalnog međutelidbenog razdoblja (tablica 16.).

Servis razdoblje i međutelidbeni razmak

Vremenski odmak od datuma posljednjeg teljenja, vremenski razmak između dva teljenja, evidencija svih osjemenjivanja i evidencija osjemenjivanja koje rezultira koncepcijom su osnovica za izračun mjera reprodukcijske učinkovitosti kojima se prikazuje vremenski trajanje reprodukcijskog ciklusa.

Servis razdoblje određeno je brojem dana između posljednjeg teljenja i osjemenjivanja koje rezultira koncepcijom. Servis razdoblje je pored trajanja graviditeta ključno za izračun međutelidbenog razdoblja ili intervala teljenja. U svrhu postizanja idealnog međutelidbenog razdoblja (365 dana) trajanje servis razdoblja ne bi trebalo biti duže od 85 dana.

(365 dana – 280 dana trajanja bređosti = 85 dana servis razdoblja)

Pored trajanja servis razdoblja u svrhu praćenja aktualnog stanja reprodukcije sve više se koristi prikazivanje trajanja razdoblja od teljenja do osjemenjivanja (*open day*) bez obzira na rezultirajuću bređost. Kada se trajanje servis razdoblja želi prikazati kao mjera koja je potpuno pod utjecajem upravljanja proizvodnjom na farmi onda se iskazuje broj dana od teljenja do osjemenjivanja koji određuje uprava farme na razini cjelokupnog stada (*voluntary waiting period*). Određivanje trenutka za prvi pripust donosi uprava farme na osnovu bioloških (zdravlje, stanje reprodukcijskih organa nakon teljenja, kondicija) i ekonomski utvrđenih kriterija (cijena mlijeka) za pojedinačnu kravi i stado u cjelini (Löf i sur., 2007.).

Međutelidbeno razdoblje ili interval teljenja predstavlja vrijeme između dva uzastopna teljenja, a određeno je trajanjem servis razdoblja i dužinom bređosti. U slučaju raspoloživosti datuma dva uzastopna teljenja istog grla interval između teljenja odnosno međutelidbeno razdoblje izračunava se na osnovu razlike između datuma teljenja te datuma prijašnjeg teljenja. Datum koncepcije određuje se oduzimanjem 280 dana od datuma teljenja (Norman i sur., 2009., ICAR, 2012.).

Općenito je u svim zemljama s razvijenim mliječnim govedarstvom prisutan negativan trend pokazatelja reprodukcijske uspješnosti izražen kroz produžavanje trajanja servis razdoblja i međutelidbenog razdoblja.

1.2. CILJ ISTRAŽIVANJA

Recentna istraživanja su dovela u pitanje opće prihvaćenu činjenicu o povezanosti visoke proizvodnje mlijeka i loših reprodukcijskih rezultata grla. Istovremeno je utvrđena povezanost negativne energetske ravnoteže i reprodukcijske uspješnosti. Mnogobrojna istraživanja su utvrdila vezu između količine i sastava proizvedenog mlijeka i energetske ravnoteže, što može koristiti pri predviđanju trajanja razdoblja od teljenja do koncepcije.

Cilj istraživanja je bio utvrditi modele obrade podataka dobivenih kontrolama mliječnosti na populaciji krava te razviti sustav predviđanja trajanja razdoblja od teljenja do koncepcije (servis razdoblje) primjenom rezultata iz prva dva kontrolna dana na početku laktacije za predviđanje reprodukcijske učinkovitosti, odnosno trajanja servis razdoblja.

Hipoteza ovog rada je da se na osnovu količine i sastava mlijeka u prve dvije kontrole mliječnosti u laktaciji može predvidjeti dužina trajanja servis razdoblja.

Provedba ovih istraživanja obavlja se radi primjene novih postupaka u uzgoju goveda koji omogućuju bolje upravljanje reprodukcijom u stadu.

Temeljni doprinos ovog istraživanja bit će modeliranje postupaka predviđanja trajanja servis razdoblja na odabranoj populaciji grla u kontroli mliječnosti u Hrvatskoj. Optimalni model predviđanja trajanja servis razdoblja moći će se primijeniti u svakodnevnom upravljanju proizvodnjom mlijeka, a posebice u dijelu koji je vezan uz reprodukcijski uspjeh. Konkurentnost proizvodnje mlijeka se temelji na racionalnom upravljanju mliječnom farmom. Kvalitetno upravljanje svim aspektima proizvodnje mlijeka posebice u početku laktacije može povećati uspješnost reprodukcije, čime se smanjuju troškovi u poslovanju. Slijedom navedenog biti će moguće primijeniti rezultate ovoga rada za upravljanje proizvodnjom mlijeka kroz detektiranje krava koje će vjerojatno imati problema u koncepciji. Ovo je posebno bitno kod grla u kojih se zbog izmijenjenih vrijednosti glavnih osobina mliječnosti može umanjiti vjerojatnost koncepcija, čime se produžava servis razdoblje i međutelidbeno razdoblje. Detektiranjem krava s manjom vjerojatnošću koncepcije posredno se može utjecati na uspješnost provedbe uzgojnih programa, poglavito u dijelu poboljšanja reproduktivnih osobina populacije.

2. MATERIJAL I METODE

2.1. Materijal

Utvrđivanje trajanja dužine servis razdoblja krava holstein i simentalske pasmine provedeno je u vremenskom razdoblju od 01.01.2008. do 31.12.2012. godine na svim gospodarstvima u Republici Hrvatskoj kod kojih je provođena kontrola mliječnosti. U analizi su korišteni podaci za krave kod kojih je u navedenom razdoblju bilo moguće izračunati trajanje servis razdoblja. Izračun trajanja dužine servis razdoblja te datuma koncepcije obavljen je kod krava koje su imale najmanje dva teljenja, oduzimanjem prosječnog trajanja graviditeta (Norman i sur., 2009., ICAR 2012.) od posljednjeg teljenja.

Prvotni skup podataka obuhvaćao je sve krave u navedenom razdoblju bez ograničenja u trajanju servis razdoblja ili ukupno 25.910 krave holstein pasmine s trajanjem servis razdoblja do 897 dana te ukupno 32.496 krave simentalske pasmine s trajanjem servis razdoblja do 1.004 dana. Iz prvotnog skupa korekcijom na trajanje servis razdoblja izdvojene su krave koje su imale trajanje servis razdoblja do 165 dana. Za logičku kontrolu podataka i osnovnu statističku obradu korišten je SAS (SAS Inst.Inc., 2011.) programski paket.

Statističkom obradom drugog seta podataka metodom analize preživljavanja i metodom logističke regresije obuhvaćeno je 14.864 krave holstein pasmine s ukupno 29.278 zapisa rezultata kontrole mliječnosti, te 18.708 krava simentalske pasmine s ukupno 37.416 zapisa rezultata kontrole mliječnosti. Veći broj krava i broj dnevnih kontrola obuhvaćenih obradom podataka za simentalsku pasminu (56%) nego kod holstein pasmine (44%) odraz je većeg broja simentalskih krava obuhvaćenih u kontroli mliječnosti nego holstein pasmine. Sve dnevne kontrole na jednom stadu obavljane su u jednom kontrolnom danu.

2.2. Priprema proizvodnih podataka

Podaci o mliječnosti za svaku kravu (količina i kemijski sastav proizvedenog mlijeka te broj somatskih stanica), datum obavljanja kontrole mliječnosti i svi datumi teljenja kontrolirane krave dobiveni su iz Središnje baze podataka Hrvatske poljoprivredne agencije.

Podaci koji se odnose na omjere masti i bjelančevina u mlijeku (IMB) dobiveni su stavljanjem u međusobni omjer mliječne masti i mliječnih bjelančevina iz dnevnih zapisa

kontrole mliječnosti. Zavisno o sadržaju mliječne masti i mliječnih bjelančevina mlijeku te njihovom međusobnom omjeru (IMB), napravljena je podjela na 3 razreda i krave su razvrstane prema slijedećem obrascu:

Tablica 17.: Kriteriji razvrstavanja u razrede omjera mliječne masti i bjelančevina (IMB)

RAZRED	OMJER MAST : BJELANČEVINE
A	< 1,1
B	1,1 – 1,5
C	> 1,5

Na osnovu međusobnog odnosa sadržaja bjelančevina i ureje u mlijeku (IBU) iz dnevnih zapisa kontrole mliječnosti učinjena je podjela na 9 razreda te su krave razvrstane prema sljedećem obrascu:

Tablica 18.: Kriteriji razvrstavanja u razrede odnosa bjelančevina i ureje u mlijeku (IBU)

RAZRED	BJELANČEVINE (%)	UREJA (mg/dl)
C1	≤ 3,2	≤ 15,00
C2	≤ 3,2	15,01 – 30,00
C3	≤ 3,2	≥ 30,01
B1	3,21 – 3,8	≤ 15,00
B2	3,21 – 3,8	15,01 – 30,00
B3	3,21 – 3,8	≥ 30,01
A1	≥ 3,81	≤ 15,00
A2	≥ 3,81	15,01 – 30,00
A3	≥ 3,81	≥ 30,01

U svrhu dobivanja normalne distribucije podaci koji se odnose na dobiveni broj somatskih stanica iz dnevnih zapisa su logaritmirani prema slijedećoj formuli:

logBSS = log2 (BSS/100000) + 3 (Ali i Shook, 1980.)

i prikazani su kao logaritamska vrijednost. Svi ovi podaci su za svaku kravu izraženi posebno za prvi i drugi kontrolirani dan u laktaciji. Pored podataka dobivenih kontrolom

mliječnosti za svaku kravu je izračunato trajanje servis razdoblja i datum koncepcije. Trajanje servis razdoblja podijeljeno je u 6 razreda. Granice razreda postavljene su prema sljedećim kriterijima:

Tablica 19.: Kriteriji razdiobe servis razdoblja

Razred	Trajanje servis razdoblja (dani)
1	20 – 60
2	61 – 82
3	83 – 102
4	103 – 123
5	124 – 144
6	145 – 165

Sezone teljenja i sezone koncepcije su određene na slijedeći način:

1. sezona = od prosinca do veljače,

2. sezona = od ožujka do svibnja,

3. sezona = od lipnja do kolovoza,

4. sezona = od rujna do studenog.

Podaci preuzeti iz središnje baze podataka HPA razvrstani su prema lokaciji pojedinog gospodarstva u određenoj županiji. a nakon toga su županije raspoređene u pet proizvodnih regija. Županije sa sličnom klimom i krajobrazom, načinom hranidbe i tradicijom u mliječnom govedarstvu razvrstane su u pet proizvodnih regija. Na ovaj način smanjena je neravnomjerna distribucija broja krava po županijama.

Tablica 20.: Razvrstavanje županija u proizvodne regije

Regija	Županija
1	Grad Zagreb i Zagrebačka županija, Međimurska, Varaždinska, Krapinsko zagorska
2	Sisačko moslavačka, Karlovačka, Ličko senjska
3	Bjelovarsko bilogorska, Koprivničko križevačka
4	Osječko baranjska, Vukovarsko srijemska, Brodsko posavska, Požeško slavonska, Virovitičko podravska
5	Zadarska, Šibensko kninska, Splitsko dalmatinska, Istarska

Cjelokupni sustav upravljanja proizvodnjom mlijeka značajno je definiran veličinom stada (način držanja, mužnje, hranidbe). S obzirom na neujednačenu veličinu stada koje su obuhvaćene kontrolom mliječnosti prije statističke obrade podataka učinjena je raspodjela stada prema broju krava prema slijedećem predlošku.

Tablica 21.: Kriteriji razvrstavanja stada prema broju krava u stadu

Razred	Broj krava u stadu
1	1 - 10
2	10 - 20
3	20 - 50
4	50 - 100
5	> 100

2.3. Kontrola mliječnosti

Kontrola mliječnosti obavljana je sukladno preporukama ICAR-a (2012.) za AT4 i BT4 metodu. Vremenski razmaci između dvije uzastopne kontrole bili su od 22 do 37 dana. Kontrolu mliječnosti kod AT4 metode provodili su djelatnici Hrvatske poljoprivredne agencije, a kod BT4 metode sami uzgajivači. Kontrola mliječnosti je obavljana tijekom jutarnje ili večernje mužnje prema unaprijed napravljenom godišnjem rasporedu koji osigurava redovitu izmjenu kontrolne mužnje (jutarnja ili večernja). Prilikom svake mužnje evidentirano je početno vrijeme aktualne te početno vrijeme prethodne mužnje.

Prva kontrola mliječnosti provedena je najranije 5., a najkasnije 35. dana nakon teljenja. Druga kontrola mliječnosti provedena je najkasnije 65. dana nakon teljenja. Mjerenje količine pomuzenog mlijeka obavljano je mjernim uređajima za koje postoji dokumentacija o provedenom postupku umjeravanja sukladno preporukama ICAR-a (2012). Osiguravanje reprezentativnosti uzorka koji se šalje na analizu u Središnji laboratorij za kvalitetu mlijeka (SLKM) osigurava se proporcionalnim uzimanjem iz ukupno pomuzene količine mlijeka svake kontrolirane krave. Uzorci mlijeka od kontroliranih krava (40 ml) stavljani su u plastične bočice u koje je prethodno stavljen konzervans azidiol (0,2 ml) s ciljem očuvanja kemijskog sastava mlijeka u razdoblju od uzorkovanja do ispitivanja u SLKM-u.

2.4. Analiza uzoraka mlijeka

Uzorak mlijeka dobiven kontrolom mliječnosti označava se bar kodom koji predstavlja poveznicu između životnog broja svake krave i samog uzorka. Prije početka provedbe analize obavlja se očitavanje bar koda čime je omogućeno povezivanje dobivenih rezultata s pripadajućim životnim brojem krave.

Središnji laboratorij za kvalitetu mlijeka djeluje u okviru Hrvatske poljoprivredne agencije, a od 2004. godine je akreditiran u skladu s međunarodnom normom HRN EN ISO/IEC 17025. Kod svih uzoraka mlijeka dobivenih kontrolom mliječnosti, metodom infracrvene spektrofotometrije (HRN ISO 9622:2001), određeni su udjeli mliječne masti, bjelančevina, laktoze, bezmasne suhe tvari i koncentracija ureje, na dva analizatora MilkoScan FT 6000 (FOSS, Danska). Mjeriteljski uvjeti osiguravaju se brojnim testiranjima, a prije svega temeljitim umjeravanjem. Umjeravanje se obavlja na temelju referentnih umjernih uzoraka njemačkog laboratorija MUVA Kempten i Referentnog laboratorija Zavoda za mljekarstvo, Agronomskog fakulteta Sveučilišta u Zagrebu.

Broj somatskih stanica određen je fluoro-opto-elektronskom metodom (HRN EN ISO 13366 – 2 : 2007) na brojačima somatskih stanica Fossomatic 5000 i Fossomatic FC (FOSS, Danska). Mjeriteljski uvjeti osiguravaju se uključivanjem u ring testove koje provodi laboratorij MIH Huefner (Njemačka) i Referentnog laboratorija Zavoda za mljekarstvo, Agronomskog fakulteta Sveučilišta u Zagrebu.

Rezultati kontrole mliječnosti koji su bili izvan preporuka ICAR-a nisu uključeni u obradu podataka (ICAR, 2012.).

Tablica 22.: Granice dnevnih vrijednosti (ICAR, 2012.)

Svojstvo	Minimum	Maksimum
Količina mlijeka (kg)	3,0	99,9
Sadržaj mliječne masti (%)	1,5	9,0
Sadržaj bjelančevina (%)	1,0	7,0

Izračun dnevne količine mlijeka i dnevnog sadržaja mliječne masti obavlja se pomoću korekcijskih faktora (DeLorenzo i Wiggans, 1986.), dok se sadržaj bjelančevina, laktoze, broja somatskih stanica i ureje kod kontrolne mužnje preuzima kao dnevni sadržaj.

2.5. Statistička obrada podataka

Razvijena su dva statistička modela za predviđanje trajanja servis razdoblja i to:

Model 1. sa sastavnicama koje proizlaze iz rezultata kontrole mliječnosti (dnevna količina mlijeka, dnevni sadržaj i količina mliječne masti i bjelančevina, omjer masti i bjelančevina, dnevni sadržaj ureje, odnos bjelančevina i ureje, dnevni sadržaj laktoze i broj somatskih stanica).

Model 2. koji pored sastavnica iz prvog modela uključuje utjecaje regije, veličine stada, sezone koncepcije i sezone teljenja.

Statistička obrada podataka u svrhu predviđanja trajanja servis razdoblja u prvoj fazi je obavljena je metodom logističke regresije pomoću LOGISTIC procedura u okviru statističkog programa SAS (SAS Inst.Inc., 2011.). Unutar svake grupe varijabli u svakom modelu metodom stupanjske regresije (*Stepwise Logistic Regression)* napravljen je izbor varijabli (Jazbec, 2001.) koje značajno utječu na dužinu trajanja servis razdoblja.

Zavisna varijabla u modelima je diskretna, binarna odnosno krava ili je ili nije koncipirala u određenom vremenskom razdoblju. U svakom regresijskom modelu ključno je odrediti očekivanu vrijednost zavisne varijable za određenu vrijednost nezavisne varijable (Grozdić, 2011.). U logističkoj regresiji moguće je odrediti predikciju zavisne varijable (koja je diskretna varijabla) na osnovu kontinuiranih i diskretnih prediktora. Logistička regresija se najčešće koristi kada relacija između zavisne (diskretne) varijable i prediktora nije linearna i onda se izvodi logit transformacija koja daje linearnu relaciju između vjerojatnosti promatranog događaja (koncepcije) i vrijednosti nezavisne varijable x prema sljedećem modelu :

$$\ln = \left(\frac{p}{1-p}\right) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_n x_n$$

Vjerojatnost (p) se izračunava prema sljedećoj jednadžbi:

$$p = \frac{e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_n x_n}}{1 + e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_n x_n}}$$

p = vjerojatnost da je krava koncipirala u određenom vremenskom razdoblju (razredu),

β_0 = intercept za svaki razred servis razdoblja,

$\beta_1 x_1$ - $\beta_n x_n$ = koeficijent regresije za odabrane varijable.

Nakon odabira varijabli metodom stupanjske regresije pomoću LOGISTIC procedure za svaki model, daljnja statistička obrada podataka obavljena je metodom logističke regresije pomoću procedure SURVEYLOGISTIC upotrebljavajući SAS programski paket.

Surveylogistic procedure su pogodne za izvođenje analize doživljavanja kada je vrijeme u kojem se dogodio neki događaj (vrijeme kada je krava koncipirala) podijeljeno u više razreda – *discrete time*. U istraživanju se utvrđuje mogućnost primjene rezultata kontrole mliječnosti na prva dva kontrolna dana za predviđanje reprodukcijske učinkovitosti odnosno trajanja servis perioda.

S obzirom da je trajanje servis razdoblja podijeljeno u više vremenskih intervala onda je povezanost između dnevne količine i sastava mlijeka utvrđenih pri prve dvije kontrole mliječnosti nakon teljenja, te vjerojatnosti koncepcije u svakom od definiranih intervala modelirana uporabom *discrete-time survival models* (Yang i Goldstein, 2003.). Analiza podataka o povijesti događaja ili survival analiza (analiza preživljavanja) se odnosi na statističku analizu vremena u kojem se događaj od interesa javlja (Kalbfleisch i Prentice, 2002.; Allison, 1995.). Za primjenu analize preživljavanja podaci moraju sadržavati vrijeme nekog događaja koji se prati. Analiza preživljavanja je grupa statističkih metoda za proučavanje slučajnosti i vremena zbivanja nekog događaja. Ove metode najčešće se primjenjuju za proučavanje vremena smrti zbog čega su i izvorno kreirane, a po čemu je ova analiza i dobila ime, iako je njezina potencijalna primjenjivost mnogo šira (Allison, 1995.). U istraživanjima povezanim s mliječnim sektorom uobičajeno se koristi za istraživanja dugovječnosti proizvodnih grla (Raguž, 2010.). Kalbfleisch i Prenticeu (2002.), navode da je analiza preživljavanja „umjetnost“ kombiniranja informacija o cenzuriranim i necenzuriranim zapisima.

U pogledu podataka obuhvaćenih ovim istraživanjem obavljeno je intervalno cenzuriranje prema razredima servis razdoblja jer je riječ o podacima koji su raspređeni unutar formiranih vremenskih razdoblja (*discrete time*). Krave koje nisu ostale bređe u npr. prvom razredju trajanja servis razdoblja do 60 dana su necenzurirane, a ako su ostale bređe u tom razdoblju onda su bile cenzurirane i nakon toga se više ne prate.

Svrha analize preživljavanja sastoji se u mogućnosti predviđanja, tj. uspostavljanja prediktivnog modela u kojem rizik promatranog događaja ovisi o varijablama.

Funkcija preživljavanja je definirana kao vjerojatnost ***(P)*** da je vrijeme preživljavanja veće ili jednako nekom vremenu ***t***, tj. predstavlja vjerojatnost da određena krava još nije ostala bređa o određenom vremenskom razdoblju:

$$S\ (t) = funkcija\ preživljavanja = P\ (T > t\ )$$

gdje je:

S(t) – funkcija preživljavanja,

T – vrijeme dok krava nije koncipirala,

t = razred trajanja servis razdoblja.

Uspoređivanje vremena trajanja servis razdoblja po pasminama odnosno projekcija odgovarajućih funkcija preživljavanja učinjena je pomoću Kaplan-Meirove krivulje pomoću LIFETEST procedura upotrebljavajući SAS programski paket.

2.6. Statistički modeli

Statistički modeli za procjenu trajanja servis razdoblja za obje pasmine i a kontrolna dana prikazani su tablicama u nastavku.

Tablica 23.: Statistički modeli za procjenu trajanja servis razdoblja za holstein pasminu

Model 1. Kontrolni dan 1.	$\mathbf{p} = \frac{e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3}}{1 + e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3}}$
	$\mathbf{ln} = \left(\frac{p}{1-p}\right) = \boldsymbol{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3}$
Model 1. Kontrolni dan 2.	$\mathbf{p} = \frac{e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2}}{1 + e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2}}$
	$\mathbf{ln} = \left(\frac{p}{1-p}\right) = \boldsymbol{\beta_0 + \beta_1 x_1 + \beta_2 x_2}$
Model 2. Kontrolni dan 1.	$\mathbf{p} = \frac{e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_7 x_7 + \beta_8 x_8 + \beta_9 x_9 + \beta_{10} x_{10}}}{1 + e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_7 x_7 + \beta_8 x_8 + \beta_9 x_9 + \beta_{10} x_{10}}}$
	$\mathbf{ln} = \left(\frac{p}{1-p}\right) = \boldsymbol{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_7 x_7 + \beta_8 x_8 + \beta_9 x_9 + \beta_{10} x_{10}}$
Model 2. Kontrolni dan 2.	$\mathbf{p} = \frac{e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_7 x_7 + \beta_8 x_8 + \beta_{10} x_{10}}}{1 + e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_7 x_7 + \beta_8 x_8 + \beta_{10} x_{10}}}$
	$\mathbf{ln} = \left(\frac{p}{1-p}\right) = \boldsymbol{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_7 x_7 + \beta_8 x_8 + \beta_{10} x_{10}}$

Tablica 24.: Statistički modeli za procjenu trajanja servis razdoblja za simentalsku pasminu

Model 1. Kontrolni dan 1.	$\mathbf{p = \frac{e^{\beta_0 + \beta_1 x_1 + \beta_3 x_3 + \beta_4 x_4 + \beta_5 x_5}}{1 + e^{\beta_0 + \beta_1 x_1 + \beta_3 x_3 + \beta_4 x_4 + \beta_5 x_5}}}$
	$\mathbf{\ln = \left(\frac{p}{1-p}\right) = \beta_0 + \beta_1 x_1 + \beta_3 x_3 + \beta_4 x_4 + \beta_5 x_5}$
Model 1. Kontrolni dan 2.	$\mathbf{p = \frac{e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_4 x_4}}{1 + e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_4 x_4}}}$
	$\mathbf{\ln = \left(\frac{p}{1-p}\right) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_4 x_4}$
Model 2. Kontrolni dan 1.	$\mathbf{p = \frac{e^{\beta_0 + \beta_1 x_1 + \beta_3 x_3 + \beta_4 x_4 + \beta_5 x_5 + \beta_7 x_7 + \beta_8 x_8 + \beta_9 x_9}}{1 + e^{\beta_0 + \beta_1 x_1 + \beta_3 x_3 + \beta_4 x_4 + \beta_5 x_5 + \beta_7 x_7 + \beta_8 x_8 + \beta_9 x_9 + \beta_{10} x_{10}}}}$
	$\mathbf{\ln = \left(\frac{p}{1-p}\right) = \beta_0 + \beta_1 x_1 + \beta_3 x_3 + \beta_4 x_4 + \beta_5 x_5 + \beta_7 x_7 + \beta_8 x_8 + \beta_9 x_9}$
Model 2. Kontrolni dan 2.	$\mathbf{p = \frac{e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_4 x_4 + \beta_6 x_6 + \beta_7 x_7 + \beta_8 x_8 + \beta_9 x_9 + \beta_{11} x_{11}}}{1 + e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_4 x_4 + \beta_6 x_6 + \beta_7 x_7 + \beta_8 x_8 + \beta_9 x_9 + \beta_{11} x_{11}}}}$
	$\mathbf{\ln = \left(\frac{p}{1-p}\right) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_4 x_4 + \beta_6 x_6 + \beta_7 x_7 + \beta_8 x_8 + \beta_9 x_9 + \beta_{11} x_{11}}$

U tablici 23. i 24. simboli predstavljaju sljedeće:

β_0 = konstantni član,

β_1 = koeficijent regresije,

x_1 = dnevni sadržaj bjelančevina,

x_2 = broj somatskih stanica,

x_3= dnevni sadržaj laktoze,

x_4 = omjer masti i bjelančevina,

x_5= dnevni sadržaj ureje,

x_6 = dnevna količina mlijeka,

x_7 = sezona koncepcije,

x_8 = sezona teljenja,

x_9= veličina stada,

x_{10} = regija,

x_{11} = odnos bjelančevina i ureje.

2.7. Ispitivanje sukladnosti ispitivanih modela

Za uspoređivanje stvarnih s predviđenim vrijednostima na osnovi modela korišten je Akaike Information Criterion (AIC), koji je temeljen na logaritmu funkcije vjerojatnosti. Model s najmanjim AIC vrijednostima smatra se najboljim modelom (Gagne i Dayton, 2002.). Veličina brojčanog izraza za pojedinačni model nema objašnjavajućeg značenja i ona se ne tumači zasebno.

Tablica 25.: AIC vrijednosti za modele po kontrolnim danima

Holstein pasmina				**Simentalska pasmina**			
Kontrolni dan 1.		**Kontrolni dan 2.**		**Kontrolni dan 1.**		**Kontrolni dan 2.**	
Model 1.	50271.328	Model 1.	50643.852	Model 1.	59692.630	Model 1.	61644.014
Model 2.	49297.863	Model 2.	49546.382	Model 2.	57734.006	Model 2.	59654.937

U tablici 25. su prikazane zajedničke AIC vrijednosti za konstantni član i varijable uključene u pojedine modele. Iz tablice je razvidno smanjenje vrijednosti AIC od prvog do drugog modela za obadvije pasmine i obadva kontrolna dana. Svaki model s većim rednim brojem sadrži varijable iz prethodnog modela uz nadogradnju s novim varijablama koje su doprinijele boljem slaganju registriranih i predviđenih podataka.

Interpretacija sukladnosti predloženih modela pomoću R^2 u logističkoj regresiji postaje sve raširenija zbog jasne distinkcije između predloženih modela. Model s većim R^2 vrijednostima od početnog modela je bolji model s obzirom na postignutu sukladnost podataka (Shtatland i sur., 2002.).

Tablica 26.: Vrijednosti R^2 za modele po kontrolnim danima

Holstein pasmina				**Simentalska pasmina**			
Kontrolni dan 1.		**Kontrolni dan 2.**		**Kontrolni dan 1.**		**Kontrolni dan 2.**	
Model 1.	0,0053	Model 1.	0,0095	Model 1.	0,0040	Model 1.	0,0043
Model 2.	0,0768	Model 2.	0,0840	Model 2.	0,1125	Model 2.	0,1099

U tablici 26. su prikazane vrijednosti R^2 za predložene modele po pasminama i kontrolnim danima. Vidljivo je povećanje vrijednosti R^2 za svaki model s većim rednim brojem u odnosu na početni model, ali i model koji prethodi aktualnom modelu. Kao i kod AIC vrijednosti svaki model s većim rednim brojem sadrži varijable iz prethodnog modela uz nadogradnju s novim varijablama koje su doprinijele boljem slaganju registriranih i predviđenih podataka. Model s većim rednim brojem sadrži veći broj prediktora i ima veći R^2 od predloženih modela.

2.8. Ispitivanje mogućnosti modela za predviđanje

Ispitivanje snage modela za predviđanje događaja prikazano je pomoću indeksa konkordancije koji predstavlja sukladnost slaganja registriranih i predviđenih podataka unutar svakog modela.

Vrijednosti indeksa konkordancije kreću se od 0,5 (model bez snage diskriminacije) do 1 (izvanredno razdvajanje). Indeks konkordancije se podudara s vrijednostima površine ispod ROC (Receiver Operating Characteristic Curve) krivulje (Hosmer i sur., 2000.).

Tablica 27.: Odnosa snage modela za predviđanje i stvarno utvrđenih događaja

Holstein pasmina				**Simentalska pasmina**			
Kontrolni dan 1.		**Kontrolni dan 2.**		**Kontrolni dan 1.**		**Kontrolni dan 2.**	
Model 1.	0,530	Model 1.	0,539	Model 1.	0,527	Model 1.	0,526
Model 2.	0,593	Model 2.	0,604	Model 2.	0,677	Model 2.	0,676

U tablici 27. su prikazane vrijednosti indeksa konkordancije za predložene modele po pasminama i kontrolnim danima. Vidljivo je povećanje vrijednosti za svaki model s većim rednim brojem u odnosu na početni model. Najmanji indeks konkordancije zabilježen je u prvom modelu, a najveći u drugom.

Utvrđeno je povećanja indeksa konkordancije s povećanjem broja prediktora u modelu pa model s većim rednim brojem koji sadrži veći broj prediktora ima veći indeks konkordancije od modela s manjim brojem prediktora.

3. REZULTATI ISTRAŽIVANJA I RASPRAVA

Rezultati istraživanja podijeljeni su u četiri cjeline. U prvoj cjelini prikazana je varijabilnost (opisna statistika) količine i sastava mlijeka po kontrolnom danu i razredima trajanja servis razdoblja, udjela koncepcija i teljenja po sezonama, razredima veličine stada te regijama zasebno za svaku pasminu (holstein, simentalska). U drugoj cjelini prikazane su korelacije između trajanja servis razdoblja i rezultata provedbe kontrole mliječnosti te korelacije između pojedinih svojstava utvrđenih provedbom kontrole mliječnosti (dnevna količina i sastav mlijeka) posebno po pasminama. U trećoj cjelini prikazani su rezultati analize trajanja servis razdoblja po pasminama i kontrolnim danima metodom logističke regresije uz prikaz omjera izgleda za osobine koje su izdvojene kao statistički značajne. U četvrtoj cjelini prikazane su krivulje preživljavanja trajanja servis razdoblja po pasminama, regijama, veličini stada, sezoni koncepcije i sezoni teljenja.

3.1. Varijabilnost količine i sastava mlijeka po kontrolnom danu

Varijabilnost svojstava rezultata provedbe kontrole mliječnosti po pasminama i kontrolnim danima obuhvaća prikaz srednje, minimalne i maksimalne vrijednosti te standardne devijacije za svojstva dnevne kvantitete i kvalitete mlijeka.

Tablica 28. Varijabilnost dnevne količine i sastava mlijeka krava ovisno o rednom broju kontrole za holstein pasminu

Varijable	Pasmina	Redni broj kontrole	Broj kontrola	min	$\bar{x}$	max	sd
Dnevna količina mlijeka	**HF**	1	14.864	3,21	27,08	50,00	8,00
		2	14.864	3,46	28,55	50,00	8,40
Dnevna količina masti	**HF**	1	14.864	0,08	1,14	3,33	0,44
		2	14.864	0,10	1,09	3,18	0,42
Dnevni sadržaj masti	**HF**	1	14.864	1,5	4,21	7,00	1,04
		2	14.864	1,5	3,83	7,00	0,90
Dnevna količina bjelančevina	**HF**	1	14.864	0,10	0,87	1,92	0,26
		2	14.864	0,10	0,86	2,51	0,26
Dnevni sadržaj bjelančevina	**HF**	1	14.864	1,99	3,22	5,89	0,40
		2	14.864	1,73	3,04	5,64	0,31
Omjer masti i bjelančevina	**HF**	1	14.864	0,33	1,32	2,92	0,33
		2	14.864	0,40	1,27	2,96	0,31
Dnevni sadržaj ureje	**HF**	1	14.864	1,00	21,23	67,9	9,77
		2	14.864	1,00	21,79	66,00	9,92
Dnevni sadržaj laktoze	**HF**	1	14.864	2,37	4,48	5,11	0,29
		2	14.864	2,43	4,55	5,23	0,19
Broj somatskih stanica (log)	**HF**	1	14.864	-3,10	3,58	11,01	2,12
		2	14.864	-2,10	3,23	10,19	2,15

Tablica 29. Varijabilnost dnevne količine i sastava mlijeka krava ovisno o rednom broju kontrole za simentalsku pasminu

Varijable	Pasmina	Redni broj kontrole	Broj kontrola	min	$\bar{x}$	max	sd
Dnevna količina mlijeka	**SIM**	1	18.708	3,10	21,69	49,65	5,90
		2	18.708	3,85	21,07	49,87	6,17
Dnevna količina masti	**SIM**	1	18.708	0,11	0,90	2,83	0,32
		2	18.708	0,09	0,82	2,90	0,31
Dnevni sadržaj masti	**SIM**	1	18.708	1,50	4,12	7,00	0,91
		2	18.708	1,50	3,89	6,98	0,83
Dnevna količina bjelančevina	**SIM**	1	18.708	0,13	0,71	1,80	0,21
		2	18.708	0,10	0,65	2,05	0,20
Dnevni sadržaj bjelančevina	**SIM**	1	18.708	2,11	3,27	5,98	0,41
		2	18.708	1,84	3,08	5,90	0,33
Omjer masti i bjelančevina	**SIM**	1	18.708	0,34	1,27	3,03	0,29
		2	18.708	0,41	1,27	3,20	0,28
Dnevni sadržaj ureje	**SIM**	1	18.708	1,00	16,86	69,60	10,01
		2	18.708	1,00	16,99	68,10	10,30
Dnevni sadržaj laktoze	**SIM**	1	1.8708	2,10	4,51	5,29	0,20
		2	18.708	2,68	4,55	5,41	0,20
Broj somatskih stanica (log)	**SIM**	1	18.708	-3,10	3,31	10,19	2,14
		2	18.708	-2,10	3,06	16,29	2,21

Iz tablica 28. i 29. razvidno je da su utvrđene srednje vrijednosti analiziranih svojstava (dnevne količine masti, dnevnog sadržaja masti, dnevne količine bjelančevina, dnevnog sadržaja bjelančevina, omjera mast : bjelančevina i broja somatskih stanica) bile veće u prvom, nego u drugom kontrolnom dana kod obje pasmine. Trend smanjenja sadržaja mliječne masti i bjelančevina na početku laktacije te usporenog podizanja nakon postignutog minimuma utvrdili su i Wood (1976.), Shutz i sur. (1990.), Stanton i sur. (1992.), Vasconcelos i sur. (2003.), Quinn i sur. (2006.), te Madouasse (2009.). Snižavanje vrijednosti omjera mast : bjelančevina na početku laktacije utvrđeno u ovom istraživanju sukladno je rezultatima istraživanja de Vries i Verkampa (2000.) te Buttchereita i sur. (2010.), a nastaje prvenstveno kao posljedica smanjivanja sadržaja mliječne masti. Utvrđeno smanjivanje broja somatskih stanica kod drugog kontrolnog dana u ovom istraživanju sukladno je smanjivanju broja somatskih stanica utvrđenom u istraživanjima koja su proveli Reents i sur. (1995.) te Dodenhoff i Emmerling (2008.). Broj somatskih stanica je povećan u kolostralnom (prvom tjednu laktacije) razdoblju, a nakon toga slijedi opadanje broja somatskih stanica do vrha laktacije (Schepers i sur., 1997.). Krave holstein pasmine imaju veći broj somatskih stanica pri oba kontrolna dana u odnosu na krave

simentalske pasmine što je sukladno rezultatima istraživanja Vicario i Carnier (2010.) te Ivkić i sur. (2012.).

Iz navedenih tablica razvidno je da su utvrđene srednje vrijednosti za dnevni sadržaj ureje i dnevni sadržaj laktoze veće u drugom, nego u prvom kontrolnom danu kod obje pasmine. Povećanje sadržaja ureje u mlijeku kod drugog kontrolnog dana sukladno je istraživanjima Johnson i Young (2003.) te Rajala-Shultz i Saville (2003.) u kojima promjena sadržaja ureje prati tijek laktacijske krivulje te svoju najveću vrijednost dostiže u vrhu laktacije. Utvrđeno povećanje sadržaja laktoze u drugom u odnosu na prvi kontrolni dan kod obje pasmine sukladno je rezultatima istraživanja Pollota (2004.).

Srednje vrijednosti za dnevnu količinu mlijeka kod holstein pasmine veće su u drugom nego li u prvom kontrolnom danu dok su kod simentalske pasmine veće u prvom nego u drugom kontrolnom danu. Laktacijska krivulja za dnevnu količinu mlijeka ima rastući trend nakon teljenja do dostizanja najveće dnevne proizvodnje u vrhu laktacije. Vrh laktacijske proizvodnje za dnevnu količinu mlijeka događa se između četvrtog i osmog tjedna nakon teljenja (Schultz i sur., 1990.; Stanton i sur., 1992.). Krave simentalske pasmina u Republici Hrvatskoj dolaze u vrh laktacije već u prvom mjesecu laktacije (Špehar, 2010.), što je sukladno utvrđenim većim vrijednostima za prvi kontrolni dan u predmetnom istraživanju.

3.1.1. Opisna statistika odnosa masti i bjelančevina u mlijeku

Udio krava u pojedinom razredu omjera masti i bjelančevina ovisno o kontrolnom danu i pasmini prikazan je u tablici 30.

Tablica 30. Udio krava po pojedinim razredima omjera masti i bjelančevina (IMB) u mlijeku ovisno o kontrolnom danu i pasmini

IMB	Holstein		Simentalska	
	Kontrolni dan 1.	Kontrolni dan 2.	Kontrolni dan 1.	Kontrolni dan 2.
A	24,33	18,36	17,89	16,69
B	43,64	48,43	50,45	54,08
C	32,03	33,21	31,66	29,23
Ukupno	100	100	100	100

Razvidno je da se najveći udio krava obije pasmine (holstein 46,43 % i 48,43 % te simentalska pasmina 50,45 % i 54,08 %) nalazi u B razredu kojeg karakterizira optimalan omjer mliječna mast : bjelančevine u vrijednosti 1,1 – 1,5. Najveći udio krava u A razredu u kojem je omjer mliječna mast : bjelančevine < 1,1 zabilježen je u prvom kontrolnom danu i to za holstein pasminu 24,33 % te 17,89 % za simentalsku pasminu. Udio krava koje se nalaze u C razredu u kojem je omjer mliječna mast : bjelančevine > 1,5 najveći je u drugom kontrolnom danu za holstein pasminu (33,21%) te prvom kontrolnom danu za simentalsku pasminu (31,66 %). Rezultati predmetnog istraživanja ukazuju na niže vrijednosti udjela A i B razreda te veće vrijednosti udjela C razreda od rezultata dobivenih u ranije provedenim istraživanjima u Republici Hrvatskoj (Jovanovac i sur. (2007.) te Kuterovac i sur. (2005.)). Smanjenje udjela krava u drugom kontrolnom danu u A razredu kod holstein pasmine ukazuje na uravnoteženje energetskih zahtjeva u ovom razdoblju. Više vrijednosti međusobnog omjera masti i bjelančevina su indikator veće vjerojatnosti pojave metaboličkih poremećaja i pojave ketoze kod holstein pasmine nego li kod simentalske pasmine na početku laktacije.

Tablica 31. Udio krava po pojedinim razredima omjera masti i bjelančevina (IMB) u mlijeku ovisno o sezoni i pasmini

SEZONA	Pasmina	RAZRED			
		A	B	C	UKUPNO
1	Holstein	21,25	46,08	32,67	100
	Simentalska	16,95	53,42	29,63	100
2	Holstein	24,19	46,34	29,48	100
	Simentalska	20,74	52,93	26,33	100
3	Holstein	21,98	47,34	30,68	100
	Simentalska	16,66	51,72	31,63	100
4	Holstein	18,18	45,04	36,78	100
	Simentalska	13,59	50,18	36,24	100

Udio krava po pojedinim razredima omjera mliječne masti i bjelančevina ovisno o sezoni i pasmini prikazan je u tablici 31. Najveći udio krava obje pasmine u svim sezonama nalazi u B razredu (omjer mast : bjelančevine u intervalu 1,1 – 1,5). Najveći udio krava holstein pasmine u A razredu (24,19 %) bilježi se u drugoj sezoni odnosno od ožujka do svibnja, a najmanji udio je u četvrtoj sezoni odnosno od rujna do studenog (18,18 %). Isto tako, najveći udio krava simentalske pasmine u A razredu (20,74 %) nalazi se u drugoj sezoni, a najmanji udio je u četvrtoj sezoni (13,59 %). Prema ovim rezultatima krave imaju najveću sklonost prema pojavi acidoze u razdoblju od ožujka do svibnja.

Najveći udio grla holstein pasmine u C razredu (36,78 %) nalazi se u četvrtoj sezoni odnosno od rujna do studenog, a najmanji udio je u drugoj sezoni odnosno od ožujka do svibnja (29,48%). Isto tako, najveći udio grla simentalske pasmine u C razredu (36,24 %) nalazi se u četvrtoj sezoni, a najmanji udio je u drugoj sezoni (26,33 %).

Sukladno utvrđenim udjelima krava u pojedinim razredima omjera masti : bjelančevina vidljiva je nepovoljnija razdioba za holstein pasminu u odnosu na simentalsku pasminu. Niže vrijednosti međusobnog omjera masti i bjelančevina (≤ 1,1) kod holstein pasmine su indikator veće vjerojatnosti pojave metaboličkih poremećaja i pojave acidoze, kao što su više vrijednosti međusobnog omjera masti i bjelančevina (≥ 1,5) indikator veće vjerojatnosti pojave metaboličkih poremećaja i pojave ketoze na početku laktacije kod holstein pasmine nego li kod simentalske pasmine.

3.1.2. Varijabilnost odnosa bjelančevina i ureje u mlijeku

Međusobni odnos sadržaja bjelančevina i ureje u mlijeku upotrebljava se za ocjenjivanje hranidbenog statusa mliječnih krava s naglaskom na opskrbljenost probavljivim bjelančevinama i energijom na početku laktacije (Eicher, 2004.; Babnik i sur., 2004.; Gantner i sur., 2006.). Udio krava u pojedinom razredu odnosa bjelančevina i ureje (IBU) u mlijeku ovisno o kontrolnom dani i pasmini prikazan je u tablici 32.

Tablica 32. Udio krava u pojedinom razredu odnosa bjelančevina i ureje (IBU) u mlijeku ovisno o kontrolnom dani i pasmini

IBU	Holstein		Simentalska		Opskrbljenost	
	Kontrolni dan 1.	Kontrolni dan 2.	Kontrolni dan 1.	Kontrolni dan 2.	Probavljivim bjelančevinama	Energijom
A1	2,31	0,57	4,51	1,20	Nedostatna	U suvišku
A2	4,14	0,74	4,14	1,08	Zadovoljavajuća	U suvišku
A3	1,25	0,35	1,05	0,38	U suvišku	U suvišku
B1	10,20	5,95	19,98	13,39	Nedostatna	Zadovoljavajuća
B2	19,58	13,40	15,50	11,60	Zadovoljavajuća	Zadovoljavajuća
B3	6,12	4,04	4,25	3,01	U suvišku	Zadovoljavajuća
C1	19,54	23,02	28,27	38,23	Nedostatna	Nedostatna
C2	27,69	38,29	17,65	23,91	Zadovoljavajuća	Nedostatna
C3	9,17	13,64	4,65	7,20	U suvišku	Nedostatna
Ukupno	100	100	100	100		

Kod obje pasmine razred B2 (sadržaj bjelančevina 3,21 – 3,8 % i ureje 15,01 – 30,00 mg/dl) je veći u prvom (19,58 % i 15,50 %), nego u drugom kontrolnom danu (13,40 % i 11,60 %). Krave koje se nalaze u ovom razredu imaju optimalan odnos sadržaja bjelančevina i ureje te imaju zadovoljavajuću opskrbljenost probavljivim bjelančevinama i energijom. Iz tablice 32. je vidljivo da je kod holstein pasmine najveći udio pri oba kontrolna dana zauzima razred C2 (sadržaj bjelančevina ≤ 3,2 % i ureje 15,01 – 30,00 mg/dl). Krave koje se nalaze u ovom razredu su zadovoljavajuće opskrbljene probavljivim bjelančevinama, ali imaju nepodmirene potrebe za energijom. Kod simentalske pasmine najveći udio kod oba kontrolna dana zauzima razred C1 (sadržaj bjelančevina ≤ 3,2 % i ureje ≤ 15,00 mg/dl). Krave koje se nalaze u ovom razredu su imaju nepodmirene potrebe u probavljivim bjelančevinama i energiji. Rezultati predmetnog istraživanja ukazuju nedostatnu opskrbu energijom u početku laktacije te su u suglasju s prije provedenim istraživanjima u Republici Hrvatskoj (Gantner i sur., 2006.).

Tablica 33. Udio krava u pojedinom razredu odnosa bjelančevina i ureje (IBU) u mlijeku ovisno o sezoni i pasmini

Sezona	**IBU**										**Ukupno**
	Razred	**A1**	**A2**	**A3**	**B1**	**B2**	**B3**	**C1**	**C2**	**C3**	
1	**Holstein**	1,63	2,77	0,77	9,23	18,96	5,73	21,11	30,15	9,67	100
	Simentalska	3,27	3,24	0,81	20,36	14,06	3,47	33,23	17,63	3,93	100
2	**Holstein**	2,01	2,57	0,87	10,55	17,18	4,18	25,26	28,71	8,68	100
	Simentalska	3,66	2,49	0,41	19,19	11,93	2,46	39,33	17,07	3,46	100
3	**Holstein**	1,29	2,22	0,59	6,73	13,70	4,41	19,94	37,49	13,62	100
	Simentalska	2,45	2,18	0,79	12,03	12,97	3,88	30,59	26,30	8,81	100
4	**Holstein**	0,68	2,02	0,87	4,76	14,16	5,57	17,99	38,69	15,26	100
	Simentalska	1,50	2,22	0,92	11,46	15,38	5,23	26,93	26,36	10,00	100

Udio krava u pojedinom razredu odnosa bjelančevina i ureje u mlijeku ovisno o sezoni i pasmini prikazan je u tablici 33. Razvidno je da se najveći udio holstein krava u svim sezonama nalazi u razredu C2 (sadržaj bjelančevina ≤ 3,2 % i ureje 15,01 – 30,00 mg/dl) u kojem su krave nedostatno opskrbljene s energetskim potrebama. Posebice se ističe povećan udio krava u C2 razredu u trećoj sezoni od lipnja do kolovoza (37,49 %) te četvrtoj sezoni od rujna do studenog (38,69 %).

Najveći udio krava simentalske pasmine u svim sezonama nalazi u razredu C1 (sadržaj bjelančevina ≤ 3,2 % i ureje ≤ 15,00 mg/dl) u kojem su krave nedostatno

opskrbljene na probavljivim bjelančevinama i energijom. Posebice se ističe povećan udio krava u C1 razredu u drugoj sezoni odnosno od ožujka do svibnja (39,33 %). Kod holstein pasmine razred B2 kao razred s optimalnom opskrbljenošću probavljivim bjelančevinama i energijom najveći je u prvoj sezoni od prosinca do veljače (18,96 %), a najmanji u trećoj sezoni od lipnja do kolovoza (13,70 %). Kod simentalske pasmine razred B2 je najveći u četvrtoj sezoni od rujna do studenog (15,38 %), a najmanji u drugoj sezoni od ožujka do svibnja (11,93 %).

Utvrđeni udio krava holstein pasmine u pojedinom razredu odnosa bjelančevina i ureje u mlijeku ovisno o sezoni upućuje na posebno nepovoljnu energetsku opskrbljenost krava koje laktaciju započinju u drugoj polovici godine. Kod simentalske pasmine krava, s gledišta energetske opskrbljenosti, proljetno je razdoblje je izrazito nepovoljno.

3.1.3. Varijabilnost količine i sastava mlijeka po sezonama

Opisna statistika svojstava rezultata provedbe kontrole mliječnosti po sezonama za holstein pasminu obuhvaća prikaz srednje, minimalne i maksimalne vrijednosti te standardne devijacije za slijedeća svojstva: dnevna količina mlijeka (kg), dnevna količina masti (kg), dnevni sadržaj masti (%), dnevna količina bjelančevina (kg), dnevni sadržaj bjelančevina (%), omjer masti i bjelančevina, dnevni sadržaj ureje (mg/dl), dnevni sadržaj laktoze (%), broj somatskih stanica (log bss).

Sezone u kojima su izmjerene prikazane srednje vrijednosti rezultata dobivenih provedbom kontrole mliječnosti su određene prema godišnjim dobima:

1. sezona od prosinca do veljače (I SEZ)
2. sezona od ožujka do svibnja (II SEZ)
3. sezona od lipnja do kolovoza (III SEZ)
4. sezona od rujna do studenog (IV SEZ).

Metodom analize varijance (ANOVA) utvrđene su statistički značajne razlike dobivenih rezultata kontrole mliječnosti između definiranih sezona.

Varijabilnost dnevne količine i sastava mlijeka krava ovisno o sezoni za holstein pasminu prikazana je u tablici 34. dok je varijabilnost dnevne količine i sastava mlijeka krava ovisno o sezoni za simentalsku pasminu prikazana u tablici 35. Najveće vrijednosti za dnevnu količinu mlijeka u holstein pasmine u iznosu od 28,63 kg utvrđene su od prosinca do veljače (I SEZ), a najmanje vrijednosti od 27,95 kg utvrđene su u periodu od

lipnja do kolovoza (III SEZ). Najveće vrijednosti dnevne količine mlijeka kod simentalske pasmine u iznosu od 22,43 kg utvrđene su u periodu od ožujka do svibnja (II SEZ), dok su najmanje vrijednosti u iznosu od 20,49 kg utvrđene u periodu od rujna do studenog (IV SEZ).

Tablica 34. Varijabilnost dnevne količine i sastava mlijeka krava ovisno o sezoni za holstein pasminu

Svojstvo	Sezona	min	$\bar{x}$	max	sd	Duncan
Dnevna količina mlijeka	1	3,21	28,63	49,90	8,53	A
	2	4,37	28,39	49,90	8,13	A
	3	3,77	27,05	50,00	7,95	B
	4	3,46	27,29	50,00	8,11	B
Dnevna količina masti	1	0,17	1,18	3,28	0,45	A
	2	0,15	1,13	3,31	0,43	B
	3	0,12	1,02	3,14	0,39	C
	4	0,08	1,10	3,33	0,42	D
Dnevni sadržaj masti	1	1,50	4,14	7,00	1,02	A
	2	1,51	4,00	7,00	0,98	B
	3	1,50	3,81	7,00	0,95	C
	4	1,50	4,03	7,00	0,97	B
Dnevna količina bjelančevina	1	0,10	0,90	1,92	0,27	A
	2	0,13	0,87	1,97	0,26	B
	3	0,10	0,82	2,52	0,24	C
	4	0,10	0,86	1,91	0,26	D
Dnevni sadržaj bjelančevina	1	1,76	3,17	5,87	0,37	A
	2	1,73	3,07	5,89	0,35	B
	3	1,99	3,04	5,84	0,37	C
	4	1,76	3,16	5,87	0,37	A
Omjer mast : bjelančevine	1	0,33	1,31	2,92	0,33	A
	2	0,36	1,31	2,72	0,33	A
	3	0,35	1,26	2,81	0,32	B
	4	0,38	1,28	2,96	0,31	C
Dnevni sadržaj ureje	1	1,00	19,46	64,90	9,67	A
	2	1,00	21,06	64,00	9,41	B
	3	1,20	24,78	67,50	9,85	C
	4	1,10	21,64	67,90	9,71	D
Dnevni sadržaj laktoze	1	3,05	4,53	5,18	0,20	A
	2	2,43	4,55	5,18	0,20	B
	3	2,37	4,50	5,02	0,22	C
	4	2,60	4,49	5,23	0,20	D
Broj somatskih stanica (log)	1	-3,10	3,25	11,01	2,13	B
	2	-2,10	3,25	10,19	2,15	C
	3	-3,10	3,64	10,36	2,18	A
	4	-3,10	3,39	10,19	2,13	B

Niže vrijednosti dnevne količine mlijeka tijekom mjeseci s višim temperaturama, odnosno više vrijednosti tijekom mjeseci s nižim temperaturama utvrđene su i u drugim istraživanjima (West, 2003., Marenjak i Poljičak, 2007., Mellado i sur., 2011., Bendelja i sur., 2011.). Utjecaj sezone teljenja odnosno početka laktacije na količine proizvedenog mlijeka očituje se kroz mogućnost osiguravanja ujednačene hranidbe tijekom cijele godine te kroz djelovanje nepovoljnih klimatskih faktora koji mogu smanjiti mogućnost konzumacije ponuđenih krmiva. Kod holstein pasmine nisu utvrđene statistički značajne razlike između prve i druge te između treće i četvrte sezone, dok su kod simentalske pasmine utvrđene statistički značajne razlike između svih sezona. Ovo upućuje na ujednačeniji hranidbeni režim tijekom godine kod gospodarstava koje uzgajaju holstein pasminu od onih koji uzgajaju simentalsku pasminu.

Najviše srednje vrijednosti dnevne količine masti u holstein (1,18 kg) i simentalske (0,92 kg) pasmine, te najviše srednje vrijednosti dnevnog sadržaja masti u holstein (4,14%) i simentalske (4,20%) utvrđene su periodu od prosinca do veljače (I SEZ). Najniže srednje vrijednosti dnevne količine masti u holstein (1,02 kg) i simentalske pasmine (0,79 kg), te srednje vrijednosti dnevnog sadržaja masti u holstein (3,81%) i simentalske pasmine (3,74%) utvrđene su periodu od lipnja do kolovoza (III SEZ).

Najviše srednje vrijednosti dnevne količine bjelančevina u holstein (0,90 kg) i simentalske pasmine (0,70 kg) utvrđene su periodu od prosinca do veljače (I SEZ). Najniže srednje vrijednosti dnevne količine bjelančevina u holstein (0,82 kg) i simentalske pasmine (0,65 kg) utvrđene su u periodu od lipnja do kolovoza (III SEZ). Najviše srednje vrijednosti dnevnog sadržaja bjelančevina u holstein (3,17 %) i simentalske pasmine (3,22 %) utvrđene su u periodu od prosinca do veljače (I SEZ), dok su najniže vrijednosti (3,04 kg u holstein i 3,16 kg u simentalske pasmine) utvrđene u periodu od lipnja do kolovoza (III SEZ).

Utjecaj sezone na sadržaj masti i bjelančevina ispitivali su Quinn i sur. (2006.) pri čemu su utvrdili veći sadržaj i masti i bjelančevina u zimskom te niže vrijednosti u ljetnom razdoblju. Heck i sur. (2009.) u istraživanjima u Nizozemskoj utvrdili su najniže vrijednosti za sadržaj mliječne masti i bjelančevina u ljetnim, a najviše vrijednosti u zimskim mjesecima. Bendelja i sur. (2011.) u istraživanju utjecaja sezone na sadržaj masti i bjelančevina objedinili su razdoblja jesen-zima te proljeće-ljeto. Utvrdili su veće vrijednosti sadržaja masti bjelančevina u razdoblju jesen-zima, a niže u razdoblju proljeće

– ljeto. Sagledavajući rezultate ovog istraživanja s prethodnim istraživanjima kroz objedinjavanje prve dvije sezone vidljiv je povoljan učinak hranidbenog obroka u zimskom razdoblju na povećanje sadržaja i masti i bjelančevina te negativan učinak hranidbenog obroka na promatrana svojstva tijekom ljetnog razdoblja.

Tablica 35. Varijabilnost dnevne količine i sastava mlijeka krava ovisno o sezoni za simentalsku pasminu

Svojstvo	Sezona	min	$\bar{x}$	max	sd	Duncan
Dnevna količina mlijeka	1	4,62	21,73	49,87	6,24	A
	2	3,97	22,43	49,65	6,12	B
	3	4,17	21,15	49,05	5,76	C
	4	3,10	20,49	48,66	5,80	D
Dnevna količina masti	1	0,11	0,92	2,81	0,33	A
	2	0,09	0,89	2,86	0,32	B
	3	0,10	0,79	2,65	0,28	C
	4	0,10	0,82	2,90	0,30	D
Dnevni sadržaj masti	1	1,50	4,20	7,00	0,90	A
	2	1,50	3,93	6,98	0,85	B
	3	1,50	3,74	6,98	0,83	C
	4	1,51	3,99	6,99	0,86	D
Dnevna količina bjelančevina	1	0,14	0,70	2,05	0,22	A
	2	0,13	0,70	1,74	0,20	A
	3	0,12	0,65	1,74	0,19	B
	4	0,10	0,66	1,80	0,20	B
Dnevni sadržaj bjelančevina	1	2,23	3,22	5,98	0,38	A
	2	1,84	3,11	5,90	0,37	B
	3	2,13	3,09	5,66	0,37	C
	4	2,18	3,21	5,95	0,38	A
Omjer mast bjelančevina	1	0,37	1,32	3,09	0,29	A
	2	0,43	1,27	3,20	0,29	B
	3	0,34	1,22	2,92	0,29	C
	4	0,41	1,25	3,03	0,28	D
Dnevni sadržaj ureje	1	1,00	13,81	68,80	8,82	A
	2	1,00	16,62	65,80	9,76	B
	3	1,00	22,47	69,00	10,92	C
	4	1,00	17,12	69,60	9,90	D
Dnevni sadržaj laktoze	1	2,75	4,55	5,41	0,20	A
	2	2,68	4,57	5,29	0,18	B
	3	2,88	4,52	5,17	0,20	C
	4	2,10	4,50	5,35	0,21	D
Broj somatskih stanica (log)	1	-3,10	3,15	10,19	2,18	B
	2	-3,10	3,09	10,19	2,17	B
	3	-3,10	3,26	10,19	2,24	A
	4	-3,10	3,24	10,19	2,15	A

Najviše srednje vrijednosti omjera masti i bjelančevina u holstein u iznosu od 1,31 utvrđene su u razdoblju od prosinca do svibnja (I i III SEZ), dok su kod simentalske pasmine najviše srednje vrijednosti u iznosu od 1,32 utvrđene su razdoblju od prosinca do veljače (I SEZ). Najniže srednje vrijednosti omjera masti i bjelančevina kod holstein (1,26) i simentalske pasmine (1,2) utvrđene su razdoblju od lipnja do kolovoza (III SEZ). Marenjak i Poljičak-Milas (2007.) utvrdili su najveće vrijednosti omjera masti i bjelančevina u proljeće što je u skladu s rezultatima ovog istraživanja za obje pasmine. Varijabilnost omjera masti i bjelančevina u navedenim razdobljima dijelom je rezultat povećanja ili snižavanja sadržaja mliječne masti kao odgovor na količinu proizvedenog mlijeka u tim razdobljima.

Najviše srednje vrijednosti sadržaja ureje kod holstein (24,78 mg/dl) i simentalske pasmine (22,47 mg/dl) utvrđene su razdoblju od lipnja do kolovoza (III SEZ). Najniže srednje vrijednosti sadržaja ureje kod holstein (19,46 mg/dl) i simentalske pasmine (13,81 md/dl) utvrđene su razdoblju od prosinca do veljače (I SEZ). Rezultati predmetnog istraživanja sukladni su rezultatima istraživanjima Heck i sur. (2009.), Konjačića i sur. (2010.) i Bendelje i sur. (2011.) koji su utvrdili najviše vrijednosti sadržaja ureje u ljetnom i jesenskom razdoblju godine, a najniže vrijednosti u zimskom i proljetnom dijelu godine. Povećanje sadržaja ureje u navedenom razdoblju uvjetovano je povećanjem sadržaja nebjelančevinastog dušika i smanjenjem sadržaja ukupnog dušika u mlijeku uslijed hranidbe tijekom ljetnog razdoblja koju karakterizira veći sadržaj lako probavljivih bjelančevina.

Najviše srednje vrijednosti sadržaja laktoze u holstein (4,55 %) i simentalske pasmine (4,57 %) utvrđene su razdoblju od ožujka do svibnja (II SEZ). Najniže srednje vrijednosti sadržaja laktoze u iznosu od 4,49 % kod holstein pasmine i 4,50 % kod simentalske pasmine utvrđene su u razdoblju od rujna do studenog (IV SEZ). Rezultati predmetnog istraživanja sukladni su rezultatima istraživanjima Heck i sur. (2009.) koji su zaključili da laktoza ima najniže vrijednosti tijekom jeseni (u listopadu), a najviše tijekom proljeća (u svibnju). Marenjak i Poljičak-Milas (2007.) su utvrdili vrlo male varijacije u sadržaji laktoze tijekom godine uz viši sadržaj laktoze u razdoblju koje obuhvaća proljeće i ljeto nego li u razdoblju jeseni i zime. Lujerdean i sur. (2007.) su utvrdili veće vrijednosti laktoze u razdoblju od listopada do ožujka nego li u razdoblju od svibnja do rujna.

Povezanost sadržaja laktoze i količine mlijeka uvjetovana je razinom ispunjavanja energetskih potreba u navedenim razdobljima.

Najviše srednje vrijednosti logaritmiranog broja somatskih stanica (log BSS) u iznosu od 3,64 u holstein te 3,26 u simentalske pasmine utvrđene su u razdoblju od lipnja do kolovoza (III SEZ). Najniže srednje vrijednosti logBSS u holstein (3,25) te simentalske pasmine (3,09) utvrđene su razdoblju od ožujka do svibnja (II SEZ). Schutz i sur. (1994.), Harmon i sur. (1994.), te Ivkić i sur. (2012.) utvrdili su veći broj somatskih stanica kod krava koje su započele laktaciju u ljetnom i jesenskom razdoblju komparabilno sa onima koje su započele laktaciju u zimskom razdoblju. Visoke temperature zraka tijekom ljetnih mjeseci koje su praćene s visokom vlagom zraka imaju nepovoljan utjecaj na zdravlje vimena i uzrokuju povećanje broja somatskih stanica u navedenom razdoblju.

3.1.4. Varijabilnost trajanja servis razdoblja

Varijabilnost trajanja servis razdoblja po razredima te udjeli teljenja i koncepcija po sezonama prikazani su zasebno za svaku pasminu. Broj i udio krava po razredima trajanja servis razdoblja za holstein pasminu prikazan je u tablici 36. Obzirom na trajanje servis razdoblja krave su podijeljene u 6 razreda. Najveći udio krava holstein pasmine (20,65%) nalazi se u drugom razredu trajanja servis razdoblja odnosno u razdoblju od 61 do 82 dana, a najmanji udio krava (12,57%) nalazi se u 6 razredu odnosno u razdoblju od 145 do 165 dana.

Tablica 36. Broj i udio krava po razredima trajanja servis razdoblja za holstein pasminu

Razred	Granice razreda	Broj krava	% krava	$\bar{x}$	sd	1. kvartil	median	3. kvartil
1	20-60	2.261	15,21	48,68	9,22	43,00	51,00	56,00
2	61-81	3.069	20,65	71,38	5,86	67,00	71,00	76,00
3	82-102	2.901	19,52	91,71	6,09	86,00	92,00	97,00
4	103-123	2.600	17,49	112,83	6,10	108,00	113,00	118,00
5	124-144	2.165	14,57	133,75	5,96	129,00	134,00	139,00
6	145-165	1.868	12,57	154,39	6,12	149,00	154,00	160,00

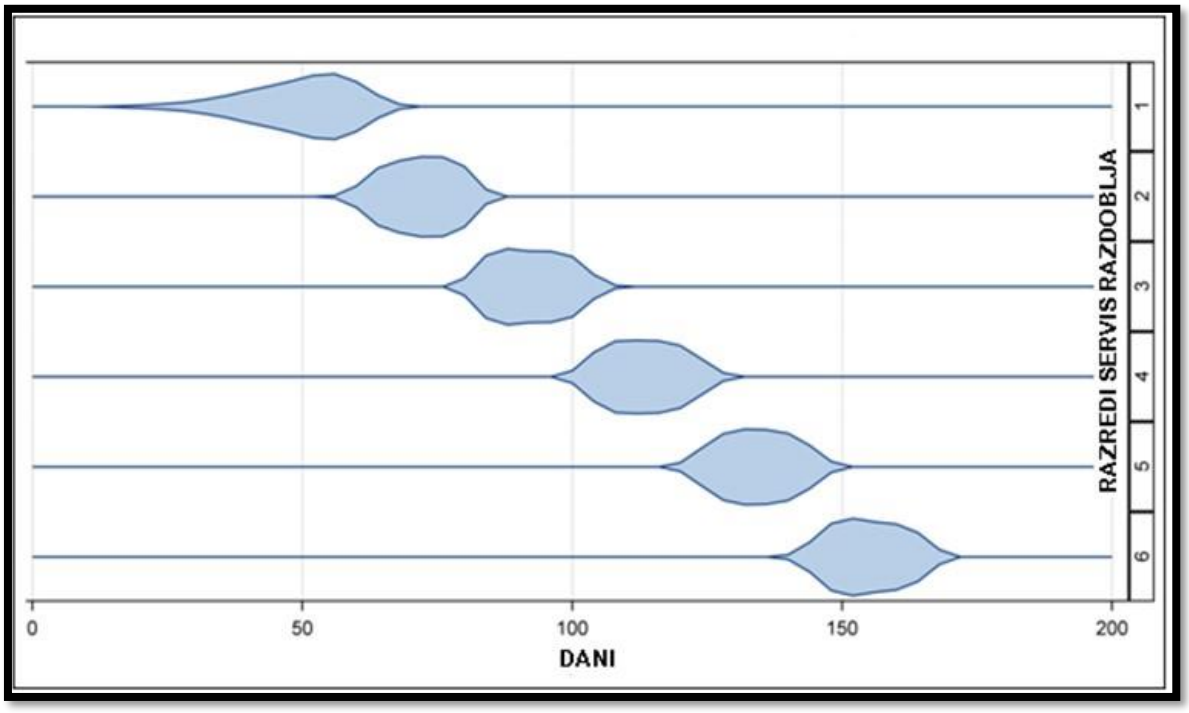

Grafikon 5: Distribucija trajanja servis razdoblja za holstein pasminu

Značajnije odstupanje između aritmetičke sredine i medijane u trajanju servis razdoblja kod holstein pasmine prisutno je samo unutar prvog razreda trajanja servis razdoblja od 20 do 61 dana, što je vidljivo na grafikonu 5. Prosječno trajanje servis razdoblja u prvom razdoblju bilo je 48,68 dana s medijanom od 51 dana.

Kod simentalske pasmine najveći udio krava u iznosu od 23,89 % nalazi se u drugom razredu trajanja servis razdoblja odnosno od 61 do 82 dana, a najmanji u šestom razredu trajanja servis razdoblja odnosno od 145 do 165 dana u iznosu od 8,8 % (tablica 37.).

Tablica 37. Broj krava i udio po razredima trajanja servis razdoblja za simentalsku pasminu

Razred	Granice razreda	Broj krava	% krava	$\bar{x}$	sd	1. kvartil	median	3. kvartil
1	20-60	3.302	17,65	49,46	8,66	45,00	52,00	56,00
2	61-81	4.469	23,89	71,12	5,94	66,00	71,00	96,00
3	82-102	3.992	21,34	91,51	6,07	86,00	91,00	97,00
4	103- 123	3.089	16,51	112,65	6,04	107,00	112,00	118,00
5	124-144	2.210	11,81	133,41	6,04	128,00	133,00	139,00
6	145-165	1.646	8,8	154,51	6,07	149,00	154,00	160,00

Značajnije odstupanje između aritmetičke sredine i medijane kod simentalske pasmine za trajanje servis razdoblja prisutno je unutar prvog razreda trajanja servis razdoblja (grafikon 6.). Prosječno trajanje servis razdoblja u prvom razdoblju bilo je 49,46 dana s medijanom od 52 dana.

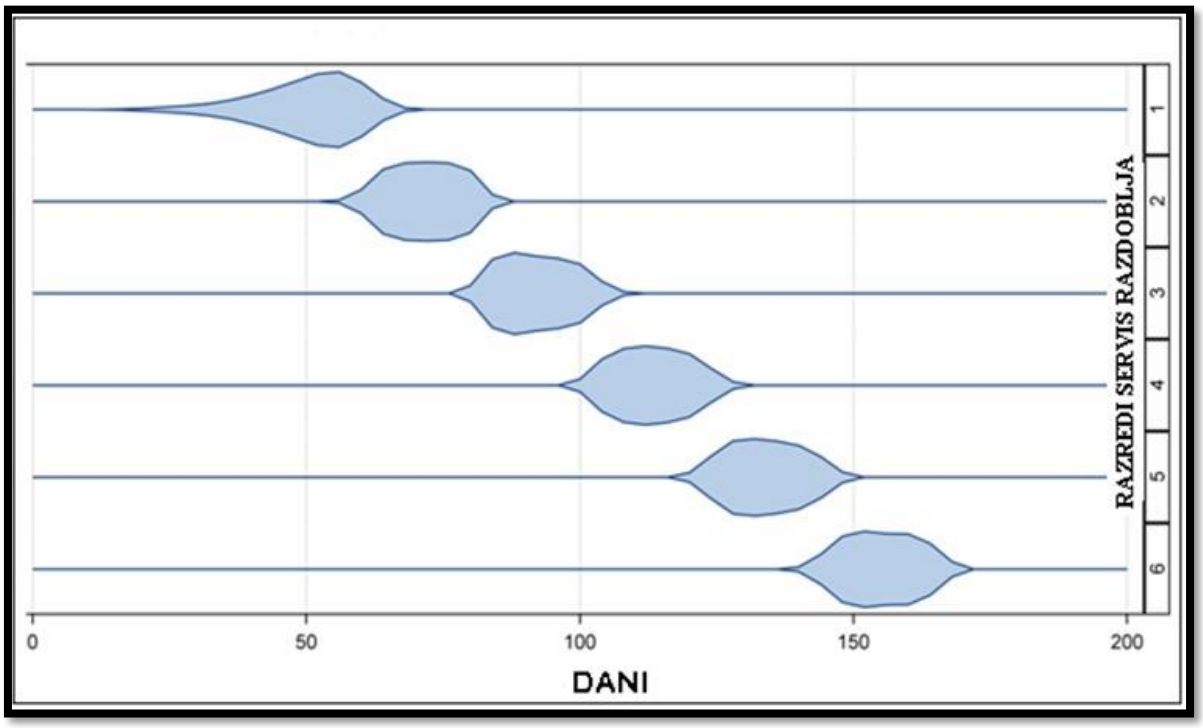

Grafikon 6: Distribucija trajanja servis razdoblja za simentalsku pasminu

Komparirajući distribuciju udjela krava u pojedinom razredu trajanja servis razdoblja po pasminama zamjetan je veći udio simentalske pasmine u prva tri razreda trajanja servis u odnosu na holstein pasminu. Udio holstein krava koje imaju trajanje servis razdoblja do 60 dana iznosio je 15,21 % dok je udio krava simentalske pasmine iznosio 17,65 %. Udio holstein krava koje su imale trajanje servis razdoblja do 81 dan iznosio je 20,65 %, dok je udio krava simentalske pasmine iznosio 23,89 %. Udio holstein krava u trećem razredu trajanja servis razdoblja odnosno do 102 dana iznosio je 19,52 %, dok je udio krava simentalske pasmine iznosio 21,34%. Ukupan udio krava holstein pasmine u razredima do 102 dana (prva tri razreda) iznosio je 55,38 %, odnosno 72,87 % do 123 dana (prva četiri razreda). Udio simentalske pasmine u prva tri razreda iznosio je 62,88 %, odnosno 79,39 % do 123 dana (prva četiri razreda trajanja servis razdoblja).

Prema preporukama Wattiauxa (1995.) optimalno trajanje servis razdoblja je do 110 dana. U razredima kod koji je trajanje servis razdoblja iznad 123 do 165 dana (peti i

šesti razred) kod holstein pasmine nalazi se 27,14 % krava te 20,61 % krava simentalske pasmine. Sukladno rezultatima ovog istraživanja, veći je udio krava simentalske pasmine u razredima sa kraćim trajanjem trajanje servis razdoblja u odnosu na holstein pasminu. Kraće trajanje servis razdoblja za simentalsku pasminu (135 dana) u odnosu na holstein pasminu (prosječno 175 dana) navodi se u izvješću Hrvatske poljoprivredne agencije (HPA, 2011.).

3.1.5. Varijabilnost udjela koncepcija i teljenja po sezonama

Analiza udjela koncepcija i teljenja za holstein pasminu prikazana je na grafikonu 7. Evidentan je najveći udio teljenja u iznosu od 33,96 % u razdoblju od rujna do studenog (IV SEZ). Najmanji se udio teljenja u iznosu od 12,74 % bilježi u razdoblju od ožujka do svibnja (II SEZ). Najveći udio koncepcija krava holstein pasmine utvrđen je u razdoblju od prosinca do veljače (I SEZ) u iznosu od 32,19 %, dok se najmanji udio koncepcija bilježi u razdoblju od lipnja do kolovoza (III SEZ) u ukupnom iznosu od 13,09 %.

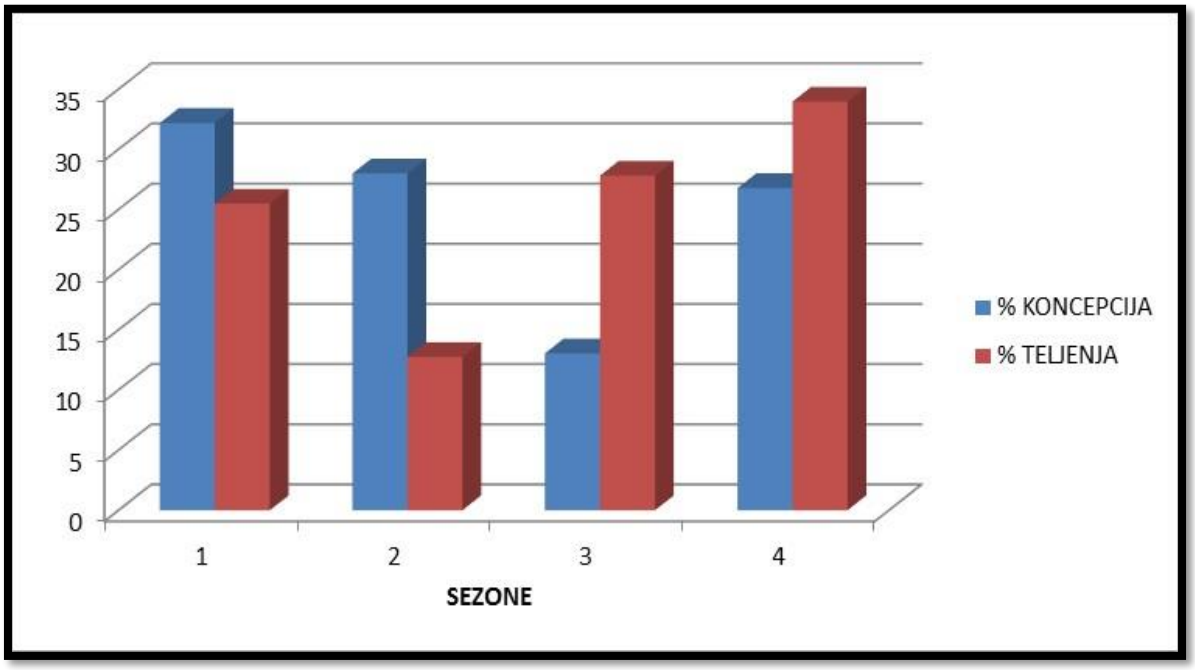

Grafikon 7: Udio koncepcija i teljenja za holstein pasminu

Sličan je udio koncepcija utvrđen i u krava simentalske pasmine u razdoblju od prosinca do svibnja (I i II SEZ) u iznosu od 30,98 % i 30,78 % (grafikon 8.). Najmanji udio koncepcija u iznosu od 15 % utvrđen je u razdoblju od lipnja do kolovoza (III SEZ). Najveći je udio teljenja (33,09 %) utvrđen u razdoblju od rujna do studenog (IV SEZ), a najmanji udio teljenja (14,43 %) u razdoblju od prosinca do lipnja do kolovoza (III SEZ).

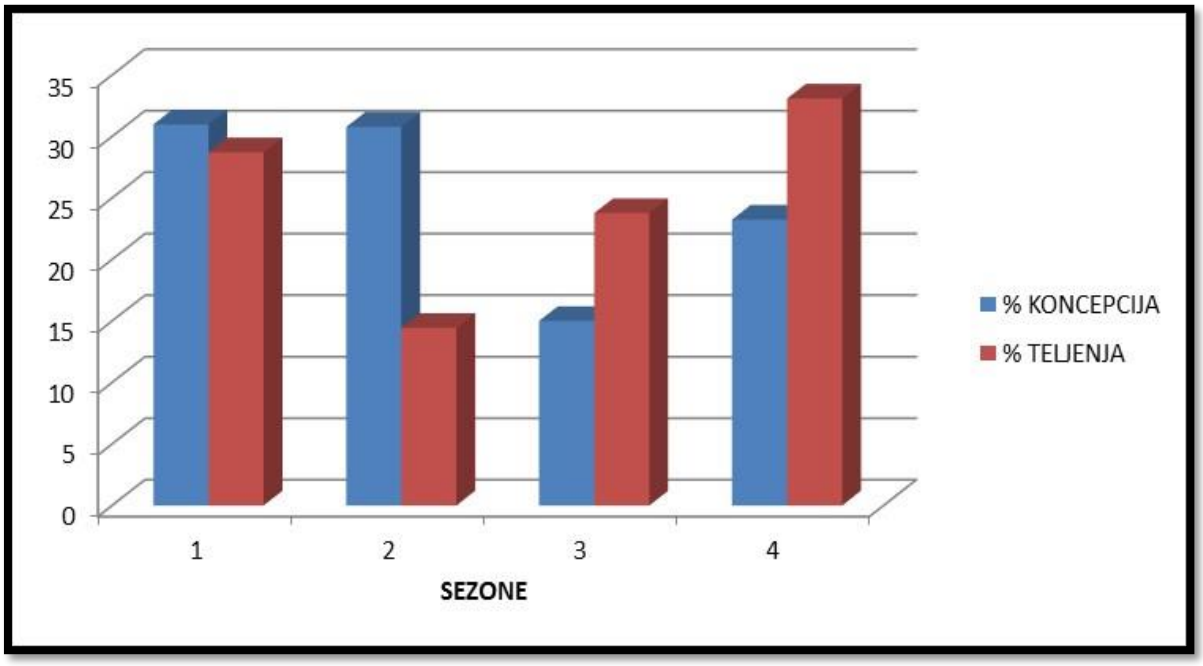

Grafikon 8: Udio koncepcija i teljenja za simentalsku pasminu

Sagledavajući distribuciju udjela koncepcija i teljenja po sezonama u obje je pasmine zamjetan najveći udio teljenja u jesenskom razdoblju odnosno od rujna do studenog te najmanji udio teljenja u proljetnom razdoblju odnosno od ožujka do svibnja. Najmanji udio koncepcija kod obje pasmine utvrđen je u ljetnom razdoblju odnosno od lipnja do kolovoza, a najveći je udio utvrđen u razdoblju od prosinca do veljače. Kod holstein pasmine posebno je naglašeno smanjenje udjela koncepcije u ljetnom razdoblju u odnosu na tri preostala razdoblja, dok simentalska pasmina ima smanjen udio koncepcije u ljetnom i jesenskom razdoblju. Visoke temperature zraka tijekom ljetnog razdoblja u kombinaciji s visokom vlagom u zraku uzrokuju pojavu toplinskog stresa. Krave koje su izložene toplinskom stresu imaju reduciranu uspješnost umjetnog osjemenjivanja i povećan broj embrionalnih uginuća. Istraživanja koje proveo Lopez –Gautius (2003.) ukazuju na izraženi pad plodnosti krava kao posljedice djelovanja toplinskog stresa. Prema Grohn i Rajala – Schultz (2000.) jesen je optimalno razdoblje za teljenje ukoliko se želi postići međutelidbeno razdoblje od 1 godine.

3.1.6. Varijabilnost udjela krava po razredima veličine stada

Broj i udio stada i krava po razredima veličine stada prikazan je odvojeno za holstein i simentalsku pasminu. Podaci za holstein pasminu prikazani su u tablici 38. U obradu podataka uključeno je ukupno 1.950 holstein stada sa 25.910 krava. Prosječan broj

krava po stadu iznosio je 13,29. Najveći broj stada nalazi se u prvom razredu veličine stada odnosno od 1 do 10 krava. U istom razredu nalazi se 1.544 stado ili 79,18% od ukupnog broja stada, ali istovremeno svega 27,36% ukupnog broja krava. U prvom razredu se nalazi prosječno 4,59 krave u stadu. Najmanji broj stada nalazi se u petom razredu veličine stada odnosno stada s više od 100 krava. U tom razredu nalazi se 36 stada odnosno 1,85% od ukupnog broja stada, no čak 41,67% ukupnog broja krava s prosječno 299,91 krave/stadu.

Tablica 38. Broj i udio stada i krava po razredima veličine stada za holstein pasminu

Razredi veličine stada	Broj stada	%	Broj krava	%	Broj krava po stadu
1. (1-10)	1.544	79,18	7.088	27,36	4,59
2. (10-20)	241	12,36	3.293	12,71	13,66
3. (20-50)	107	5,48	3.172	12,24	29,64
4. (50-100)	22	1,13	1.561	6,02	70,95
5. (>100)	36	1,85	10.796	41,67	299,91
Ukupno	1.950	100,00	25.910	100,00	13,29

Podaci za simentalsku pasminu prikazani su u tablici 39. U obradu podataka uključeno je ukupno 4.880 stada sa 32.496 krava simentalske pasmine. Prosječan broj krava po stadu za simentalsku pasminu iznosio je 6,66 krava. Najveći broj stada nalazi se u prvom i drugom razredu veličine stada odnosno do ukupno 20 krava u stadu. U tim razredima nalazi se 4.763 stado ili 97,6% ukupnog broja stada te 87,87% ukupnog broja krava.

Tablica 39. Broj i udio stada i krava po razredima veličine stada za simentalsku pasminu

Razredi veličine	Broj stada	%	Broj krava	%	Broj krava po stadu
1. (1-10)	4.195	85,96	20.932	64,41	4,99
2. (10-20)	568	11,64	7.626	23,46	13,43
3. (20-50)	105	2,15	3.057	9,41	29,11
4. (50-100)	11	0,23	748	2,3	68
5. (>100)	1	0,02	133	0,41	133
Ukupno	4.880	100	32.496	100	6,66

U prvom razredu se nalazi prosječno 4,99 krava, a u drugom razredu je prosječno 13,43 krava u stadu. U preostala tri razreda veličine stada nalazi se 117 stada odnosno 2,4% ukupnog broja stada te 12,12% ukupnog broja krava.

Sagledavajući distribuciju broja i udjela stada i krava po razredima veličine stada razvidna je veća neproporcionalnost između udjela broja stada u prva dva razreda veličine stada kod holstein pasmine nego kod simentalske pasmine. Izrazito veliki udio krava u malom broju stada kod petog razreda veličine holstein stada najviše je utjecao na dvostruko veći prosječni broj krava holstein pasmine u stadu u odnosu na prosječni broj simentalskih krava u stadu. Velik broj stada s manjim brojem krava te mali broj stada s velikim brojem krava u ovom istraživanju, kao i istraživanjima koje su provodili Špehar (2010.) i Ivkić (2011.) odraz su nepovoljne strukture veličine stada u Republici Hrvatskoj, koja vrlo često onemogućuje učinkovito i rentabilno poslovanje gospodarstava za proizvodnju mlijeka.

3.1.7. Varijabilnost udjela krava po regijama

Broj i udio stada i krava po regijama prikazan je odvojeno za holstein i simentalsku pasminu. Regija 1. (1. REG) obuhvaća: Grad Zagreb i Zagrebačka županiju, Međimursku, Varaždinsku, te Krapinsko zagorsku županiju. Regija 2. (2. REG) obuhvaća: Sisačko moslavačku, Karlovačku, te Ličko senjsku županiju. Regija 3. (3. REG) obuhvaća: Bjelovarsko bilogorsku i Koprivničko križevačku županiju. Regija 4. (4. REG) obuhvaća: Osječko baranjsku, Vukovarsko srijemsku, Brodsko posavsku, Požeško slavonsku, te Virovitičko podravsku županiju. Regija 5. (5. REG) obuhvaća: Zadarsku, Šibensko kninsku, Splitsko dalmatinsku, te Istarsku županiju.

Broj i udio stada i krava po regijama za holstein pasminu prikazani su u tablici 40. Najveći udio stada u iznosu od 35,98 % nalazi se na području Bjelovarsko bilogorske i Koprivničko križevačke županije (3. REG), s udjelom od 21,44 % ukupnog broja krava i prosječno 7,91 kravom u stadu. Najveći udio krava u iznosu od 55,41 % ukupnog broja krava sa znatno manjim udjelom stada od 27,83 % i znatno većim prosječnim brojem krava u stadu (26,45 krava) nalazi se u području Osječko baranjske, Vukovarsko srijemske, Brodsko posavske, Požeško slavonske i Virovitičko podravske županije (4. REG). Najveća prosječna veličina stada u iznosu od 28,75 krava u stadu utvrđena je na području Zadarske, Šibensko kninske, Splitsko dalmatinske, i Istarske županije (5. REG), no s vrlo malim udjelom stada u ukupnom broju stada (2,46 %) i malim udjelom krava u ukupnom broju (5,33 %). Najmanja prosječna veličina stada od 6,60 krava u stadu nalazi se na području Grada Zagreba, Zagrebačke, Međimurske, Varaždinske i Krapinsko zagorske županije (1. REG).

Tablica 40. Broj i udio stada i krava po regijama za holstein pasminu

Regija	Broj stada	%	Broj krava	%	Broj krava po stadu
1.	447	22,91	2.948	11,38	6,60
2.	211	10,82	1.669	6,44	7,91
3.	702	35,98	5.555	21,44	7,91
4.	542	27,83	14.358	55,41	26,49
5.	48	2,46	1.380	5,33	28,75
Ukupno	1.950	100,00	25.910	100,00	13,29

Broj i udio stada i krava po regijama za simentalsku pasminu prikazan je u tablici 41. Najveći udio stada u iznosu od 45,33% i najveći udio krava u iznosu od 46,98% , s prosječno 6,90 krava po stadu nalazi se u području Bjelovarsko bilogorske i Koprivničko križevačke županije (3. REG). Najmanji udio stada u iznosu od 0,35% i najmanji udio broja krava u iznosu od 0,41% nalazi se u području Grada Zagreba, Zagrebačke, Međimurske, Varaždinske i Krapinsko zagorske županije.

Tablica 41. Broj i udio stada i krava po regijama za simentalsku pasminu

Regija	Broj stada	%	Broj krava	%	Broj krava po stadu
1.	1.196	24,51	6.378	19,62	5,33
2.	388	7,94	2.336	7,19	6,02
3.	2.216	45,33	15.269	46,98	6,90
4.	1.067	21,87	8.380	25,80	7,85
5.	17	0,35	133	0,41	7,83
	4.880	100,00	32.496	100,00	6,66

Sagledavajući distribuciju broja krava u stadu prema regionalnoj podjeli kod holstein i simentalske pasmine razvidna je veća neproporcionalnost između udjela broja krava u stadu kod holstein nego kod simentalske pasmine. Tako je najmanji prosječan broj krava u stadu kod holstein pasmine (6,6 krava) u području 1. REG, a najveći prosječan broj krava u stadu (28,75 krava) u području 5. REG. Kod simentalske pasmine ujednačen je broj krava u stadu između regija te se kreće se od 5,33 krava u stadu u području 1. REG do 7,85 krava u stadu u području 4. REG.

3.2. Korelacija trajanja servis razdoblja i rezultata provedbe kontrole mliječnosti

Korelacije između trajanja servis razdoblja i rezultata dobivenih provedbom kontrole mliječnosti po pojedinim kontrolnim danima prikazana je odvojeno za holstein i simentalsku pasminu. Rezultati analize povezanosti za holstein pasminu prikazani su u tablici 42.

Tablica 42. Korelacija trajanja servis razdoblja i svojstava mliječnosti za holstein pasminu

Svojstvo	**Kontrolni dan 1.**	**Kontrolni dan 2.**
Dnevna količina mlijeka (DKM)	-0,00061	0,0039
Dnevna količina masti (DKMM)	0,00416	0,0040
Dnevni sadržaj masti (DSM)	0,00654	0,00367
Dnevna količina bjelančevina (DKB)	-0,02224**	-0,0206*
Dnevni sadržaj bjelančevina (DSB)	-0,05494***	-0,07824***
Dnevni sadržaj ureje (DSU)	-0,01061	-0,0133
Dnevni sadržaj laktoze (DSL)	-0,03353***	-0,03341***
Broj somatskih stanica (log) (BSS)	0,01980*	0,04864***
Omjer masti i bjelančevina (IMP)	0,03419***	0,02972**

****p <0,0001, vrijednosti koeficijenata korelacije koje su statistički vrlo značajne*
***p <0,01 i *p <0,05, vrijednosti koeficijenta korelacije koje su statistički značajne*

U kontrolnom danu 1. utvrđene su statistički vrlo značajne ($p < 0,0001$) i negativne korelacije između trajanja servis razdoblja i dnevnog sadržaja bjelančevina (DSB, -0,05494) te dnevnog sadržaja laktoze (DSL, -0,03353). Statistički vrlo značajne ($p < 0,0001$) i pozitivne korelacije utvrđene su između trajanja servis razdoblja i omjera masti i bjelančevina (IMP, 0,03419). Utvrđene su i statistički značajne korelacije ($p < 0,01$) između trajanja servis razdoblja i dnevnog sadržaja bjelančevina (DSB, -0,05494) te broja somatskih stanica (BSS, 0,01980).

U kontrolnom danu 2. utvrđene su statistički vrlo značajne ($p < 0,0001$) i negativne korelacije između trajanja servis razdoblja i DSB (-0,07824) te DSL (-0,0341). Statistički vrlo značajne ($p < 0,0001$) i pozitivne korelacije utvrđene su između trajanja servis razdoblja i BSS (0,04864). Statistički značajne korelacije ($p < 0,01$) utvrđene su između

trajanja servis razdoblja i IMP (0,02972), te DKB (-0,0206). Između ostalih svojstva dobivenih provedbom mliječnosti i trajanja servis razdoblja nisu utvrđene korelacije na razini statističke značajnosti.

Tablica 43. Korelacija trajanja servis razdoblja i svojstava mliječnosti za simentalsku pasminu

Svojstvo	**Kontrolni dan 1.**	**Kontrolni dan 2.**
Dnevna količina mlijeka (DKM)	-0,00282	0,00605
Dnevna količina masti (DKMM)	0,02173*	0,01548*
Dnevni sadržaj masti (DSM)	0,03366***	0,02112**
Dnevna količina bjelančevina (DKB)	-0,00334	-0,01094
Dnevni sadržaj bjelančevina (DSB)	-0,01429	-0,04265***
Dnevni sadržaj ureje (DSU)	0,02243**	-0,00708
Dnevni sadržaj laktoze (DSL)	-0,03463***	-0,01680 *
Broj somatskih stanica (log) (BSS)	0,00913	0,02818***
Omjer masti i bjelančevina (IMP)	0,04075***	0,04312***

***p <0,0001, vrijednosti koeficijenata korelacije koje su statistički vrlo značajne
**p <0,01 i *p <0,05, vrijednosti koeficijenta korelacije koje su statistički značajne

Rezultati analize povezanosti za holstein pasminu prikazani su u tablici 43. U kontrolnom danu 1. utvrđene su statistički vrlo značajne ($p < 0,0001$) i negativne korelacije između trajanja servis razdoblja i dnevnog sadržaja laktoze (DSL, -0,03463). Statistički vrlo značajne ($p < 0,0001$) i pozitivne korelacije utvrđene su između trajanja servis razdoblja i dnevnog sadržaja masti (DSM, 0,03366) te omjera masti i bjelančevina (IMP, 0,04075). Utvrđene su i statistički značajne korelacije ($p < 0,01$) između trajanja servis razdoblja i dnevnog sadržaja ureje (DSU, 0,02243) te dnevne količine mlijeka (DKM, 0,02173).

U kontrolnom danu 2. utvrđene su statistički vrlo značajne ($p < 0,0001$) i negativne korelacije između trajanja servis razdoblja i DSB (-0,04265). Utvrđene su i statistički vrlo značajne ($p < 0,0001$) i pozitivne korelacije utvrđene su između trajanja servis razdoblja i BSS (0,02818) te IMP (0,04312).

Statistički značajne korelacije ($p < 0,01$) utvrđene su između trajanja servis razdoblja i sljedećih svojstava: DSM (0,02972), DKMM (0,01548) te DSL (-0,01680).

Između ostalih svojstva dobivenih provedbom mliječnosti i trajanja servis razdoblja nisu utvrđene korelacije na razini statističke značajnosti.

Premda su kod obje pasmine za svojstva dobivena provedbom mliječnosti pri oba kontrolna dana utvrđene statistički vrlo značajne ili značajne korelacije vrijednosti svih koeficijenata korelacija kretale su se unutar raspona ±0,00 do ±0,20. Prema Petzu (2004.) koeficijenti korelacije koji se nalaze unutar navedenog raspona ukazuju na nikakvu ili zanemarivu povezanost između trajanja servis razdoblja i osobina koje proizlaze iz provedbe kontrole mliječnosti.

Dnevna proizvodnja mlijeka kod obje pasmine pri kontrolnom danu 1. je u negativnoj povezanosti s trajanjem servis razdoblja, dok je pri kontrolnom danu 2. utvrđena pozitivna korelacija između povećanja proizvodnje i trajanja servis razdoblja. Mnogobrojna istraživanja povezala su pad plodnosti mliječnih krava uz istovremeno povećanje proizvodnje mlijeka po kravi (Pryce i sur., 1999.; Royal i sur., 2000.; Roche i sur., 2000.; Lucy, 2001.; LeBlanc, 2010.; López-Gatius, 2003.; Djedović i sur., 2012., Bujko i sur., 2013.). Međutim, posljednjih nekoliko godina sve veći broj istraživača dokazuje da visoka proizvodnja mlijeka, nužno ne dovodi do loših reprodukcijskih rezultata. Weerkamp i sur. (2001.) utvrdili su niske vrijednosti korelacije između proizvedenih količina mlijeka i trajanja međutelidbenog razdoblja. Istraživanja Jagusiaka (2006.) pokazala su niske vrijednosti koeficijenta korelacije između količina proizvedenog mlijeka, sadržaja mliječne masti i bjelančevina i trajanja servis razdoblja. Bello i sur. (2012.) navode da se temeljem rezultata istraživanja unazad nekoliko godina (Peters i Pursley, 2002.; López-Gatius i sur., 2006.; LeBlanc, 2010.; Löf i sur., 2007.) mijenja percepcija o univerzalnom antagonizmu između visine proizvodnje mlijeka i uspjeha u reprodukciji krava.

Povećanje broja somatskih stanica povezano je s produženjem trajanja servis razdoblja (Miller i sur. (2001.), Morek-Kopeć i sur. (2008.), Madousse i sur. (2010.), Nguyen i sur. (2011.), Hudson i sur., (2012.) i Lomander i sur. (2013.). Povećanje broja somatskih stanica povezano je s odgođenom obnovom ciklusa jajnika te kasnijom prvom ovulacijom nakon teljenja.

Negativna korelacije između sadržaja laktoze i dužine trajanja servis razdoblja utvrđena je i u istraživanjima Reksena i sur. (2002.) te Buckley i sur. (2003.), što znači da povećanje sadržaja laktoze u mlijeku indicira skraćivanje trajanja servis razdoblja. Veći

sadržaj laktoze u mlijeku na početku laktacije povezuje se s energetskom ravnotežom i boljom reprodukcijskom učinkovitošću. Rezultati istraživanja Miglior i sur. (2006.) pak ne upućuju na povezanost između sadržaja laktoze i plodnosti mliječnih krava.

Istraživanja koja su proveli Butler (1998.), Hojman i sur. (2004.), Guo i sur. (2004.) te Rhoads i sur. (2006.) pokazala su, kao i u predmetnom istraživanju (osim kod kontrolnog dana 1. za simentalsku pasminu) negativnu povezanost između trajanja servis razdoblja i sadržaja ureje u mlijeku na početku laktacije. Sadržaj ureje u mlijeku odražava metabolizam bjelančevina i pokazatelj je metaboličkog stresa na početku laktacije. Međutim istraživanja Rehaka i sur. (2009.) pokazuju izostanak povezanosti između sadržaja ureje i vjerojatnosti koncepcije nakon teljenja.

Povećanje dnevnog sadržaja mliječne masti u pozitivnoj je korelaciji s trajanjem servis razdoblja kod obje pasmine. Korelacija utvrđena u predmetnom istraživanju sukladna je rezultatima istraživanja Madoussa i sur. (2010.) te Bujko i sur. (2013.). Sadržaj mliječne masti smatra se glavnim sastojkom mlijeka koji određuje energetske potrebe proizvodnje mlijeka obzirom da postoji jaka povezanost između sadržaja mliječne masti na početku laktacije i energetske ravnoteže (de Vries i Veerkamp, 2000.). Povećanje dnevne količine mliječne masti u predmetnom istraživanju je u pozitivnoj korelaciji s dužinom trajanja servis razdoblja što je u suprotnosti s rezultatima istraživanja Bujko i sur. (2013.).

Povećanje dnevne količine i dnevnog sadržaja bjelančevina kod obje pasmine indicira skraćivanje trajanja servis razdoblja, odnosno utvrđena je negativna korelacija između navedenih osobina. Sukladno predmetnom istraživanju, skraćivanje trajanja servis razdoblja s povećanjem sadržaja i količine bjelančevina utvrdili su Morton (2001.), Buckley i sur. (2003.), Patton i sur. (2007.) te Yang i sur. (2010.) oslanjajući se na povezanost energetske ravnoteže i mogućnosti sinteze mliječnih bjelančevina na početku laktacije.

Povećanje međusobnog omjera masti i bjelančevina u pozitivnoj je korelaciji s trajanjem servis razdoblja kod obje pasmine pri oba kontrolna dana. Sukladno ovim istraživanjem utvrđeno produženje trajanja servis razdoblja s povećanjem omjera masti i bjelančevina iznad vrijednosti 1,1 do 1,5 uslijed mobilizacije tjelesnih masti te posljedično tome smanjenja udjela bjelančevina utvrdili su Heuer i sur. (1999.) Paura i sur. (2012.), Podpecan i sur. (2010.), Negussie i sur. (2013.).

3.2.1. Korelacija između pojedinih svojstava utvrđenih provedbom kontrole mliječnosti

Korelacije između pojedinih svojstva dobivenih provedbom kontrole mliječnosti prikazani su za svaku pasminu posebno po prvom i drugom kontrolnom danu. Analiza povezanosti pojedinih svojstava utvrđenih provedbom kontrole mliječnosti za holstein pasminu prikazana je u tablici 44. Razvidne su statistički vrlo značajne korelacije ($p < 0,001$) pozitivnog predznaka između DKM i DKMM, DKM i DKB, DKMM i DKB, DSM i IMP za prvi i drugi kontrolni dan. Utvrđene vrijednosti koeficijenata korelacije prema Petzu, 2004. (0,7 – 1) ukazuju na jaku ili vrlo jaku povezanost. Između svojstava DKMM i IMP te DKMM i DSM utvrđene su statistički vrlo značajne korelacije ($p < 0,001$) s pozitivnim koeficijentom korelacije pri oba kontrolna dana. Utvrđeni koeficijenti korelacije prema Petzu, 2004. (0,4 – 0,7) ukazuju na značajnu povezanost. Između većine ostalih svojstava sukladno klasifikaciji prema Petzu (2004.) postoji slaba (0,2 – 0,4) ili neznatna povezanost (0,0 – 0,2).

Tablica 44. Korelacija između pojedinih svojstava mliječnosti za holstein pasminu

	DKM	DKMM	DSM	DKB	DSB	DSU	DSL	BSS	IMP
DKMM	0,74**	1							
	0,75**								
DSM	-0,05**	0,61**	1						
	-0,04**	0,60**							
DKB	0,92**	0,73**	0,03**	1					
	0,95**	0,74**	0,02						
DSB	-0,15**	0,007	0,21**	0,23**	1				
	-0,09**	0,02*	0,16**	0,22**					
DSU	0,15**	0,05**	-0,08**	0,14**	-0,008	1			
	0,22**	0,12**	-0,08**	0,22**	0,006				
DSL	0,14**	-0,05**	-0,25**	0.07**	-0,22**	0,02*	1		
	0,07**	-0,03**	-0,13**	0.09**	0,03**	0,06**			
BSS	-0,14**	-0.03**	0,13**	-0,07**	0,20**	-0,06**	-0,39**	1	
	-0,13**	-0,03*	0,10**	-0,08**	0,15**	-0,12**	-0,36**		
IMP	0,02*	0,59**	0,88**	-0,08**	-0,27**	-0,07**	-0,15**	0,04**	1
	-0.004	0,57**	0,90**	-0,09**	-0,27**	-0,08**	-0,14**	0,04*	

***p <0,01 i *p <0,05, vrijednosti koeficijenta korelacije koje su statistički značajne*

Tablica 45. Korelacija između pojedinih svojstava mliječnosti za simentalsku pasminu

	DKM	DKMM	DSM	DKB	DSB	DSU	DSL	BSS	IMP
DKMM	0,77** 0,80**	1							
DSM	0,04** 0,03**	0,64** 0,59**	1						
DKB	0,91** 0,94**	0,76** 0,79**	0,12** 0,09**	1					
DSB	-0,07** -0,05**	0,07* 0,07*	0,21** 0,19**	0,35** 0,29**	1				
DSU	0,07** 0,13**	0,04** 0,09**	-0,02** -0,02*	0,08** 0,15**	0,05** 0,06**	1			
DSL	0,09** 0,10**	-0,05* 0,03**	-0,19** -0,09**	-0,02** 0,08**	-0,28** -0,04**	-0,02* -0,004	1		
BSS	-0,12** -0,14**	-0,05** -0.07**	0,08** 0,07**	-0,05** -0,09**	0,18** 0,14**	-0,04** -0,05**	-0,43** -0,39**	1	
IMP	0,07** 0,05**	0,57** 0,54**	0,86** 0,88**	-0,07** -0,06**	-0,32** -0,30**	-0,04** -0,05**	-0,04** -0,06**	-0,02* 0,003	1

***p <0,01 i *p <0,05, vrijednosti koeficijenta korelacije koje su statistički značajne*

Analiza povezanosti pojedinih svojstava utvrđenih provedbom kontrole mliječnosti za simentalsku pasminu prikazana je u tablici 45. Utvrđene su statistički vrlo značajne korelacije ($p < 0,001$) pozitivnog predznaka između DKM i DKMM, DKMM i DKB, DSM i IMP te DKM i DKB za prvi i drugi kontrolni dan. Utvrđene vrijednosti koeficijenata korelacije prema Petzu, 2004. (0,7 – 1) ukazuju na jaku ili vrlo jaku povezanost.

Između svojstava DKMM i IMP te DKMM I DSM utvrđene su statistički vrlo značajne korelacije ($p < 0,001$) pozitivnog predznaka pri oba kontrolna dana, dok je između svojstava DSB i DIM te DSL i BSS kod prvog kontrolnog dana utvrđen negativni koeficijent korelacije. Vrijednosti utvrđenih koeficijenata korelacije u intervala od 0,4 do 0,7 ukazuje na značajnu povezanost (Petz, 2004.). Između većine ostalih svojstava sukladno klasifikaciji prema Petzu (2004.) postoji slaba (0,2 – 0,4) ili neznatna povezanost (0,0 – 0,2).

3.3. Rezultati analize trajanja servis razdoblja metodom logističke regresije

Logistička regresija se najčešće koristi kada relacija između zavisne (diskretne) varijable i prediktora nije linearna. U ovom slučaju provodi se logit transformacija koja daje linearnu relaciju između vjerojatnosti promatranog događaja (u ovom istraživanju koncepcije) i vrijednosti nezavisne varijable. U ovom modelu zavisna varijabla je diskretna, binarna (odnosno krava ili je ili nije koncipirala u određenom vremenskom razdoblju). U svakom regresijskom modelu ključno je odrediti očekivanu vrijednost zavisne varijable za određenu vrijednost nezavisne varijable (Grozdić, 2011.).

3.3.1. Model 1. – rezultati kontrole mliječnosti

Model uključuje svojstva koja su rezultat provedbe kontrole mliječnosti (dnevna količina mlijeka, dnevni sadržaj i količina mliječne masti, dnevni sadržaj i količina bjelančevina, omjer masti i bjelančevina, dnevni sadržaj ureje, odnos bjelančevina i ureje, dnevni sadržaj laktoze, broj somatskih stanica). Unutar navedenih varijabli metodom stupanjske regresije (*Stepwise Logistic Regression)* u LOGISTIC proceduri izdvojene su sljedeće varijable koje značajno utječu na dužinu trajanja servis razdoblja. Nakon izdvajanja odabranih varijabli pomoću stupanjske regresije provedena je obrada logističkom regresijom procedurom SURVEYLOGISTIC.

Tablica 46. Odabrane varijable po pasminama i kontrolnim danima za model 1.

Pasmina	**Kontrolni dan 1.**	**Kontrolni dan 2.**
Holstein	Dnevni sadržaj bjelančevina (DSB)	Dnevni sadržaj bjelančevina (DSB)
	Broj somatskih stanica (BSS)	Broj somatskih stanica (BSS)
	Dnevni sadržaj laktoze (DSL)	
Simentalska	Dnevni sadržaj bjelančevina (DSB)	Dnevni sadržaj bjelančevina (DSB)
	Omjer masti i bjelančevina (IMP)	Omjer masti i bjelančevina (IMP)
	Dnevni sadržaj ureje (DSU	Broj somatskih stanica (BSS)
	Dnevni sadržaj laktoze (DSL)	

Iz tablice 46. vidljivo je pojavljivanje varijabli dnevni sadržaj bjelančevina i broj somatskih stanica kod holstein pasmine pri oba kontrolna dana te dnevnog sadržaja laktoze

u prvom kontrolnom danu. Kod simentalske pasmine pri oba kontrolna dana pojavljuju se varijable dnevni sadržaj bjelančevina te omjer masti i bjelančevina.

Varijable dnevni sadržaj ureje i dnevni sadržaj laktoze pojavljuju se u prvom, a broj somatskih stanica u drugom kontrolnom danu.

3.3.1.1. Rezultati logističke regresije za model 1. i kontrolni dan 1. holstein pasmine

Rezultati logističke regresije za model 1. i kontrolni dan 1. holstein pasmine prikazani su u tablici 47. Provedbom logističke regresije za prvi kontrolni dan kod holstein pasmine kao statistički visoko značajne izdvojene su varijable dnevni sadržaj bjelančevina i dnevni sadržaj laktoze dok je varijabla broj somatskih stanica nalazi na granici statističke značajnosti što je vidljivo i kroz krajnju vrijednost (**1**) intervala povjerenja od 0,971 – 1,000 (grafikon 9).

Tablica 47. Rezultati logističke regresije za model 1. i kontrolni dan 1. holstein pasmine

	Procjena parametara β	**Standardna greška**	**p**	**Omjer izgleda**
INTERCEPT 1	-3,9281	0,4045	<0,0001	
INTERCEPT 2	-2,7919	0,4043	<0,0001	
INTERCEPT 3	-1,9858	0,4039	<0,0001	
INTERCEPT 4	-1,2086	0,4037	0,0028	
INTERCEPT 5	-0,2632	0,4037	0,5145	
DSB	0,2968	0,0381	<0,0001	1,345
DSL	0,3112	0,0753	<0,0001	1,365
BSS	-0,0146	0,00762	0,0555	0,986

Prikaz omjera izgleda (odds ratio) s 95% Waldovim intervalom povjerenja za 1. model i kontrolni dan 1. holstein pasmine vidljiv je na grafikonu 9. Krave koje kod prvog kontrolnog dana imaju manji broj somatskih stanica imaju za 1,4 % veći omjer izgleda za koncepciju. Krave koje kod prvog kontrolnog dana imaju veći dnevni sadržaj bjelančevina imaju 34,5 % veći omjer izgleda za koncepciju uz interval povjerenja u iznosu od 1,249 – 1,420. Krave koje imaju veći dnevni sadržaj laktoze imaju 36,5 % veći omjer izgleda za koncepciju uz interval povjerenja u iznosu od 1,178 – 1,582.

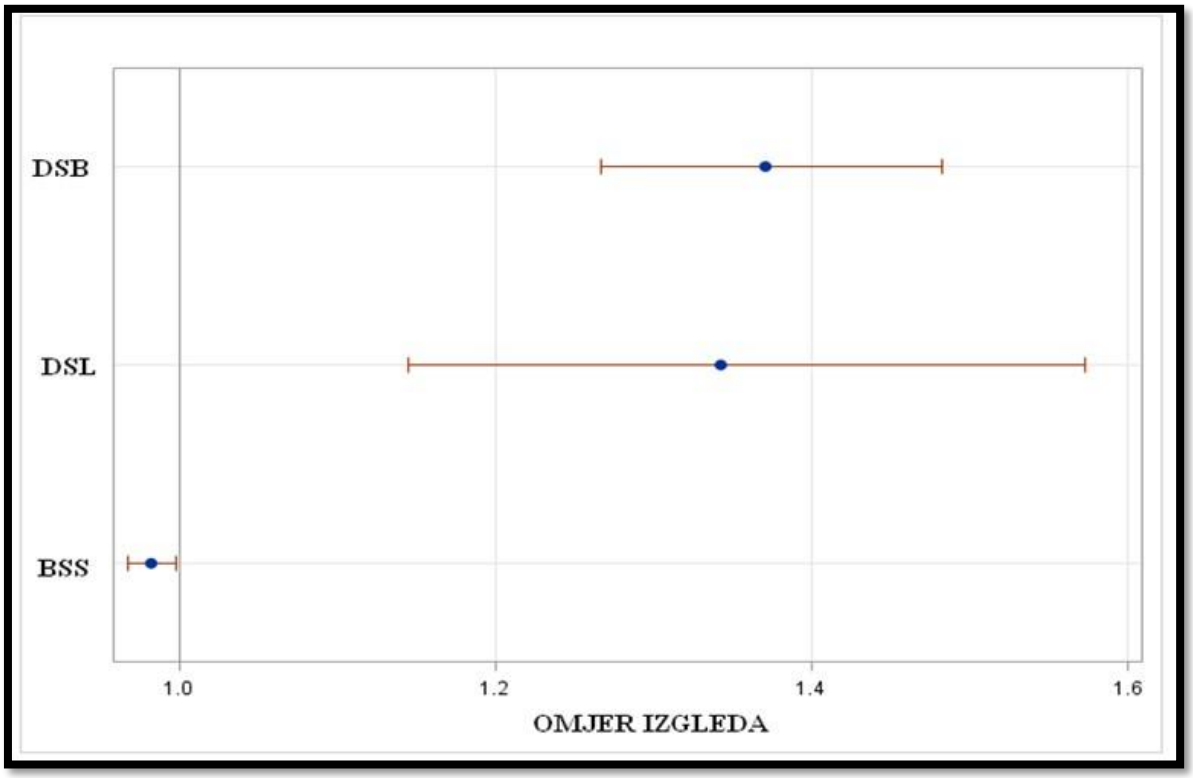

Grafikon 9: Prikaz omjera izgleda s 95% Waldovim intervalom povjerenja za model 1. i kontrolni dan 1. holstein pasmine

3.3.1.2. Rezultati logističke regresije za model 1. i kontrolni dan 2. holstein pasmine

Rezultati logističke regresije za model 1. i kontrolni dan 2. holstein pasmine prikazani su u tablici 48. Provedbom logističke regresije za drugi kontrolni dan kod holstein pasmine kao statistički visoko značajne ($p < 0,001$) izdvojene su varijable dnevni sadržaj bjelančevina i broj somatskih stanica (log).

Tablica 48. Rezultati logističke regresije za model 1. i kontrolni dan 2. holstein pasmine

	Procjena parametara β	**Standardna greška**	**p**	**Omjer izgleda**
INTERCEPT 1	-2,7468	0,1530	<0,0001	
INTERCEPT 2	-1,6009	0,1525	<0,0001	
INTERCEPT 3	-0,7943	0,1521	<0,0001	
INTERCEPT 4	-0,0170	0,1518	0,9109	
INTERCEPT 5	0,9389	0,1522	<0,0001	
DSB	0,4881	0,0483	<0,0001	1,791
BSS	-0,0494	0,00691	<0,0001	0,965

Prikaz omjera izgleda s 95% Waldovim intervalom povjerenja za model 1. i kontrolni dan 2. holstein pasmine vidljiv je na grafikonu 10. Krave koje kod drugog kontrolnog dana imaju veći dnevni sadržaj bjelančevina imaju 79,1 % veći omjer izgleda za koncepciju uz interval povjerenja u iznosu od 1,482 do 1,791. Krave koje imaju veći broj somatskih stanica imaju 3,5 % manju vjerojatnost koncepciju uz interval povjerenja u iznosu od 0,939 do 0,965.

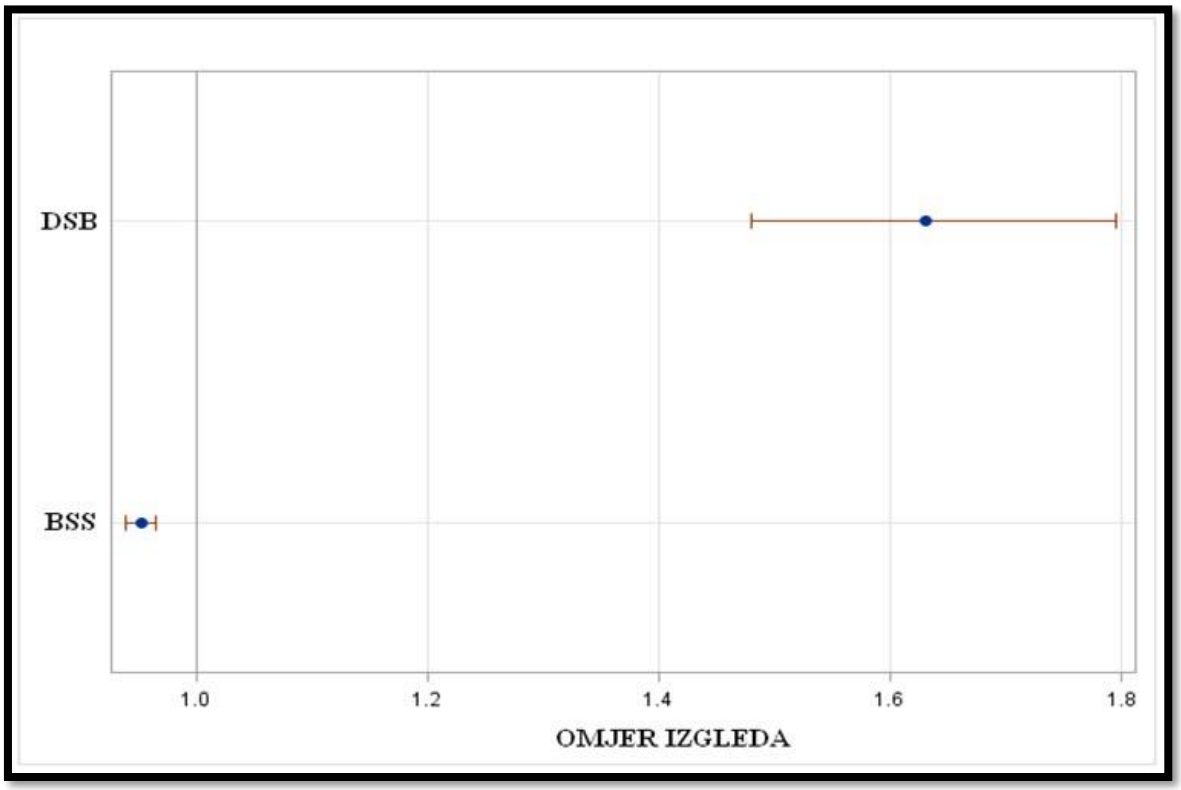

Grafikon 10: Prikaz omjera izgleda s 95% Waldovim intervalom povjerenja za model 1. i kontrolni dan 2. holstein pasmine

3.3.1.3. Rezultati logističke regresije za model 1. i kontrolni dan 1. simentalske pasmine

Rezultati logističke regresije za model 1. i kontrolni dan 1. simentalske pasmine prikazani su u tablici 49. Provedbom logističke regresije za prvi kontrolni dan kod simentalske pasmine kao statistički visoko značajne izdvojene su varijable dnevni sadržaj bjelančevina, dnevni sadržaj laktoze, dnevni sadržaj ureje, te omjer masti i bjelančevina.

Tablica 49. Rezultati logističke regresije za model 1. i kontrolni dan 1. simentalske pasmine

	Procjena parametara β	**Standardna greška**	**p**	**Omjer izgleda**
INTERCEPT 1	-3,3626	0,4117	<0,0001	
INTERCEPT 2	-2,1641	0,4112	<0,0001	
INTERCEPT 3	-1,2954	0,4110	0,0016	
INTERCEPT 4	-0,4687	0,4110	0,2541	
INTERCEPT 5	-0,5136	0,4112	0,2117	
DSB	0,1131	0,0371	0,0023	1,120
DSU	-0,00357	0,00135	0,0081	0,997
DSL	0,3929	0,0736	<0,0001	1,481
IMP	-0,2011	0,0490	<0,0001	0,818

Prikaz omjera izgleda s 95% Waldovim intervalom povjerenja za model 1. i kontrolni dan 1. simentalske pasmine vidljiv je grafikonu 11.

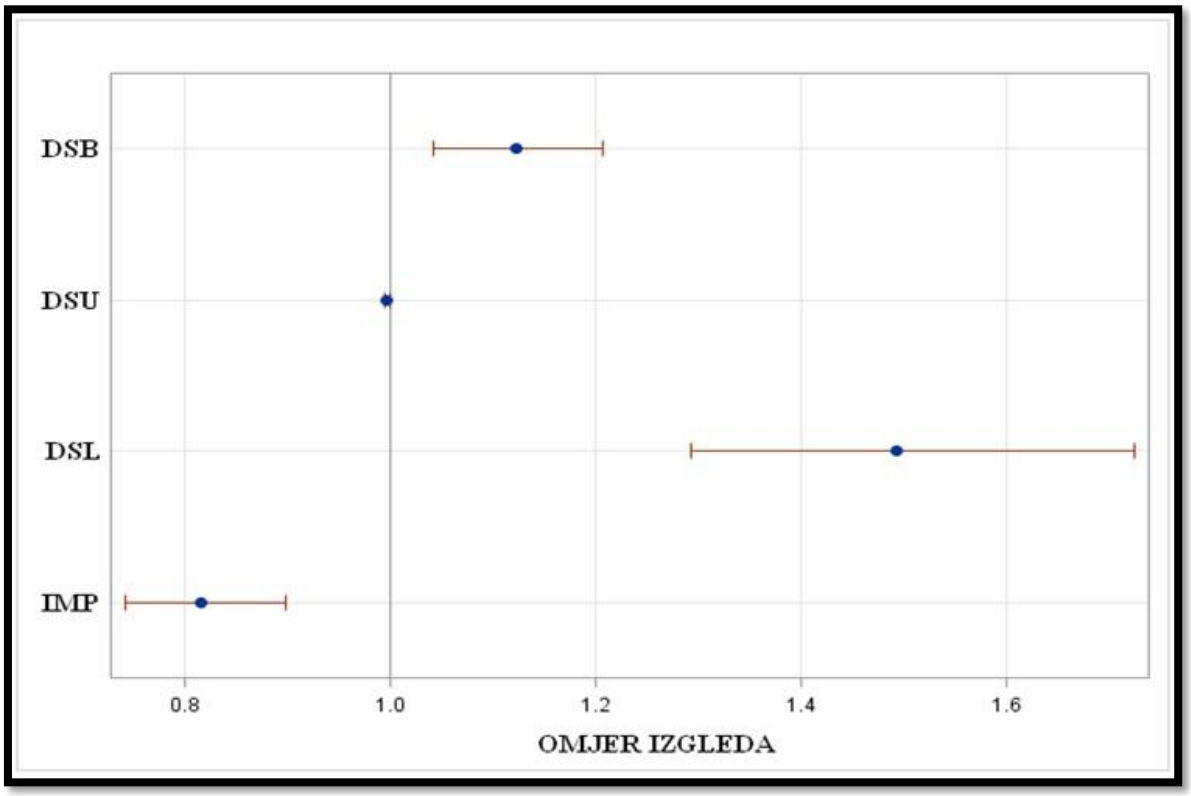

Grafikon 11: Prikaz omjera izgleda s 95% Waldovim intervalom povjerenja za model 1. i kontrolni dan 1. simentalske pasmine

Krave koje kod prvog kontrolnog dana imaju veći dnevni sadržaj bjelančevina imaju 12 % veći omjer izgleda za koncepciju uz interval povjerenja od 1,042 – 1,206. Krave koje kod prvog kontrolnog dana imaju manji sadržaj ureje imaju za 0,3 % veći omjer izgleda za koncepciju uz interval povjerenja od 0,994 – 0,999. Krave koje kod prvog kontrolnog dana imaju veći dnevni sadržaj laktoze imaju 48,1 % veći omjer izgleda za koncepciju uz interval povjerenja od 1,292 – 1,724. Krave koje kod prvog kontrolnog dana imaju niže vrijednosti omjera masti i bjelančevina imaju 18,2 % veći omjer izgleda za koncepciju uz interval povjerenja od 0,741 – 0,898.

3.3.1.4. Rezultati logističke regresije za model 1. i kontrolni dan 2. simentalske pasmine

Rezultati logističke regresije za model 1. i kontrolni dan 2. simentalske pasmine prikazani su u tablici 50. Provedbom logističke regresije za drugi kontrolni dan kod simentalske pasmine kao statistički visoko značajne izdvojene su varijable dnevni sadržaj bjelančevina, broj somatskih stanica (log), te omjer masti i bjelančevina.

Prikaz omjera izgleda s 95% Waldovim intervalom povjerenja za model 1. i kontrolni dan 2. simentalske pasmine vidljiv je na grafikonu 12. Krave koje imaju veći dnevni sadržaj bjelančevina imaju 24,1% veći omjer izgleda za koncepciju uz interval povjerenja u iznosu 1,141 – 1,350, a koje imaju veći broj somatskih stanica imaju 2,9 % manji omjer izgleda za koncepciju uz interval povjerenja 0,959 – 0,983. Krave koje kod drugog kontrolnog dana imaju niže vrijednosti omjera masti i bjelančevina imaju 17,5 % veći omjer izgleda za koncepciju uz interval povjerenja 0,749 – 0,908.

Tablica 50. Rezultati logističke regresije za model 1. i kontrolni dan 2. simentalske pasmine

	Procjena parametara β	**Standardna greška**	**p**	**Omjer izgleda**
INTERCEPT 1	-1,6909	0,1605	<0,0001	
INTERCEPT 2	-0,4880	0,1646	0,0030	
INTERCEPT 3	0,3810	0,1646	0,0206	
INTERCEPT 4	1,2020	0,1648	<0,0001	
INTERCEPT 5	2,1885	0,1660	<0,0001	
DSB	0,2157	0,0430	<0,0001	1,241
BSS	-0,0295	0,00605	<0,0001	0,971
IMP	-0,1929	0,0490	<0,0001	0,825

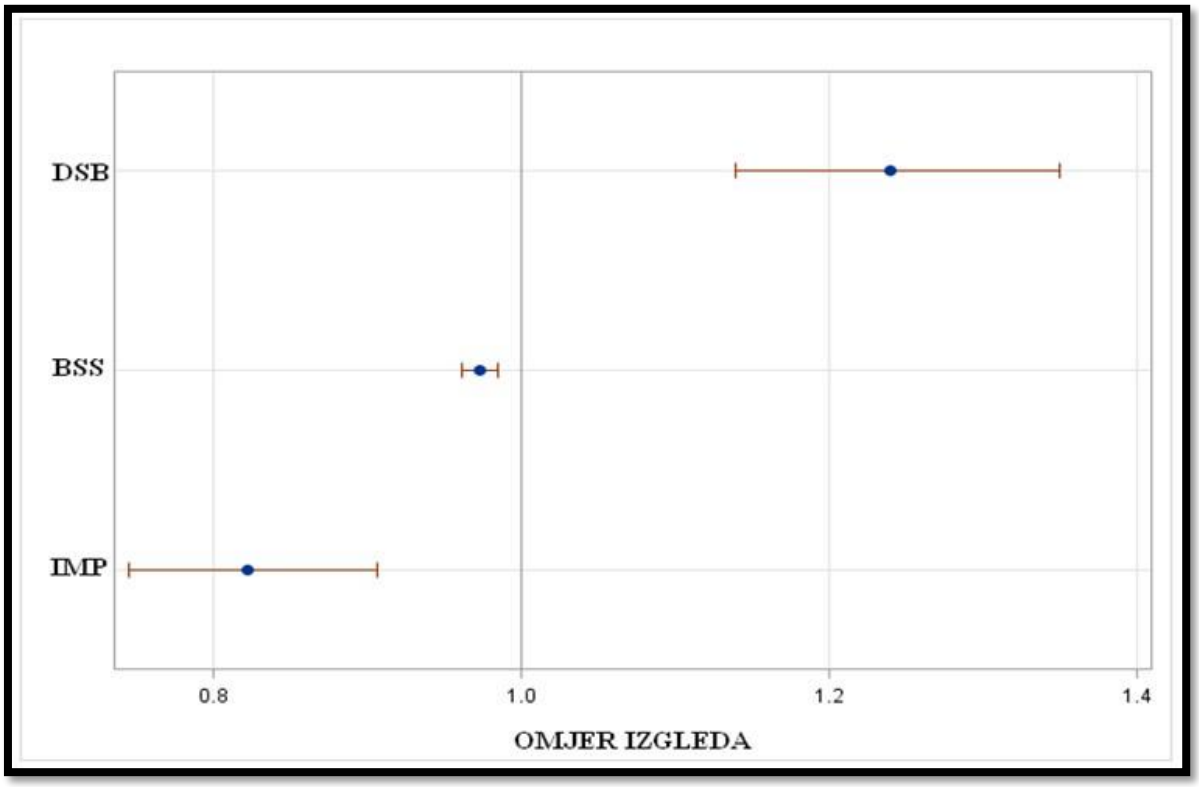

Grafikon 12: Prikaz omjera izgleda s 95% Waldovim intervalom povjerenja za model 1. i kontrolni dan 2. simentalske pasmine)

3.3.2. Model 2. - rezultati kontrole mliječnosti uz klasifikacijske varijable

Model uključuje svojstva koja su rezultat provedbe kontrole mliječnosti (dnevna količina mlijeka, dnevni sadržaj i količina mliječne masti, dnevni sadržaj i količina bjelančevina, omjer masti i bjelančevina, dnevni sadržaj ureje, odnos bjelančevina i ureje, dnevni sadržaj laktoze i broj somatskih stanica), nadograđen je sa slijedećim varijablama: regija, veličina stada, redni broj teljenja, sezona koncepcije i sezona teljenja.

Unutar navedenih varijabli metodom stupanjske regresije (*Stepwise Logistic Regression)* u LOGISTIC proceduri izdvojene su sljedeće varijable koje značajno utječu na dužinu trajanja servis razdoblja. Nakon izdvajanja odabranih varijabli pomoću stupanjske regresije provedena je obrada logističkom regresijom procedurom SURVEYLOGISTIC. Varijable nadograđene u drugom modelu su zatim obrađene i analizom preživljavanja za trajanje servis razdoblje usporedno za holstein i simentalsku pasminu upotrebom procedure LIFETEST. Odabrane varijable po pasminama i kontrolnim danima za model 2. prikazane su u tablici 51.

Tablica 51. Odabrane varijable po pasminama i kontrolnim danima za model 2.

Pasmina	**Kontrolni dan 1.**	**Kontrolni dan 2.**
Holstein	Dnevni sadržaj bjelančevina (DSB)	Dnevni sadržaj bjelančevina (DSB)
	Dnevni sadržaj laktoze (DSL)	Broj somatskih stanica
	Sezona koncepcije (SK)	Sezona koncepcije (SK)
	Regija (REG)	Regija (REG)
	Sezona teljenja (ST)	Sezona teljenja (ST)
	Veličina stada (VS)	
Simentalska	Dnevni sadržaj bjelančevina (DSB)	Dnevni sadržaj bjelančevina (DSB)
	Sezona teljenja (ST)	Sezona teljenja (ST)
	Sezona koncepcije (SK)	Sezona koncepcije (SK)
	Veličina stada (VS)	Veličina stada (VS)
	Omjer masti i bjelančevina (IMP)	Omjer masti i bjelančevina (IMP)
	Dnevni sadržaj laktoze (DSL)	Odnos bjelančevina i ureje (IBU)
	Dnevni sadržaj ureje (DSU)	Broj somatskih stanica (BSS)
		Dnevna količina mlijeka DKM)

Evidentno je pojavljivanje varijabli dnevni sadržaj bjelančevina, sezona koncepcije, sezona teljenja i regija kod holstein pasmine pri oba kontrolna dana te dnevni sadržaj laktoze i veličina stada u prvom kontrolnom danu. Kod simentalske pasmine pri oba kontrolna dana pojavljuju se varijable dnevni sadržaj bjelančevina, sezona teljenja, sezona koncepcije i veličina stada i omjer masti i bjelančevina. Dnevni sadržaj laktoze i dnevni sadržaj ureje pojavljuju se samo u prvom, a broj somatskih stanica i dnevna količina mlijeka samo u drugom kontrolnom danu.

3.3.2.1 Rezultati logističke regresije za model 2. i kontrolni dan 1. holstein pasmine

Provedbom logističke regresije za model 2. i kontrolni dan 1. kod holstein pasmine kao statistički visoko značajne ($p < 0,001$) izdvojene su sljedeće varijable iz rezultata provedbe kontrole mliječnosti: dnevni sadržaj bjelančevina i sadržaj laktoze (tablica 52.). U modelu su kao statistički značajne izdvojene i sljedeće varijable: sezona teljenja, sezona koncepcije, veličina stada i regija.

Prikaz omjera izgleda s 95% Waldovim intervalom povjerenja za model 2. i kontrolni dan 1. holstein pasmine prikazan je na grafikonu 13. Krave koje imaju veći dnevni sadržaj bjelančevina kod prvog kontrolnog dana imaju 28,8 % veći omjer izgleda za koncepciju uz interval povjerenja u iznosu od 1,195 – 1,389, a krave koje imaju veći sadržaj laktoze kod prvog kontrolnog dana imaju 31,6 % veći omjer izgleda za koncepciju uz interval povjerenja u iznosu od 1,147 – 1,511.

Tablica 52. Rezultati logističke regresije za model 2. i kontrolni dan 1. holstein pasmine

	Procjena parametara β	**Standardna greška**	**p**	**Omjer izgleda**
INTERCEPT 1	-2,5428	0,3717	<0,0001	
INTERCEPT 2	-1,3500	0,3716	0,0003	
INTERCEPT 3	-0,4979	0,3717	0,1804	
INTERCEPT 4	0,3276	0,3718	0,3784	
INTERCEPT 5	1,3222	0,3722	0,0004	
DSB	0,2534	0,0385	<0,0001	1,288
DSL	0,2750	0,0704	<0,0001	1,316
SEZONA TELJENJA 1 (1vs4)	0,8763	0,0519	<0,0001	2,402
SEZONA TELJENJA 2 (2vs4)	0,3963	0,0834	<0,0001	1,486
SEZONA TELJENJA 3 (3vs4)	-1,0018	0,0487	<0,0001	0,367
SEZONA KONCEPCIJE 1 (1vs4)	-0,9936	0,0485	<0,0001	0,370
SEZONA KONCEPCIJE 2 (2vs4)	-1,9435	0,0701	<0,0001	0,143
SEZONA KONCEPCIJE 3 (3vs4)	-1,5407	0,0893	<0,0001	0,214
VELIČINA STADA 1 (1vs5)	0,0109	0,0485	<0,0001	1,011
VELIČINA STADA 2 (2vs5)	0,0436	0,0573	<0,0001	1,045
VELIČINA STADA 3 (3vs5)	0,1440	0,0583	<0,0001	1,155
VELIČINA STADA 4 (4vs5)	0,1123	0,0752	<0,0001	1,119
REGIJA 1 (1vs5)	-0,3788	0,0766	<0,0001	0,685
REGIJA 2 (2vs5)	-0,1878	0,0854	0,0279	0,829
REGIJA 3 (3vs5)	-0,3356	0,0677	<0,0001	0,715
REGIJA 4 (4vs5)	-0,2843	0,0522	<0,0001	0,753

Krave koje su imale prethodno teljenje u prvoj sezoni (od prosinca do veljače) u odnosu na krave koje su imale prethodno teljenje u četvrtoj sezoni (od rujna do studenog) imaju 2,4 puta veći omjer izgleda za koncepciju uz interval povjerenja u iznosu od 2,170 –2,659. Krave koje su imale prethodno teljenje u drugoj sezoni (od ožujka do svibnja) u odnosu na krave koje su imale prethodno teljenje u četvrtoj sezoni imaju 1,49 puta veći omjer izgleda za koncepciju uz interval povjerenja od 1,262 – 1,750. Krave koje su imale prethodno teljenje u trećoj sezoni (od lipnja do kolovoza) u odnosu na krave koje su imale prethodno teljenje u četvrtoj sezoni imaju 63,3 % manji omjer izgleda za koncepciju uz interval povjerenja od 0,337 – 0,407.

Krave koje su imale prethodnu koncepciju u prvoj sezoni u odnosu na krave koje su imale prethodnu koncepciju u četvrtoj sezoni (od rujna do studenog) imaju 63 % manji omjer izgleda za koncepciju uz interval povjerenja od 0,337 – 0,407. Krave koje su imale prethodnu koncepciju u drugoj sezoni u odnosu na krave koje su imale prethodnu koncepciju u četvrtoj sezoni imaju 85,7 % manji omjer izgleda za koncepciju uz interval povjerenja od 0,125 – 0,164. Krave koje su imale prethodnu koncepciju u trećoj sezoni u odnosu na krave koje su imale prethodnu koncepciju u četvrtoj sezoni imaju 78,6 % manji omjer izgleda za koncepciju uz interval povjerenja od 0,180 – 0,255.

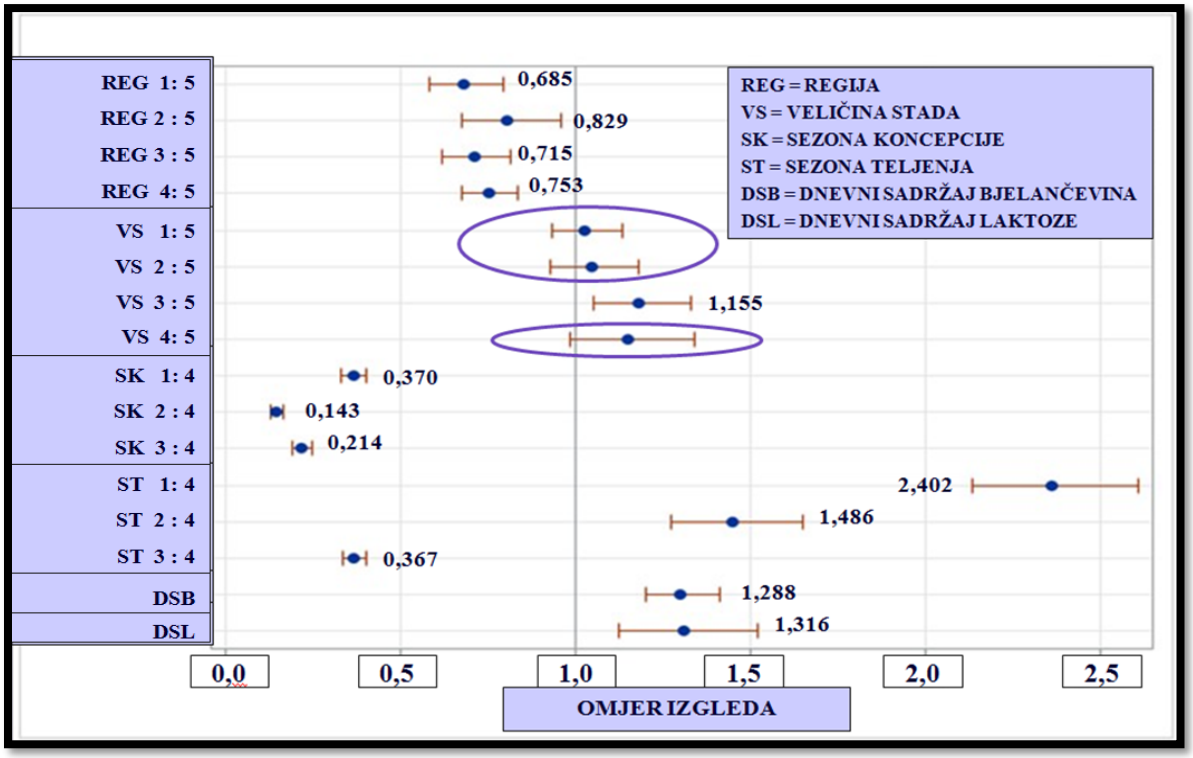

Grafikon 13: Prikaz omjera izgleda s 95% Waldovim intervalom povjerenja za model 2. i kontrolni dan 1. holstein pasmine

Krave koje se nalaze u prvom razredu veličine stada (1 – 10 krava) u odnosu na peti razred veličine stada (100 krava i više) imaju 1,1 % veći omjer izgleda za koncepciju uz interval povjerenja u iznosu od 0,919 – 1,112. Krave koje se nalaze u drugom razredu veličine stada (1 – 20 krava) u odnosu na peti razred veličine stada (100 krava i više) imaju 4,5 % veći omjer izgleda za koncepciju uz interval povjerenja u iznosu od 0,934-1,169. Krave koje se nalaze u trećem razredu veličine stada (20 – 50 krava) u odnosu na peti razred veličine stada (100 krava i više) imaju 15,5 % veći omjer izgleda za koncepciju uz

interval povjerenja u iznosu od 1,030 – 1,295. Krave koje se nalaze u četvrtom razredu veličine stada (20 – 50 krava) u odnosu na peti razred veličine stada (50-100 krava) imaju 11,9 % veći omjer izgleda za koncepciju uz interval povjerenja od 0,966 – 1,297. Krave koje se nalaze u prvoj regiji (Grad Zagreb i Zagrebačka županija, Međimurska, Varaždinska, Krapinsko zagorska) u odnosu na petu regiju (Zadarska, Šibensko kninska, Splitsko dalmatinska, Istarska) imaju 31,5 % manji omjer izgleda za koncepciju uz interval povjerenja od 0,589 – 0,796. Krave koje se nalaze u drugoj regiji (Sisačko moslavačka, Karlovačka, Ličko senjska) u odnosu na petu regiju imaju 17,1 % manji omjer izgleda za koncepciju uz interval povjerenja od 0,701 – 0,980. Krave koje se nalaze u trećoj regiji (Bjelovarsko bilogorska, Koprivničko križevačka) u odnosu na petu regiju imaju 28,5 % manji omjer izgleda za koncepciju uz interval povjerenja od 0,626 – 0,816. Krave koje se nalaze u četvrtoj regiji (Osječko baranjska, Vukovarsko srijemska, Brodsko posavska, Požeško slavonska, Virovitičko podravska) u odnosu na petu regiju imaju 24,7% manji omjer izgleda za koncepciju uz interval povjerenja 0,679 – 0,834.

3.3.2.2. Rezultati logističke regresije za model 2. i kontrolni dan 2. holstein pasmine

Tablica 53. Rezultati logističke regresije za model 2. i kontrolni dan 2. holstein pasmine

	Procjena parametara β	Standardna greška	p	Omjer izgleda
INTERCEPT 1	-1,6154	0,1655	<0,0001	
INTERCEPT 2	-0,4073	0,1656	0,0139	
INTERCEPT 3	0,4484	0,1662	0,0070	
INTERCEPT 4	1,2767	0,1668	<0,0001	
INTERCEPT 5	2,2844	0,1678	<0,0001	
DSB	0,4934	0,0488	<0,0001	1,638
BSS	-0,0418	0,00691	<0,0001	0,959
SEZONA TELJENJA 1 (1vs4)	0,9274	0,0521	<0,0001	2,528
SEZONA TELJENJA 2 (2vs4)	0,4970	0,0840	<0,0001	1,644
SEZONA TELJENJA 3 (3vs4)	-1,0269	0,0481	<0,0001	0,358
SEZONA KONCEPCIJE 1 (1vs4)	-1,0531	0,0481	<0,0001	0,349
SEZONA KONCEPCIJE 2 (2vs4)	-1,9831	0,0702	<0,0001	0,138
SEZONA KONCEPCIJE 3 (3vs4)	-1,6154	0,0903	<0,0001	0,199
REGIJA 1 (1vs5)	-0,3041	0,0665	<0,0001	0,738
REGIJA 2 (2vs5)	-0,1127	0,0780	0,1487	0,893
REGIJA 3 (3vs5)	-0,2558	0,0580	<0,0001	0,774
REGIJA 4 (4vs5)	-0,2515	0,0519	<0,0001	0,778

Provedbom logističke regresije za model 2. i kontrolni dan 2. kod holstein pasmine kao statistički visoko značajni ($p < 0,001$) izdvojene su sljedeće varijable iz rezultata provedbe kontrole mliječnosti: dnevni sadržaj bjelančevina i broj somatskih stanica (tablica 53.). U modelu su kao statistički značajne izdvojene i sljedeće varijable: sezona teljenja, sezona koncepcije i regija. Prikaz omjera izgleda s 95% Waldovim intervalom povjerenja za model 2. kontrolni dan 2. holstein pasmine vidljiv je na grafikonu 14.

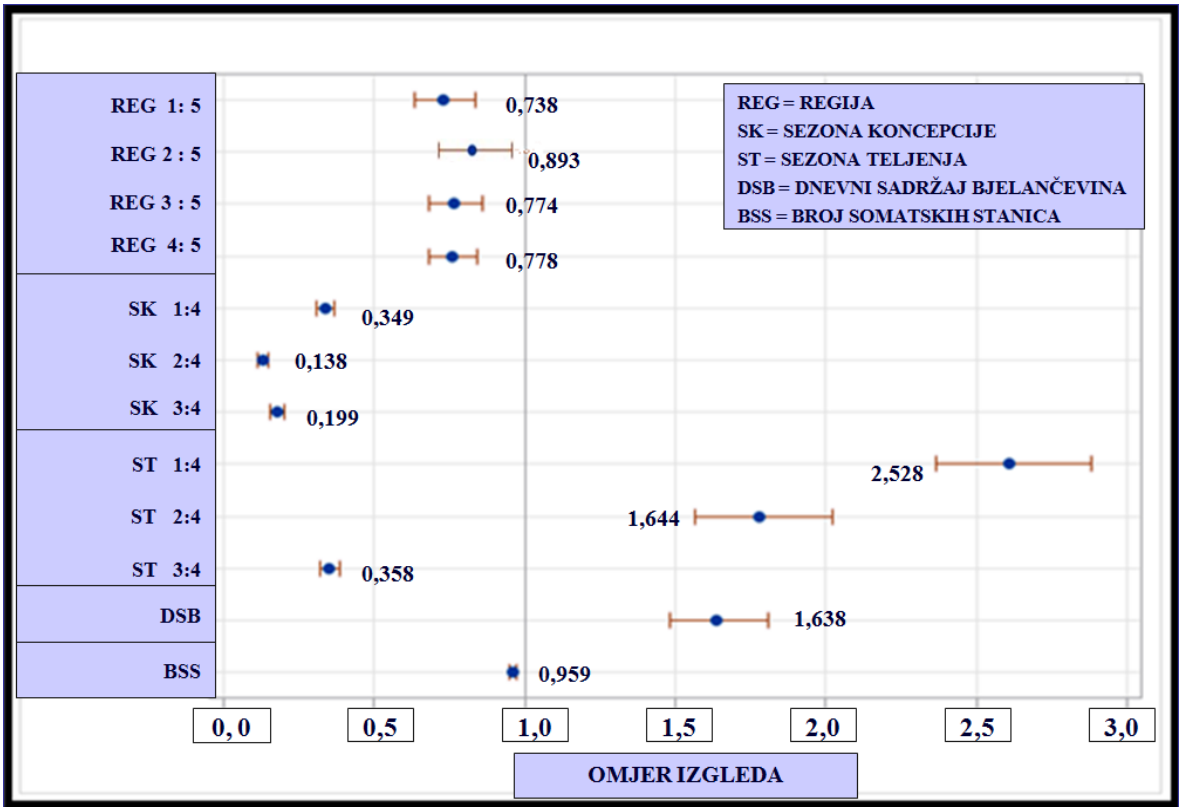

Grafikon 14: Prikaz omjera izgleda s 95% Waldovim intervalom povjerenja za model 2. i kontrolni dan 2. holstein pasmine

Krave koje imaju veći dnevni sadržaj bjelančevina kod drugog kontrolnog dana imaju 63,8 % veći omjer izgleda za koncepciju uz interval povjerenja od 1,488 – 1,802. Krave koje imaju veći broj somatskih stanica kod drugog kontrolnog dana imaju 4,1 % manji omjer izgleda za koncepciju uz interval povjerenja od 0,946 – 0,972. Krave koje su imale prethodno teljenje u prvoj sezoni (od prosinca do veljače) u odnosu na krave koje su imale prethodno teljenje u četvrtoj sezoni (od rujna do studenog) imaju 2,53 puta veći omjer izgleda za koncepciju uz interval povjerenja od 2,283 – 2,800. Krave koje su imale prethodno teljenje u drugoj sezoni (od ožujka do svibnja) u odnosu na krave koje su imale prethodno teljenje u četvrtoj sezoni imaju 1,64 puta veći omjer izgleda za koncepciju uz

interval povjerenja od 1,394 – 1,938. Krave koje su imale prethodno teljenje u trećoj sezoni (od lipnja do kolovoza) u odnosu na krave koje su imale prethodno teljenje u četvrtoj sezoni imaju 64,2 % manji omjer izgleda za koncepciju uz interval povjerenja od 0,326 – 0,394. Krave koje su imale prethodnu koncepciju u prvoj sezoni u odnosu na krave koje su imale prethodnu koncepciju u četvrtoj sezoni imaju 65,1 % manji omjer izgleda za koncepciju uz interval povjerenja od 0,317-0,383. Krave koje su imale prethodnu koncepciju u drugoj sezoni u odnosu na krave koje su imale prethodnu koncepciju u četvrtoj sezoni imaju 86,2 % manji omjer izgleda za koncepciju uz interval povjerenja od 0,120 – 0,158. Krave koje su imale prethodnu koncepciju u trećoj sezoni u odnosu na krave koje su imale prethodnu koncepciju u četvrtoj sezoni imaju 80,1 % manji omjer izgleda za koncepciju uz interval povjerenja od 0,167 – 0,238. Krave koje se nalaze u prvoj regiji (Grad Zagreb i Zagrebačka županija, Međimurska, Varaždinska, Krapinsko zagorska) u odnosu na petu regiju (Zadarska, Šibensko kninska, Splitsko dalmatinska, Istarska) imaju 26,2 % manji omjer izgleda za koncepciju uz interval povjerenja od 0,648-0,840. Krave koje se nalaze u drugoj regiji (Sisačko moslavačka, Karlovačka, Ličko senjska) u odnosu na petu regiju imaju 10,7 % manji omjer izgleda za koncepciju uz interval povjerenja od 0,767 – 1,041. Krave koje se nalaze u trećoj regiji (Bjelovarsko bilogorska, Koprivničko križevačka) u odnosu na petu regiju imaju 22,6 % manji omjer izgleda za koncepciju uz interval povjerenja od 0,694 – 0,871. Krave koje se nalaze u četvrtoj regiji (Osječko baranjska, Vukovarsko srijemska, Brodsko posavska, Požeško slavonska, Virovitičko podravska) u odnosu na petu regiju imaju 22,2% manji omjer izgleda za koncepciju uz interval povjerenja od 0,702 – 0,861.

3.3.2.3. Rezultati logističke regresije za model 2. i kontrolni dan 1. simentalske pasmine

Rezultati logističke regresije za model 2. i kontrolni dan 1. simentalske pasmine prikazani su u tablici 54. Provedbom logističke regresije za prvi kontrolni dan kod simentalske pasmine kao statistički visoko značajne ($p < 0,001$) izdvojene su sljedeće varijable iz rezultata provedbe kontrole mliječnosti: dnevni sadržaj bjelančevina, dnevni sadržaj laktoze te omjer masti i bjelančevina. Varijabla dnevni sadržaj ureje nalazi se na granici statističke značajnosti što je vidljivo i kroz raspon intervala povjerenja koji završava s vrijednosti **1** uz interval povjerenja od 0,971 – 1,000. U modelu su izdvojene i

slijedeće varijable kao statistički značajne: sezona teljenja, sezona koncepcije i veličina stada.

Tablica 54. Rezultati logističke regresije za model 2. i kontrolni dan 1. simentalske pasmine

	Procjena parametara β	**Standardna greška**	**p**	**Omjer izgleda**
INTERCEPT 1	-2,8881	0,4515	<0,0001	
INTERCEPT 2	-1,5832	0,4511	0,0004	
INTERCEPT 3	-0,6224	0,4511	0,1677	
INTERCEPT 4	0,2976	0,4512	0,5096	
INTERCEPT 5	1,3629	0,4516	0,0025	
DSB	0,1287	0,0377	0,0006	1,137
DSU	-0,00299	0,00142	0,0350	0,997
DSL	0,3997	0,0737	<0,0001	1,491
IMP	-0,1599	0,0498	0,0013	0,852
SEZONA TELJENJA 1 (1vs4)	1,2444	0,0535	<0,0001	3,471
SEZONA TELJENJA 2 (2vs4)	2,1062	0,0894	<0,0001	8,217
SEZONA TELJENJA 3 (3vs4)	-1,1828	0,0500	<0,0001	0,306
SEZONA KONCEPCIJE 1 (1vs4)	-1,3005	0,0504	<0,0001	0,272
SEZONA KONCEPCIJE 2 (2vs4)	-2,5582	0,0794	<0,0001	0,077
SEZONA KONCEPCIJE 3 (3vs4)	-3,1712	0,1112	<0,0001	0,042
VELIČINA STADA 1 (1vs5)	0,4799	0,1661	0,0039	1,616
VELIČINA STADA 2 (2vs5)	0,4874	0,1674	0,0036	1,628
VELIČINA STADA 3 (3vs5)	0,5964	0,1701	0,0005	1,815
VELIČINA STADA 4 (4vs5)	0,6817	0,1813	0,0002	1,977

Prikaz omjera izgleda s 95% Waldovim intervalom povjerenja za model 2. i kontrolni dan 1. simentalske pasmine vidljiv je na grafikonu 15. Krave koje imaju veći dnevni sadržaj bjelančevina kod prvog kontrolnog dana imaju 13,7% veći omjer izgleda za koncepciju uz interval povjerenja od 1,056 – 1,225. Krave koje imaju veći sadržaj laktoze kod prvog kontrolnog dana imaju 49,1% veći omjer izgleda za koncepciju uz interval povjerenja od 1,291 – 1,723. Krave koje imaju veći sadržaj ureje kod kontrolnog dana 1. imaju 0,3% manji omjer izgleda za koncepciju uz interval povjerenja 0,994 – 1,000. Krave koje imaju niže vrijednosti omjera masti i bjelančevina imaju 14,8 % veći omjer izgleda za koncepciju uz interval povjerenja 0,770 – 0,940.

Krave koje su imale prethodno teljenje u prvoj sezoni (od prosinca do veljače) u odnosu na krave koje su imale prethodno teljenje u četvrtoj sezoni (od rujna do studenog) imaju 3,47 puta veći omjer izgleda za koncepciju uz interval povjerenja od 3,126 – 3,854. Krave koje su imale prethodno teljenje u drugoj sezoni (od ožujka do svibnja) u odnosu na

krave koje su imale prethodno teljenje u četvrtoj sezoni imaju 8,22 puta veći omjer izgleda za koncepciju uz interval povjerenja od 6,897 – 9,790. Krave koje su imale prethodno teljenje u trećoj sezoni (od lipnja do kolovoza) u odnosu na krave koje su imale prethodno teljenje u četvrtoj sezoni imaju 69,4 % manji omjer izgleda za koncepciju uz interval povjerenja od 0,278 – 0,338.

Krave koje su imale prethodnu koncepciju u prvoj sezoni u odnosu na krave koje su imale prethodnu koncepciju u četvrtoj sezoni imaju 72,8% manju vjerojatnost koncepcije uz interval povjerenja od 0,247 – 0,301. Krave koje su imale prethodnu koncepciju u drugoj sezoni u odnosu na krave koje su imale prethodnu koncepciju u četvrtoj sezoni imaju 92,3% manju vjerojatnost koncepcije uz interval povjerenja od 0,066 – 0,090. Krave koje su imale prethodnu koncepciju u trećoj sezoni u odnosu na krave koje su imale prethodnu koncepciju u četvrtoj sezoni imaju 95,8 % manji omjer izgleda za koncepciju uz interval povjerenja od 0,034 – 0,052.

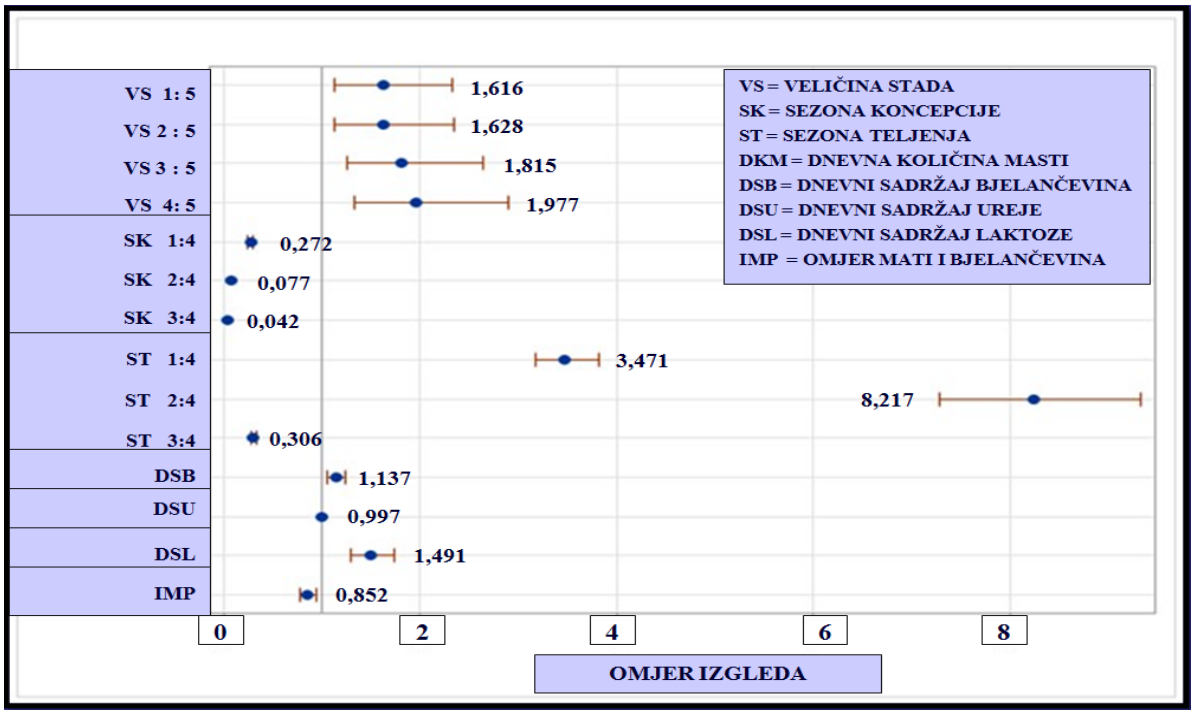

Grafikon 15: Prikaz omjera izgleda s 95% Waldovim intervalom povjerenja za model 2. i kontrolni dan 1. simentalske pasmine

Krave koje se nalaze u prvom razredu veličine stada (1 – 10 krava) u odnosu na peti razred veličine stada (100 krava i više) imaju 61,6% veći omjer izgleda za koncepciju uz interval povjerenja od 1,167 – 2,238. Krave koje se nalaze u drugom razredu veličine stada

(10 – 20 krava) u odnosu na peti razred veličine stada (100 krava i više) imaju 62,8% veći omjer izgleda za koncepciju uz interval povjerenja od 1,173 – 2,260. Krave koje se nalaze u trećem razredu veličine stada (20 – 50 krava) u odnosu na peti razred veličine stada (100 krava i više) imaju 81,5% veći omjer izgleda za koncepciju uz interval povjerenja u iznosu od 1,301 – 2,821. Krave koje se nalaze u četvrtom razredu veličine stada (20 – 50 krava) u odnosu na peti razred veličine stada (50 – 100 krava) imaju 97,7% veći omjer izgleda za koncepciju uz interval povjerenja od 1,386 – 2,821.

3.3.2.4. Rezultati logističke regresije za model 2. i kontrolni dan 2. simentalske pasmine

Tablica 55. Rezultati logističke regresije za model 2. i kontrolni dan 2. simentalske pasmine

	Procjena parametara β	**Standardna greška**	**p**	**Omjer izgleda**
INTERCEPT 1	-1,2758	0,3271	<0,0001	
INTERCEPT 2	0,0318	0,3273	0,9227	
INTERCEPT 3	0,9908	0,3277	0,0025	
INTERCEPT 4	1,9008	0,3280	<0,0001	
INTERCEPT 5	2,9667	0,3292	<0,0001	
DSB	0,2865	0,0747	0,0001	1,332
BSS	-0,0289	0,00612	<0,0001	0,972
DKM	-0,00460	0,00227	0,0430	0,995
IMP	-0,1540	0,0493	0,0018	0,857
IBU A1 (A1vsB2)	-0,2509	0,1333	0,0598	0,778
IBU A2 (A2vsB2)	-0,2668	0,1363	0,0503	0,764
IBU A3 (A3vsB2)	-0,4126	0,2374	0,0822	0,662
IBU B1 (B1vs B2)	0,0170	0,0509	0,7378	0,661
IBU B3 (B3 vs B2)	0,1622	0,0858	0,0588	1,017
IBU C1 (C1vsB2)	0,0335	0,0565	0,5530	1,176
IBU C2 (C2vsB2)	-0,0230	0,0575	0,6891	1,034
IBU C3 (C3vsB2)	-0,0353	0,0735	0,6309	0,977
VELIČINA STADA 1 (1vs5)	0,4711	0,1605	0,0033	1,602
VELIČINA STADA 2 (2vs5)	0,4892	0,1616	0,0025	1,631
VELIČINA STADA 3 (3vs5)	0,5555	0,1646	0,0007	1,743
VELIČINA STADA 4 (4vs5)	0,6759	0,1759	0,0001	1,966
SEZONA TELJENJA 1 (1vs4)	1,2217	0,0529	<0,0001	3,393
SEZONA TELJENJA 2 (2vs4)	2,0956	0,0872	<0,0001	8,131
SEZONA TELJENJA. 3 (3vs4)	-1,1749	0,0491	<0,0001	0,309
SEZONA KONCEPCIJE 1 (1vs4)	-1,2845	0,0495	<0,0001	0,277
SEZONA KONCEPCIJE 2 (2vs4)	-2,4724	0,0777	<0,0001	0,084
SEZONA KONCEPCIJE 3 (3vs4)	-3,1005	0,1079	<0,0001	0,045

Rezultati logističke regresije za model 2. i kontrolni dan 2. simentalske pasmine prikazani su u tablici 55. Provedbom logističke regresije za drugi kontrolni dan kod simentalske pasmine kao statistički visoko značajne ($p < 0,001$) izdvojene su sljedeće varijable iz rezultata provedbe kontrole mliječnosti: dnevni sadržaj bjelančevina, broj somatskih stanica, dnevna količina mlijeka, omjer masti i bjelančevina te odnos ureje i bjelančevina. U modelu su kao značajne izdvojene i sljedeće varijable kao statistički značajne: sezona teljenja, sezona koncepcije i veličina stada.

Prikaz omjera izgleda s 95% Waldovim intervalom povjerenja za model 2. i kontrolni dan 2. simentalske pasmine vidljiv je na grafikonu 16.

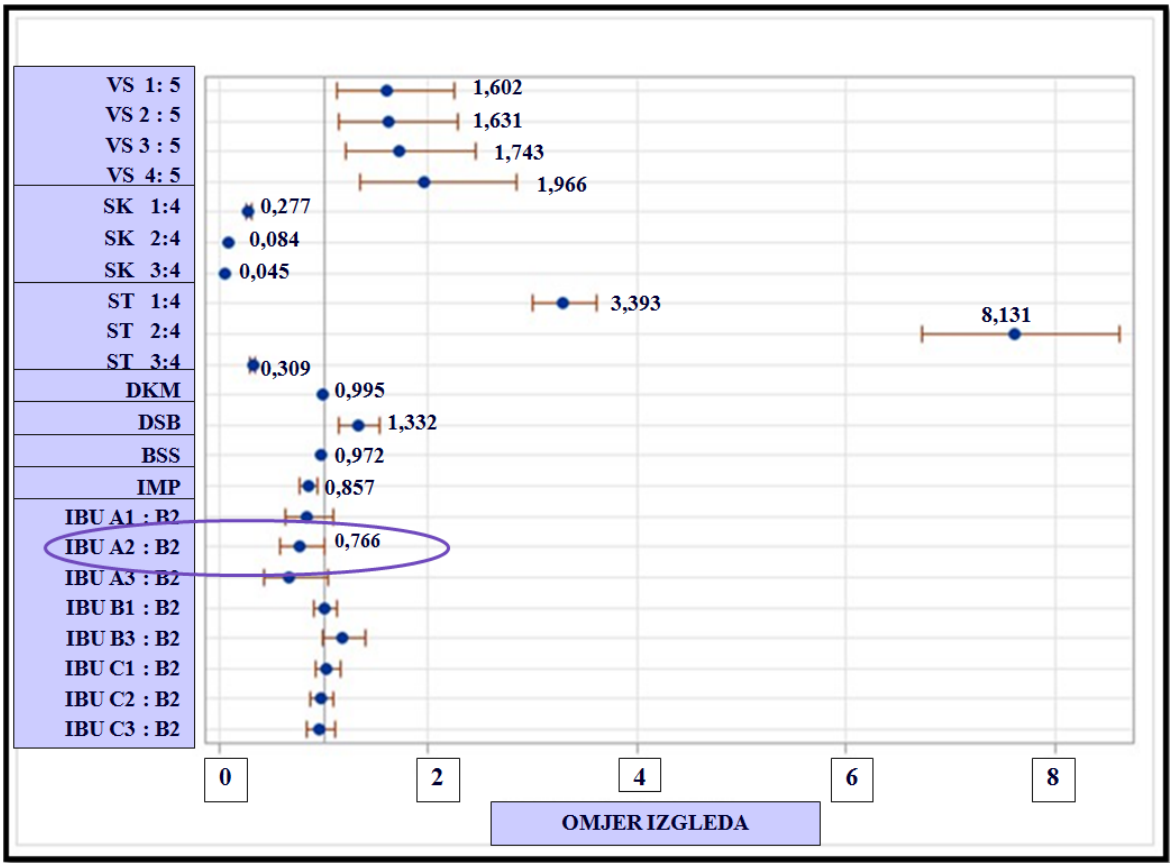

Grafikon 16: Prikaz omjera izgleda s 95% Waldovim intervalom povjerenja za model 2. i kontrolni dan 2. kontrolni dan simentalske pasmine

Krave koje imaju veći dnevni sadržaj bjelančevina kod drugog kontrolnog dana imaju 33,2 % veći omjer izgleda za koncepciju uz interval povjerenja od 1,159 – 1,554. Krave koje imaju veći broj somatskih stanica kod drugog kontrolnog dana imaju 2,8% manji omjer izgleda za koncepciju uz interval povjerenja 0,960 – 0,983. Krave koje imaju

veću dnevnu količinu proizvedenog mlijeka kod drugog kontrolnog dana imaju 0,5% manji omjer izgleda za koncepciju uz interval povjerenja 0,992 – 0,998**.**

Krave koje imaju niže vrijednosti omjera masti i bjelančevina imaju 14,3 % veći omjer izgleda za koncepciju uz interval povjerenja 0,774 – 0,946.

Procjena omjera izgleda za odnose mliječnih bjelančevina i ureje (IBU) obavljena je s referentnim B2 razredom koji ima sadržaj bjelančevina od 3,21% i sadržaj ureje 15,01 do 30, 00 mg/dl. Izdvojen je samo razred kod kojeg se unutar granice intervala povjerenja ne nalazi vrijednost izražena brojem **1**. Krave koje se nalaze u A2 razredu IBU (≥ 3,81% bjelančevina i 15,00 – 30 mg/dl ureje)) imaju 24% manji omjer izgleda za koncepciju uz interval povjerenja od 0,581 – 0,993.

Krave koje se nalaze u prvom razredu veličine stada (1 – 10 krava) u odnosu na peti razred veličine stada (100 krava i više) imaju 60,2% veći omjer izgleda za koncepciju uz interval povjerenja od 1,186 – 2,231. Krave koje se nalaze u drugom razredu veličine stada (10 – 20 krava) u odnosu na peti razred veličine stada (100 krava i više) imaju 63,1% veći omjer izgleda za koncepciju uz interval povjerenja od 1,209 – 2,284. Krave koje se nalaze u trećem razredu veličine stada (20 – 50 krava) u odnosu na peti razred veličine stada (100 krava i više) imaju 74,3 % veći omjer izgleda za koncepciju uz interval povjerenja u iznosu od 1,280 – 2,831. Krave koje se nalaze u četvrtom razredu veličine stada (20 – 50 krava) u odnosu na peti razred veličine stada (50 – 100 krava) imaju 2 puta veći omjer izgleda za koncepciju uz interval povjerenja od 1,420 – 2,831.

Krave koje su imale prethodno teljenje u prvoj sezoni (od prosinca do veljače) u odnosu na krave koje su imale prethodno teljenje u četvrtoj sezoni (od rujna do studenog) imaju 3,39 puta veći omjer izgleda za koncepciju uz interval povjerenja od 3,071 – 3,778. Krave koje su imale prethodno teljenje u drugoj sezoni (od ožujka do svibnja) u odnosu na krave koje su imale prethodno teljenje u četvrtoj sezoni imaju 8,13 puta veći omjer izgleda za koncepciju uz interval povjerenja od 6,932 – 9,753. Krave koje su imale prethodno teljenje u trećoj sezoni (od lipnja do kolovoza) u odnosu na krave koje su imale prethodno teljenje u četvrtoj sezoni imaju 69,1% manji omjer izgleda za koncepciju uz interval povjerenja u iznosu od 0,283 – 0,343.

Krave koje su imale prethodnu koncepciju u prvoj sezoni u odnosu na krave koje su imale prethodnu koncepciju u četvrtoj sezoni imaju 72,3% manji omjer izgleda za koncepciju uz interval povjerenja od 0,251 – 0,305. Krave koje su imale prethodnu

koncepciju u drugoj sezoni u odnosu na krave koje su imale prethodnu koncepciju u četvrtoj sezoni imaju 91,6% manji omjer izgleda za koncepciju uz interval povjerenja od 0,073 – 0,098. Krave koje su imale prethodnu koncepciju u trećoj sezoni u odnosu na krave koje su imale prethodnu koncepciju u četvrtoj sezoni imaju 95,5% manji omjer izgleda za koncepciju uz interval povjerenja od 0,037 – 0,056.

Izdvajanje dnevnog sadržaja bjelančevina kao statistički visoko značajne ($p < 0,001$) varijable kod obje pasmine i pri oba kontrolna dana u prvom i drugom modelu u povećavanju omjera izgleda za koncepciju u predmetnom istraživanju sukladno je naglašenom značaju povezanosti sadržaja bjelančevina u mlijeku i rezultata reprodukcijske učinkovitosti utvrđenim u istraživanjima Morton i sur. (2001.), Buckley i sur. (2003.), Patton i sur. (2007.), te Yang i sur. (2010.). Utjecaj promjena u konzumaciji suhe tvari i uspostave energetske ravnoteže u tranzicijskom razdoblju od presudnog je utjecaja na sadržaj bjelančevina u mlijeku. Ukoliko je kraće trajanje razdoblja negativne energetske ravnoteže prije se uspostavlja uobičajena lutealna aktivnost i povećava vjerojatnost skraćivanja trajanja servis razdoblja.

Povezanost između povećanog broja somatskih stanica i slabijih rezultata reprodukcijske učinkovitosti utvrđeno je u radovima Barker i sur. (1998.), Miller i sur. (2001.), Morek-Kopeć i sur. (2008.), Madousse i sur. (2010.), Nguyen i sur. (2011.), Hudson i sur. (2012), te Lomander i sur. (2013.). U predmetnom istraživanju povećanje broja somatskih stanica u prvom modelu umanjuje vjerojatnost omjer izgleda za koncepciju kod holstein pasmine u oba kontrolna dana a kod simentalske pasmine kod drugog kontrolnog dana, dok kod drugog modela broj somatskih stanica je izdvojen kao statistički visoko značajan u drugom kontrolnom danu za obadvije pasmine. Krave koje imaju povećani broj somatskih stanica na početku laktacije imaju dužu obnovu ciklusa jajnika nakon teljenja zbog čega se produžava trajanje servis razdoblja.

Povećani sadržaj laktoze u mlijeku odražava raniji izlazak iz stanja negativne energetske ravnoteže u tranzicijskom razdoblju. Pozitivan učinak na skraćenje trajanja servis razdoblja uslijed povećane lutealne aktivnosti utvrđen je u istraživanjima Reksen i sur. (2002.), Francisco i sur. (2003.), Buckley i sur. (2003.). Rezultati istraživanja Masilo i sur. (1992.) pak ne upućuju na povezanost između sadržaja laktoze u mlijeku i obnove spolnog ciklusa nakon teljenja. Izdvajanje dnevnog sadržaja laktoze kao statistički visoko značajne varijable u predmetnom istraživanju kod obje pasmine i oba modela samo kod

prvog kontrolnog dana, moguće je povezati s povećanim brojem somatskih stanica u razdoblju neposredno nakon teljenja (osobito od 5 do 8 dana) te ograničenom upotrebom laktoze kao indikatora negativne energetske ravnoteže u tranzicijskom razdoblju (Buckley i sur., 2003.).

Odnos između povećanog sadržaja ureje u mlijeku i lošijih rezultata reprodukcijske uspješnosti utvrđen je od strane Butler i sur. (1998.), Melendez i sur. (2000.) te Rajala-Shultz (2001.), dok na neznatnu povezanost upućuju rezultati istraživanja Godden i sur. (2001.), Guo i sur. (2004.), te Hojman i sur. (2004.). Izdvajanje dnevnog sadržaja ureje i trajanja servis razdoblja kao statistički visoko značajne varijable u predmetnom istraživanju utvrđeno je samo u drugom kontrolnom danu u oba modela kod simentalske pasmine. Obzirom da sadržaj ureje u mlijeku može biti dobar indikator negativne energetske ravnoteže (DePeters i Ferguson (1992.), Broderick i Clayton (1997.), Bendelja i sur. (2009.), Marenjak (2004.)) onda se u neučinkovitoj upotrebi bjelančevina uslijed poremećene ravnoteže između konzumiranih bjelančevina i energije nalazi razlog pojavljivanja sadržaja ureje u mlijeku u drugom kontrolnom danu kod simentalske pasmine.

Međusobni omjer mliječne masti i bjelančevina indikator je negativnog energetskog statusa krava u tranzicijskom razdoblju. Povećanje vrijednosti omjera mliječne masti i bjelančevina iznad 1,5 ukazuje na korištenje tjelesnih rezervi za podmirenje energetskih zahtjeva u proizvodnji mlijeka te se povezuje s pojavom ketoze. Povećanje vrijednosti omjera mliječne masti i bjelančevina uzrokovalo je produženje trajanja servis razdoblja u istraživanjima Heuer i sur. (1999.), Paura i sur. (2012.), Podpecan i sur. (2010.), te Negussie i sur. (2013.) dok je u ovom istraživanju izdvojen kao statistički visoko značajan utjecaj kod simentalske pasmine pri oba kontrolna dana u prvom modelu te u prvom kontrolnom danu u drugom modelu.

Međusobni odnos sadržaja bjelančevina i ureje u mlijeku na početku laktacije je pokazatelj hranidbenog statusa mliječnih krava s naglaskom na opskrbljenost probavljivim bjelančevinama i energijom (Eicher, 2004.; Babnik i sur., 2004.; Gantner i sur., 2006.). Izdvajanje razreda A2 samo kod drugog kontrolnog dana za simentalsku pasminu u drugom modelu kao statistički značajnih ukazuje na negativan utjecaj prekomjerne opskrbe energijom na dužinu trajanja servis razdoblja.

3.4. Analiza preživljavanja trajanja servis razdoblja

Analiza preživljavanja za trajanje servis razdoblje usporedno za holstein i simentalsku pasminu učinjena je prema LIFETEST proceduri. Krave su cenzurirane prema vremenskom razdoblju u kojem su ostajale gravidne, odnosno s danom završetka trajanja servis razdoblja. Ispitivanje statističke ekvivalentnosti između krivulja za simentalsku i holstein pasminu provedeno je s Log-Rank, Wilcoxon i testom maksimalne vjerodostojnosti.

3.4.1. Analiza preživljavanja trajanja servis razdoblja po pasminama

Ispitivanje statističke ekvivalentnosti između krivulja za simentalsku i holstein pasminu provedeno je s Log-Rank, Wilcoxon i testom maksimalne vjerodostojnosti. Sva tri provedena testa pokazuju postojanje visoko značajne statističke razlike ($p < 0,01$) kretanja krivulje trajanja servis razdoblja između holstein i simentalske pasmine.

Kaplan Meirove krivulje preživljavanja trajanja servis razdoblja zasebno za svaku pasminu prikazane su na grafikonu 17. Analizom kretanja krivulje preživljavanja iskazana je vjerojatnost koncepcije od 5% za holstein i 6% za simentalsku pasminu na kraju prvog razreda odnosno u periodu do 60 dana servis razdoblja. Vjerojatnost koncepcije u drugom razredu odnosno od 60 do 81 dana servis razdoblja iznosi 11% za holstein pasminu i 14% za simentalsku pasminu. Vjerojatnost koncepcije u trećem razredu servis razdoblja odnosno od 82 do 102 dana servis razdoblja iznosi 18% za holstein pasminu i 23% za simentalsku pasminu. Vjerojatnost koncepcije u četvrtom razredu servis razdoblja odnosno od 103 do 123 dana servis razdoblja iznosi 25% za holstein pasminu i 31% za simentalsku pasminu. Vjerojatnost koncepcije u petom razredu servis razdoblja odnosno od 122 do 144 dana servis razdoblja iznosi 35% za holstein pasminu i 40% za simentalsku pasminu. Vjerojatnost koncepcije u zadnjem šestom razredu odnosno od 145 do 165 dana je najveća za obje pasmine i kreće se od 35 do 66 % za holstein te od 40 do 69 % za simentalsku pasminu.

Obje krivulje imaju monotono rastući tijek do kraja četvrtog razreda, nakon čega slijedi oštriji rast krivulje. Krivulje se najviše udaljavaju tijekom trećeg i četvrtog razreda, a najviše približavaju u šestom razredu.

Sagledavajući tijek krivulja preživljavanja po pasminama izraženija je veća vjerojatnost koncepcije po svim razredima za simentalsku u odnosu na holstein pasminu.

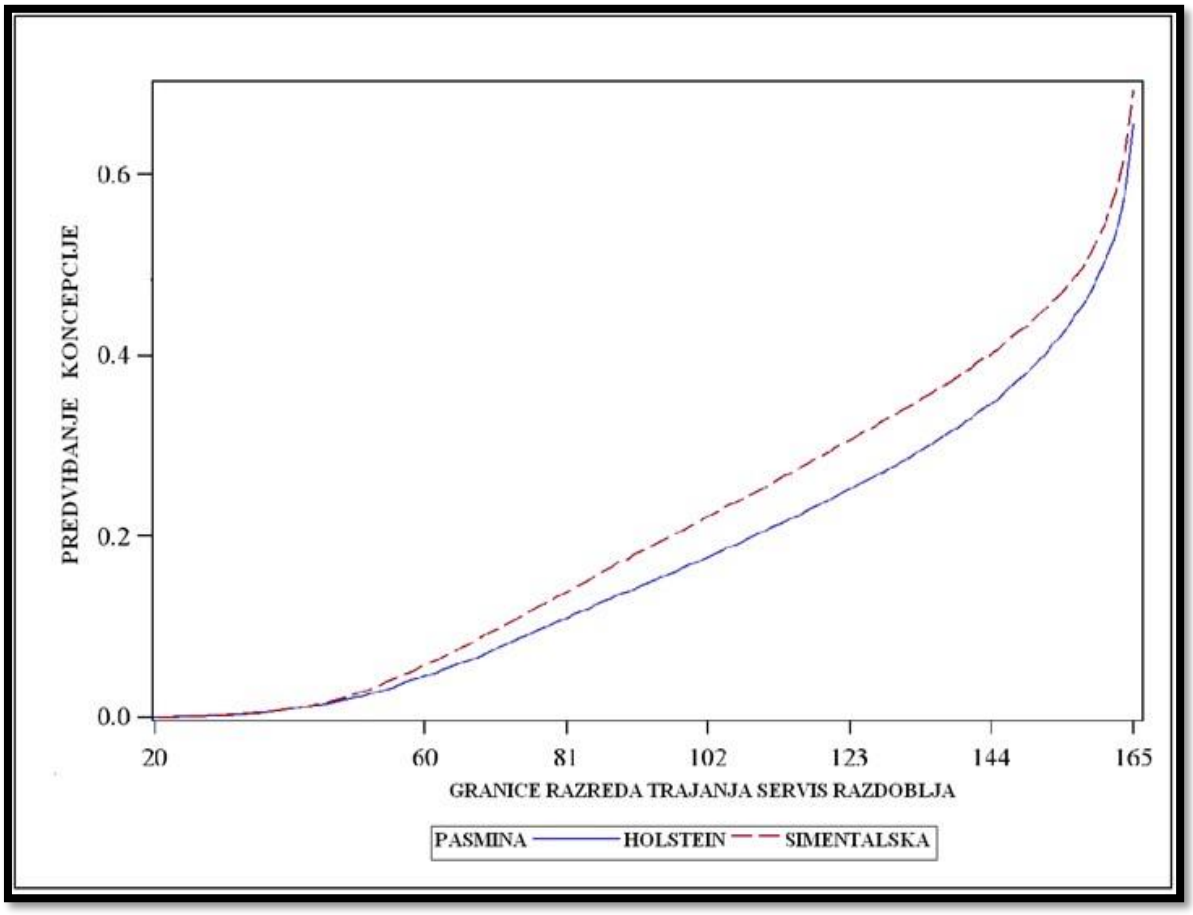

Grafikon 17: Kaplan Meirova krivulja preživljavanja trajanja servis razdoblja po pasminama

Kraće trajanje servis razdoblja kod simentalske pasmine u odnosu na holstein pasminu utvrđeno je u istraživanju Budimir i sur. (2011.), Kabalin i sur. (2013.) te je evidentirano i u Godišnjem izvješću HPA (HPA, 2014.) za razliku od proizvodnih pokazatelja (dnevna količina mlijeka, dnevni sadržaj i količina mliječne masti, dnevni sadržaj i količina bjelančevina) prikazanih u tablicama 28 i 29 koji su bolji kod holstein komparabilno sa simentalskom pasminom.

3.4.2. Analiza preživljavanja trajanja servis razdoblja po regijama

Ispitivanje statističke ekvivalentnosti između krivulja po regijama za obje je pasmine provedeno je Log-Rank, Wilcoxon i testom maksimalne vjerodostojnosti. Sva tri provedena testa pokazuju postojanje visoko značajne statističke razlike ($p < 0,001$) između kretanja krivulje trajanja servis razdoblja po regijama za holstein pasminu. Kod simentalske pasmine utvrđena je ista razina statističke značajnosti za Log-Rank i Wilcoxon test dok je za test maksimalne vjerodostojnosti utvrđena statistički značajna razlika između krivulja ($p < 0,03$).

Kaplan Meirova krivulja preživljavanja trajanja servis razdoblja po regijama za holstein pasminu prikazana je na grafikonu 18., dok je Kaplan Meirova krivulja preživljavanja trajanja servis razdoblja po regijama za simentalsku pasminu prikazana na grafikonu 19.

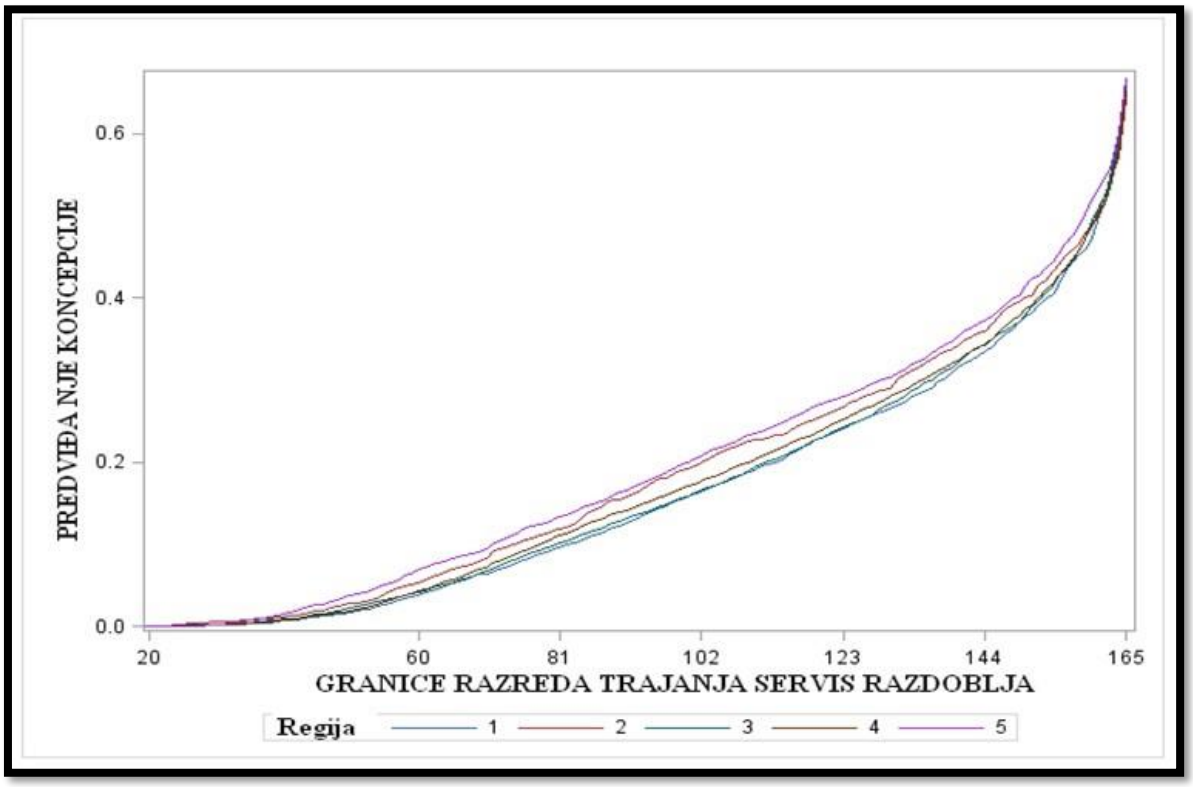

Grafikon 18: Kaplan Meirova krivulja preživljavanja trajanja servis razdoblja po regijama za holstein pasminu

Analizom kretanja krivulje preživljavanja za obje pasmine iskazana je najveća vjerojatnost koncepcije u svim razredima trajanja servis perioda u petoj regiji (Zadarska, Šibensko kninska, Splitsko dalmatinska, Istarska). Sagledavajući razlike između ostalih

razreda po regijama kod holstein pasmine uočeno je izdvajanje veće vjerojatnosti koncepcije u drugoj regiji (Sisačko moslavačka, karlovačka i ličko senjska županija) u odnosu na preostale dvije regije, izuzev veće vjerojatnosti koncepcije u šestom razredu u trećoj regiji (Bjelovarsko bilogorska i koprivničko križevačka županija).

Sve krivulje imaju monotono rastući tijek do kraja petog razreda, nakon čega slijedi oštriji rast krivulje. Najveće udaljavanje je prisutno između tijeka krivulja prve (Grad Zagreb, zagrebačka županija, međimurska, varaždinska i krapinsko zagorska) i pete regije (Zadarska, šibensko kninska, splitsko dalmatinska i istarska) u prvih pet razreda, uz približavanje svih krivulja u šestom razredu.

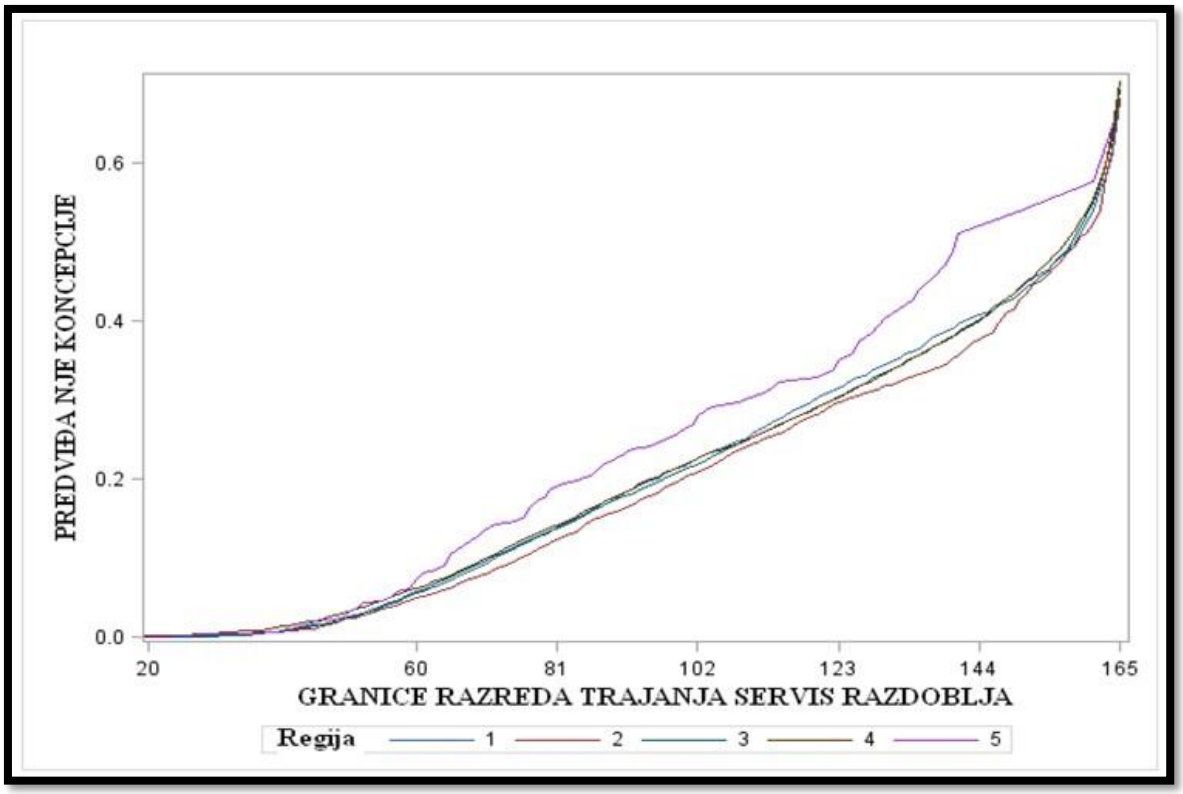

Grafikon 19: Kaplan Meirova krivulja preživljavanja trajanja servis razdoblja po regijama za simentalsku pasminu

Sagledavajući kretanje krivulja između ostalih razreda po regijama kod simentalske pasmine uočeno je približavanje tijeka krivulja prve, treće i četvrte regije (Grad Zagreb i Zagrebačka županija, Međimurska, Varaždinska, Krapinsko zagorska, Bjelovarsko bilogorska, Koprivničko križevačka, Zadarska, Šibensko kninska, Splitsko dalmatinska, Istarska) po svim razredima trajanja servis razdoblja što ukazuje na približne vjerojatnosti

koncepcije u tim regijama. Krivulje prve, treće i četvrte regije imaju monotono rastući tijek do kraja petog razreda, nakon čega slijedi oštriji rast krivulje. Krivulja prve regije (Grad Zagreb i Zagrebačka županija, Međimurska, Varaždinska, Krapinsko zagorska), ima oštriji rast na početku drugog razreda te na početku petog razreda trajanja servis razdoblja što ukazuje na povećanje vjerojatnosti koncepcije u tim razredima. Najveće udaljavanje je prisutno između tijeka krivulja druge (Sisačko moslavačka, Karlovačka, Ličko senjska) i pete regije (Zadarska, Šibensko kninska, Splitsko dalmatinska, Istarska) u prvih pet razreda, uz približavanje svih krivulja u šestom razredu.

Statistički značajan utjecaj regije na reprodukcijsku učinkovitost i dužinu trajanja servis razdoblja kod simentalske pasmine utvrdili su Pantelić i sur. (2008.), a kod holstein pasmine Washburn (2002.), Garcia-Peniche (2004.), Nagamine i Sasaki (2008.). Utjecaj regije na dužinu trajanja servis razdoblja očituje se kroz klimatske uvjete te cjelokupan sustav managementa mliječnih farmi u određenom području (struktura proizvodnje krmnih kultura i način konzerviranja, način izgradnje objekata i slično). Izdvajanje pete regije (Zadarska, šibensko kninska, splitsko dalmatinska i istarska) s najvećom vjerojatnosti koncepcije u svakom razredu posljedica je manjeg broja farmi s velikim brojem krava i primjerenog načina upravljanja cjelokupnom proizvodnjom mlijeka.

3.4.3. Analiza preživljavanja trajanja servis razdoblja po veličini stada

Ispitivanje statističke ekvivalentnosti između krivulja po razredima veličine stada za holstein pasminu provedeno je s Log-Rank, Wilcoxon i testom maksimalne vjerodostojnosti. Wilcoxon testom je utvrđeno postojanje statistički visoko značajne razlike ($p < 0,001$) između kretanja krivulje trajanja servis razdoblja po razredima veličine stada za holstein pasminu dok za ostala dva testa nisu utvrđene značajne razlike između krivulja ($p < 0,16$; $p < 0,26$). Kod simentalske pasmine utvrđene su statistički visoko značajne razlike ($p < 0,001$) između kretanja krivulje trajanja servis razdoblja po razredima veličine stada za sva tri testa.

Kaplan Meirova krivulja preživljavanja trajanja servis razdoblja po razredima veličine stada za holstein pasminu prikazana je na grafikonu 20., dok je Kaplan Meirova krivulja preživljavanja trajanja servis razdoblja po razredima veličine stada za simentalsku pasminu prikazana na grafikonu 21.

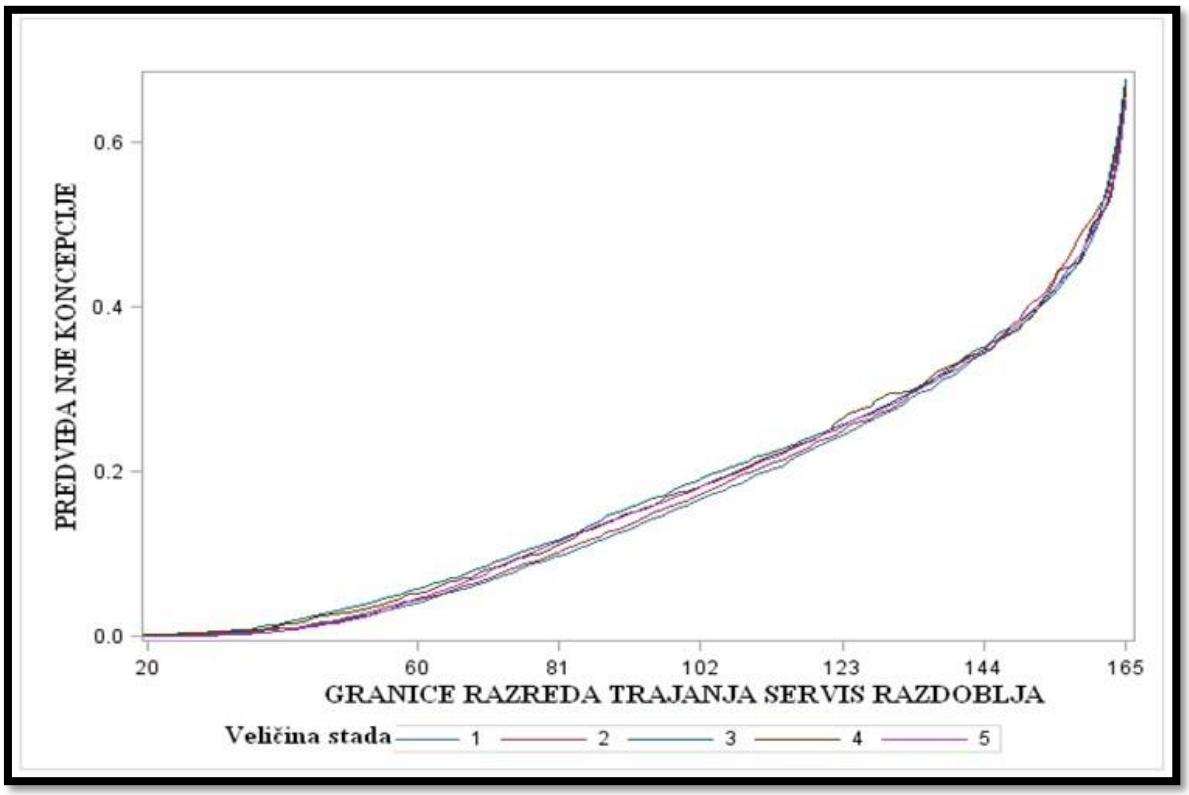

Grafikon 20: Kaplan Meirova krivulja preživljavanja trajanja servis razdoblja po razredima veličine stada za holstein pasminu

Analizom kretanja krivulje preživljavanja kod holstein pasmine krava iskazana je najveća vjerojatnost koncepcije za treći razred veličine stada (20 do 50 krava) u svim razredima trajanja servis razdoblja, izuzev četvrtog razreda trajanja servis razdoblja kada je najveća vjerojatnost koncepcije u četvrtom razredu veličine stada (50 do 100 krava u stadu). Najniža vjerojatnost koncepcije utvrđena je za prvi razred veličine stada (od 1 do 10 krava) u svim razredima trajanja servis razdoblja. Sve četiri krivulje imaju monotono rastući tijek do kraja petog razreda, nakon čega slijedi oštriji rast krivulje.

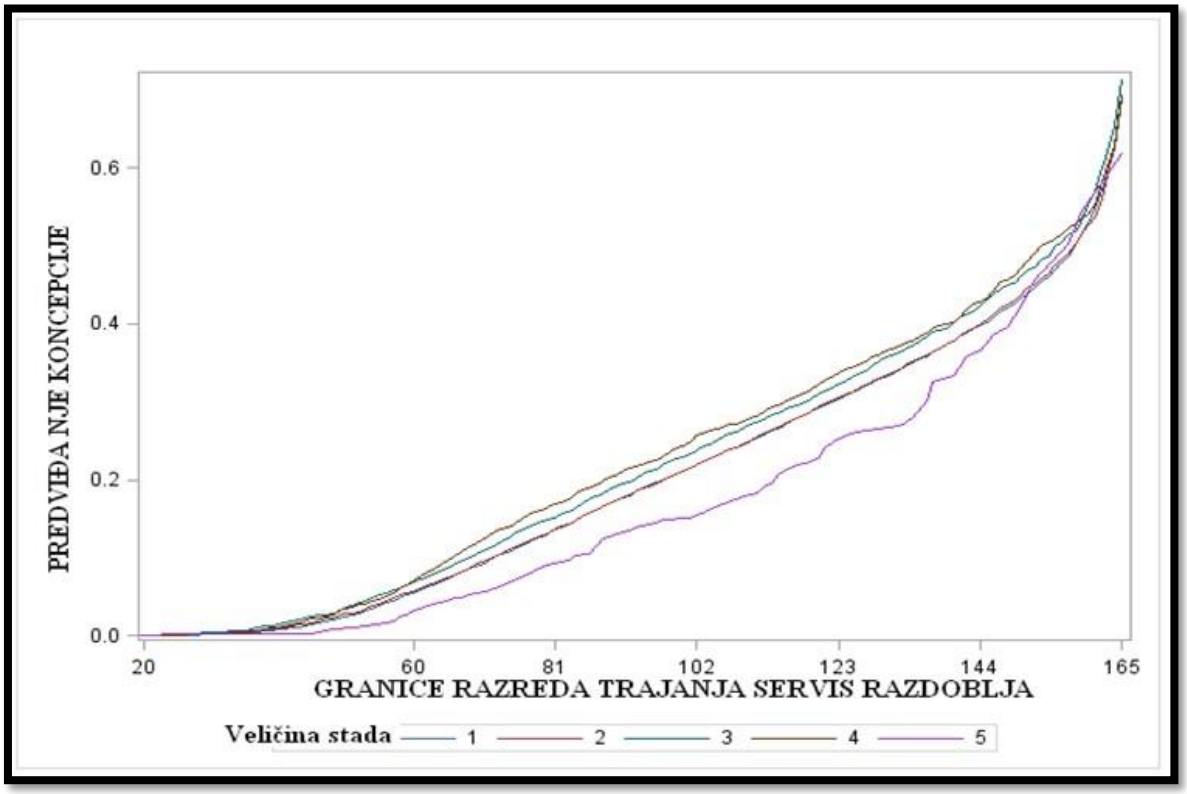

Grafikon 21: Kaplan Meirova krivulja preživljavanja trajanja servis razdoblja po razredima veličine stada za simentalsku pasminu

Analizom kretanja krivulje preživljavanja kod simentalske pasmine krava iskazana je najveća vjerojatnost koncepcije u prvom i šestom razredu trajanja servis razdoblja za prvi razred veličine stada (od 1 do 10 krava). U ostalim razredima trajanja servis razdoblja je najveća vjerojatnost koncepcije za četvrti razred veličine stada (50 do 100 krava u stadu).

Sagledavajući kretanje krivulja između ostalih razreda po regijama uočeno je udaljavanje krivulje petog razreda veličine stada (100 i više krava u stadu) od ostalih krivulja, osim u šestom razredu trajanja servis razdoblja. Krivulje prva četiri razreda veličine stada imaju monotono rastući tijek do kraja petog razreda, nakon čega slijedi oštriji rast krivulje. Krivulja petog razreda veličine stada pokazuje nejednolik rastući tijek uz oštriji rast krivulje pri kraju petog razreda trajanja servis razdoblja uz najmanju vjerojatnost koncepcije u prvih pet razreda trajanja servis razdoblja.

Pozitivan utjecaj stada s većim brojem krava na rezultate reprodukcijske učinkovitosti prikazan od Löf i sur. (2007.) usporediv je s rezultatima kretanja krivulje preživljavanja kod holstein pasmine u ovom istraživanju. Stada s većim brojem holstein krava u Republici Hrvatskoj imaju mogućnost primjene odgovarajućeg managementa posebice iz područja reprodukcije te obično počinju ranije s osjemenjivanjem nakon teljenja. Vrlo često na takvim farmama je prisutan redoviti veterinarski nadzor i provedba umjetnog osjemenjivanja. Slabiji rezultati koncepcije u manjim stadima holstein krava uglavnom su posljedica neadekvatnog smještaja (krave na vezu) i hranidbe.

Kod simentalske pasmine znatno su bolji rezultati reprodukcijske učinkovitosti kod stada s manjim brojem krava. Slične su rezultate utvrdili i Fahey i sur. (2000.). Tradicija uzgoja simentalske pasmine u Republici Hrvatskoj obilježena je držanjem manjeg broja krava u malim obiteljskim gospodarstvima. Manji broj krava omogućuje bolji pojedinačni nadzor krava što osobito dolazi do izražaja u pravovremenom otkrivanju estrusa i pravovremenom osjemenjivanju.

3.4.4. Analiza preživljavanja trajanja servis razdoblja po sezoni koncepcije

Ispitivanje statističke ekvivalentnosti između krivulja po sezonama koncepcije za holstein i simentalsku pasminu provedeno je s Log-Rank, Wilcoxon i testom maksimalne vjerodostojnosti. Sva tri provedena testa pokazuju postojanje statistički visoko značajne razlike ($p < 0,001$) između kretanja krivulje trajanja servis razdoblja po sezonama koncepcije za obje promatrane pasmine. Kaplan Meirova krivulja preživljavanja trajanja servis razdoblja po sezonama koncepcije za holstein pasminu prikazana je na grafikonu 22., dok je Kaplan Meirova krivulja preživljavanja trajanja servis razdoblja po sezonama koncepcije za simentalsku pasminu prikazana na grafikonu 23.

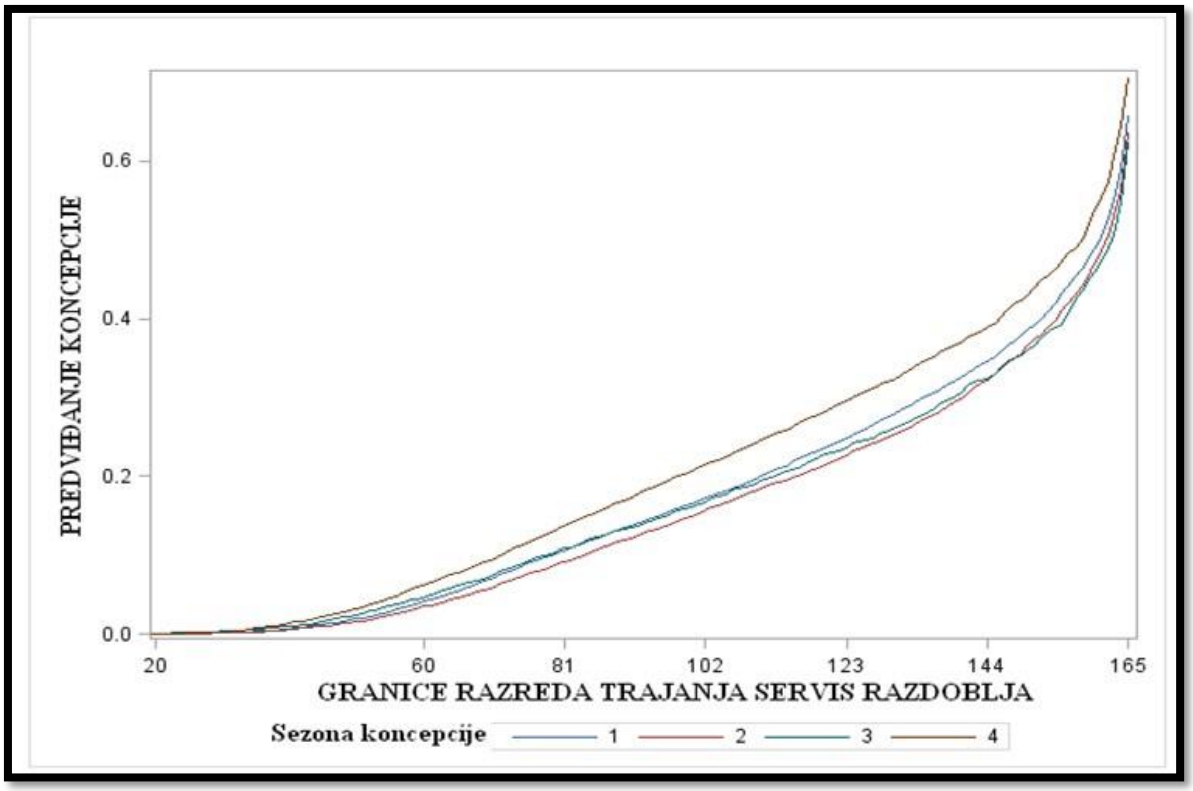

Grafikon 22: Kaplan Meirova krivulja preživljavanja trajanja servis razdoblja po sezonama koncepcije za holstein pasminu

Analizom kretanja krivulje preživljavanja za obje pasmine iskazana je najveća vjerojatnost koncepcije u svim razredima trajanja servis razdoblja u četvrtoj sezoni (od rujna do studenog). Sagledavajući razlike kod holstein pasmine između ostalih razreda po sezonama uočeno je izdvajanje veće vjerojatnosti koncepcije za prvu sezonu (od prosinca do veljače) od trećeg do šestog razreda u odnosu na preostale dvije sezone. Najniže

vjerojatnosti koncepcije utvrđene su u drugoj sezoni (od ožujka do svibnja) u svim razredima trajanja servis razdoblja (izuzev u šestom razredu). Sve četiri krivulje imaju monotono rastući tijek do kraja petog razreda, nakon čega slijedi oštriji rast krivulje. Najveće udaljavanje je prisutno između tijeka krivulja četvrte (od rujna do studenog) i druge sezone (od ožujka do svibnja) u prvih pet razreda, uz približavanje svih krivulja u šestom razredu trajanja servis razdoblja.

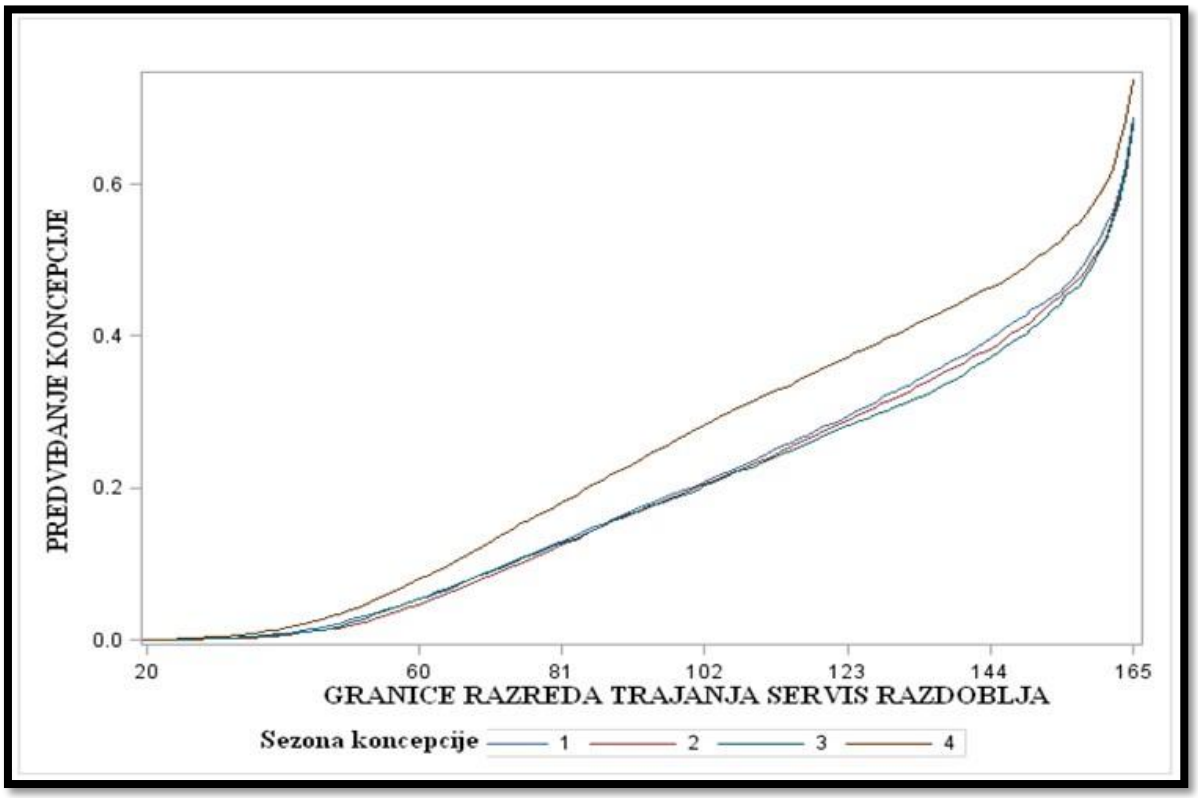

Grafikon 23: Kaplan Meirova krivulja preživljavanja trajanja servis razdoblja po sezonama koncepcije za simentalsku pasminu

Najniža vjerojatnost koncepcije kod simentalske pasmine u prvom i drugom razredu trajanja servis razdoblja je u drugoj sezoni (od ožujka do svibnja), dok je u ostalim razredima najniža vjerojatnost koncepcije u trećoj sezoni (od lipnja do kolovoza). Sve četiri krivulje imaju monotono rastući tijek do kraja petog razreda, nakon čega slijedi oštriji rast krivulje. Najveće udaljavanje je prisutno između tijeka krivulja četvrte (od rujna do studenog) i ostalih sezona od drugog do polovice šestog razreda trajanja servis razdoblja.

Premda su krave poliestrične životinje i spolni ciklusi se ponavljaju i imaju cikličku aktivnost tijekom cijele godine (Bülbül i Ataman, 2009.) još uvijek je prisutan utjecaj sezone na reprodukciju mliječnih krava (Badinga i sur., 1985.). Visoke temperature zraka u kombinaciji s visokom vlagom zraka dovode do toplinskog stresa koji je glavni čimbenik narušavanja rezultata reprodukcijske učinkovitosti (Lopez-Gautius, 2003.). Lošiji reprodukcijski rezultati kod krava tijekom razdoblja karakteriziranog toplinskim stresom uzrokovani su smanjenjem znakova izražajnosti estrusa i smanjenjem apetita i konzumacije hrane. Navedeno je osobito značajno kod krava koje se u vrućim ljetnim mjesecima nalaze u razdoblju tranzicije i negativne energetske ravnoteže (De Rensis i Scaramuzzi, 2003.). Uvjeti smještaja (slobodan ili vez), visina objekata te toplinska izolacija uz mogućnost kretanja po vanjskom prostoru doprinosi smanjenju utjecaja nepovoljnih klimatskih uvjeta.

Rezultati predmetnog istraživanja ukazuju na izraženiji negativan utjecaj ljetnog razdoblja kod simentalske pasmine koja se u Republici Hrvatskoj još uvijek na velikom broju gospodarstava drži u starije izgrađenim objektima s nedovoljnim količinama i mogućnosti izmjene zraka, uz držanje krava na vezu i bez mogućnosti slobodnog kretanja na vanjskom zraku. Jesensko razdoblje koje slijedi nakon prestanka nepovoljnih visokih temperatura rezultiralo je najboljim reprodukcijskim rezultatima kod obje pasmine.

3.4.5. Analiza preživljavanja trajanja servis razdoblja po sezoni teljenja

Ispitivanje statističke ekvivalentnosti između krivulja po sezonama teljenja za holstein i simentalsku pasminu provedeno je s Log-Rank, Wilcoxon i testom maksimalne vjerodostojnosti. Sva tri provedena testa pokazuju postojanje statistički visoko značajne razlike ($p < 0,001$) između kretanja krivulje trajanja servis razdoblja po sezonama teljenja za obje promatrane pasmine. Kaplan Meirova krivulja preživljavanja trajanja servis razdoblja po sezonama teljenja za holstein pasminu prikazana je na grafikonu 24., dok je Kaplan Meirova krivulja preživljavanja trajanja servis razdoblja po sezonama teljenja za simentalsku pasminu prikazana na grafikonu 25.

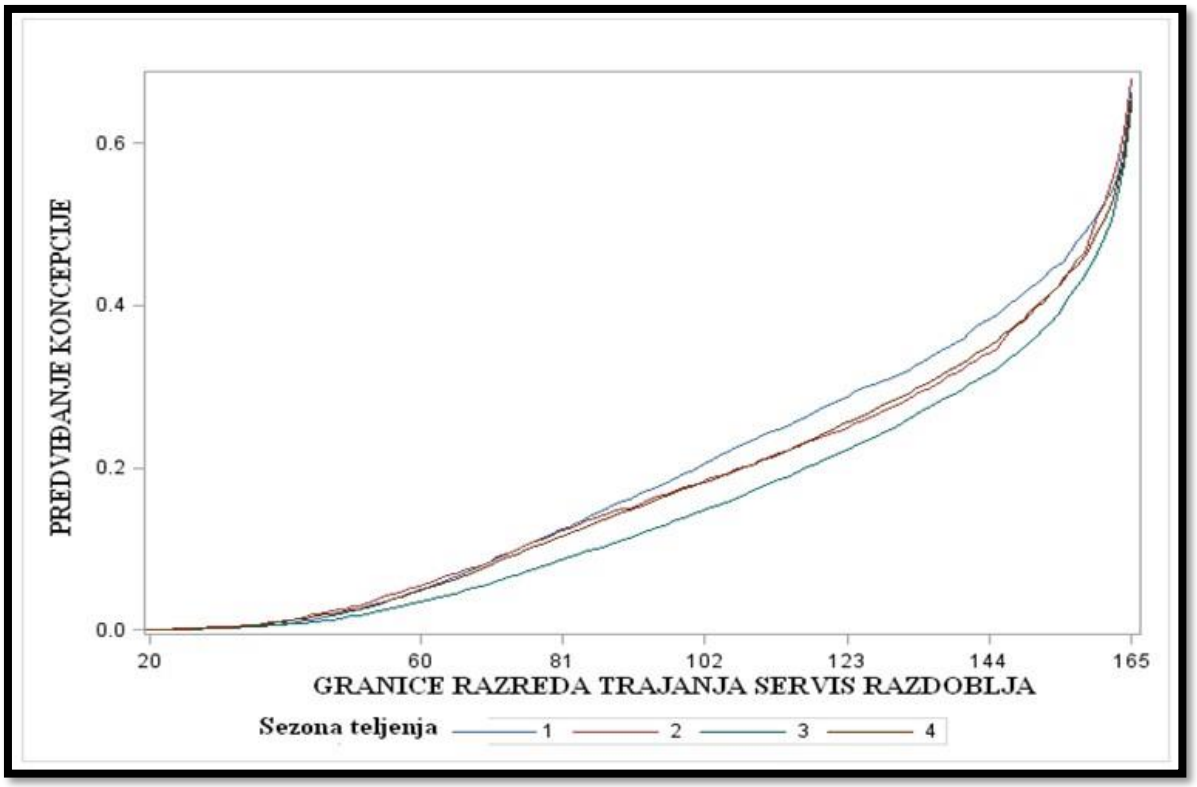

Grafikon 24: Kaplan Meirova krivulja preživljavanja trajanja servis razdoblja po sezonama teljenja za holstein pasminu

Analizom kretanja krivulje preživljavanja kod holstein pasmine iskazana je najveća vjerojatnost koncepcije u svim razredima trajanja servis razdoblja za krave koje su imale teljenje u prvoj sezoni (od prosinca do veljače), izuzev u prvom razredu. Sagledavajući razlike između ostalih razreda po sezonama uočeno je kontinuirano približavanje vjerojatnosti koncepcije za sve razrede između krivulja druge i četvrte sezone teljenja (od

ožujka do svibnja i od rujna do studenog) te najveće odstupanje između krivulja vjerojatnosti koncepcije za prvu i treću sezonu teljenja (od prosinca do veljače i od lipnja do kolovoza). Najniže vjerojatnosti koncepcije utvrđene su za krave koje su imale teljenje u trećoj sezoni (od lipnja do kolovoza) u svim razredima trajanja servis razdoblja Sve četiri krivulje imaju monotono rastući tijek do kraja petog razreda, nakon čega slijedi oštriji rast krivulje, uz približavanje svih krivulja u šestom razredu trajanja servis razdoblja.

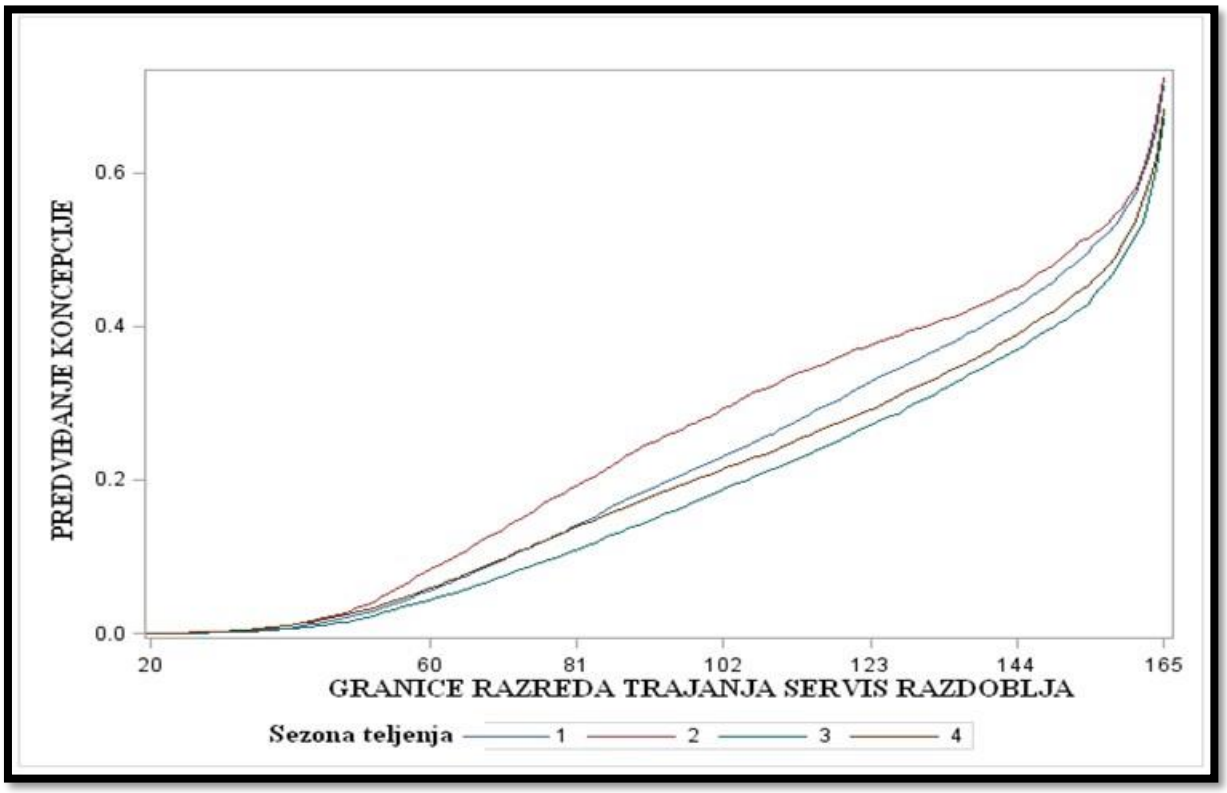

Grafikon 25: Kaplan Meirova krivulja preživljavanja trajanja servis razdoblja po sezonama teljenja za simentalsku pasminu

Analizom kretanja krivulje preživljavanja kod simentalske pasmine iskazana je najveća vjerojatnost koncepcije u svim razredima trajanja servis razdoblja za krave koje su imale teljenje u drugoj sezoni (od ožujka do svibnja). Sagledavajući razdvajanje kretanja krivulje preživljavanja druge sezone u odnosu na ostale vidljivo je naglo uzdizanje tijeka krivulje pri kraju prvog razreda te približavanje ostalim krivuljama početkom šestog razreda. Tijek krivulje preživljavanja druge sezone početkom trećeg razreda ukazuje na usporeni rast vjerojatnosti koncepcije u odnosu na ostale sezone. Najniže vjerojatnosti koncepcije utvrđene su za krave koje su imale teljenje u trećoj sezoni (od lipnja do

kolovoza) u svim razredima trajanja servis razdoblja. Krivulje prve i treće sezone imaju monotono rastući tijek do kraja petog razreda, nakon čega slijedi oštriji rast krivulje, uz približavanje svih krivulja u šestom razredu trajanja servis razdoblja.

Sezona teljenja određena je vremenskim razdobljem u kojem se dogodila koncepcija, no bez obzira u kojoj sezoni se dogodilo teljenje, upravljanje proizvodnjom mlijeka nalaže postizanje slijedeće koncepcije u razdoblju koje je optimalno s ekonomske i fiziološke strane. Prema rezultatima niza autora (Farin i sur., 1994., Ray i sur., 1992., Silva i sur., 1992.) krave koje su se otelile u toplim ljetnim mjesecima imaju zatomljenu reprodukcijsku izražajnost, dok krave koje su se otelile u zimskom i proljetnom razdoblju imaju veću vjerojatnost koncepcije. U predmetnom istraživanju primjetan je negativan utjecaj ljetnog razdoblja teljenja na vjerojatnost buduće koncepcije kod obje pasmine te pozitivan utjecaj zimskog i proljetnog razdoblja teljenja.

4. ZAKLJUČCI

Temeljem provedene analize značajnosti utjecaja na trajanje razdoblja od teljenja do koncepcije (servis razdoblje), povezanosti između trajanja servis razdoblja i svojstava rezultata provedbe kontrole mliječnosti te razvoja sustava predviđanja trajanja servis razdoblja temeljem rezultata kontrole mliječnosti na početku laktacije (prve dvije kontrole) u populaciji holstein i simentalske pasmine krava moguće je zaključiti sljedeće:

- ✓ Utvrđene srednje vrijednosti dnevne količine i sadržaja mliječne masti, dnevne količine i sadržaja bjelančevina, omjera mast : bjelančevine te broja somatskih stanica bile su veće pri kontrolnom danu 1. negoli pri kontrolnom danu 2. kod obje analizirane pasmine (holstein, simentalska). Utvrđene srednje vrijednosti dnevnog sadržaja ureje i laktoze bile su veće kontrolnom danu 2. negoli pri kontrolnom danu 1. kod obje analizirane pasmine. Utvrđene srednje vrijednosti dnevne količine mlijeka kod holstein pasmine bile su veće kontrolnom danu 2. negoli pri kontrolnom danu 1. dok su kod simentalske pasmine utvrđene obrnute vrijednosti.
- ✓ Kod obje pasmine utvrđene su statistički vrlo značajne ili značajne korelacije između trajanja servis razdoblje i dnevnog sadržaja bjelančevina, broja somatskih stanica te omjer mast : bjelančevine pri oba kontrolna dana. Vrijednosti koeficijenata korelacija kretale su se unutar raspona ±0,00 do ±0,20 što upućuje na zanemarivu povezanost između trajanja servis razdoblja i svojstava rezultata provedbe kontrole mliječnosti.
- ✓ Obzirom na distribuciju teljenja po sezonama kod obje je pasmine evidentan najveći udio teljenja u jesenskom razdoblju odnosno od rujna do studenog te najmanji udio teljenja u proljetnom razdoblju odnosno od ožujka do svibnja.
- ✓ Obzirom na distribuciju udjela koncepcija po sezonama kod obje je pasmine evidentan najmanji udio koncepcija u ljetnom razdoblju odnosno od lipnja do kolovoza te najveći u zimskom razdoblju odnosno od prosinca do veljače.
- ✓ Veća vjerojatnost koncepcije po svim razredima trajanja servis razdoblja u simentalske u odnosu na holstein pasminu utvrđena je analizom kretanja krivulje preživljavanja trajanja servis razdoblja.
- ✓ Analizom kretanja krivulje preživljavanja trajanja servis razdoblja po regijama za obje pasmine utvrđena je najveća vjerojatnost koncepcije u svim razredima u petoj regiji (Zadarska, Šibensko kninska, Splitsko dalmatinska, Istarska).
- ✓

- ✓ Analizom kretanja krivulje preživljavanja trajanja servis razdoblja po regijama kod holstein pasmine uočeno je izdvajanje veće vjerojatnosti koncepcije u drugoj regiji (Sisačko moslavačka, karlovačka i ličko senjska županija) u odnosu na preostale dvije regije, izuzev veće vjerojatnosti koncepcije u šestom razredu u trećoj regiji (Bjelovarsko bilogorska i koprivničko križevačka županija).
- ✓ Analizom kretanja krivulje preživljavanja trajanja servis razdoblja po regijama kod simentalske pasmine uočeno je približavanje tijeka krivulja prve, treće i četvrte regije (Grad Zagreb i Zagrebačka županija, Međimurska, Varaždinska, Krapinsko zagorska, Bjelovarsko bilogorska, Koprivničko križevačka, Zadarska, Šibensko kninska, Splitsko dalmatinska, Istarska) po svim razredima trajanja servis razdoblja što ukazuje na približne vjerojatnosti koncepcije u tim regijama.
- ✓ Analizom kretanja krivulje preživljavanja kod holstein pasmine iskazana je najveća vjerojatnost koncepcije za treći razred veličine stada (20 do 50 krava) u svim razredima trajanja servis razdoblja, izuzev četvrtog razreda trajanja servis razdoblja kada je najveća vjerojatnost koncepcije utvrđena u četvrtom razredu veličine stada (50 do 100 krava u stadu).
- ✓ Analizom kretanja krivulje preživljavanja za obje pasmine iskazana je najveća vjerojatnost koncepcije u svim razredima trajanja servis razdoblja u četvrtoj sezoni (od rujna do studenog).
- ✓ Analizom kretanja krivulje preživljavanja kod holstein pasmine iskazana je najveća vjerojatnost koncepcije u svim razredima trajanja servis razdoblja za krave koje su imale teljenje u prvoj sezoni (od prosinca do veljače), izuzev u prvom razredu.
- ✓ Analizom kretanja krivulje preživljavanja kod simentalske pasmine krava iskazana je najveća vjerojatnost koncepcije u prvom i šestom razredu trajanja servis razdoblja za prvi razred veličine stada (od 1 do 10 krava). U ostalim razredima trajanja servis razdoblja je najveća vjerojatnost koncepcije za četvrti razred veličine stada (50 do 100 krava u stadu).
- ✓ Analizom kretanja krivulje preživljavanja kod simentalske pasmine iskazana je najveća vjerojatnost koncepcije u svim razredima trajanja servis razdoblja za krave koje su imale teljenje u drugoj sezoni (od ožujka do svibnja).

- ✓ Provedbom logističke regresije izrađena su dva statistička modela.
  - ✓ Model 1. koji uključuje varijable rezultata provedbe kontrole mliječnosti zasebno za svaku pasminu i svaki kontrolni dan.

  Kod holstein pasmine u model su uključene varijable dnevni sadržaj bjelančevina i broj somatskih stanica pri oba kontrolna dana te dnevni sadržaja laktoze pri kontrolnom danu 1.

  Kod simentalske pasmine pri oba kontrolna dana u model su uključene varijable dnevni sadržaj bjelančevina te omjer masti i bjelančevina. Varijable dnevni sadržaj ureje i dnevni sadržaj laktoze uključene su pri procjeni temeljem kontrolnog dana 1., a broj somatskih stanica pri procjeni temeljem kontrolnog dana 2.

  - ✓ Model 2. koji pored varijabli iz prvog modela uključuje i utjecaje regije, sezone i veličine stada, sezone koncepcije i sezone teljenja.

  Kod holstein pasmine modelom su obuhvaćene varijable dnevni sadržaj bjelančevina, sezona koncepcije, sezona teljenja i regija pri oba kontrolna dana te veličina stada pri kontrolnom danu 1.

  Kod simentalske pasmine pri oba kontrolna dana u model su uključene varijable dnevni sadržaj bjelančevina, sezona teljenja, sezona koncepcije, veličina stada te omjer masti i bjelančevina. Varijable dnevni sadržaj laktoze i dnevni sadržaj ureje uključene su pri procjeni temeljem kontrolnog dana 1., dok su varijable odnos bjelančevina i ureje, broj somatskih stanica te dnevna količina mlijeka uključene pri procjeni temeljem kontrolnog dana 2.

- ✓ Ispitivanje snage modela za predviđanje događaja prikazano je pomoću indeksa konkordancije koji predstavlja sukladnost slaganja registriranih i predviđenih podataka unutar svakog modela. Utvrđeno je povećanje vrijednosti indeksa konkordancije za svaki model s većim rednim brojem u odnosu na početni model kao i povećanje vrijednosti indeksa konkordancije 2. kontrolnog dana u odnosu na 1. kontrolni dan.

5. LITERATURA

1. Abdallah, J. M., McDaniel, B. T. (2000): Genetic parameters and trends of milk, fat, days open, and body weight after calving in North Carolina experimental herds. Journal of Dairy Science, 83(6) : 1364-1370.
2. Akalović, I., Gantner, V.,Mijić, P., Bogut, I. (2011): Analiza provođenja kontrole mloječnosti krava u Republici Hrvatskoj. Stočarstvo, 65:2011(1) 67-74.
3. Akers, R.M. (2002): Lactation and mammaary gland. Blackwell
4. Aleandri, R., Tondo, A. (2003.): Milk recording methods: Effects on Phenotypic Variation of Lactation Record. Stočarstvo, 57: 273 – 289.
5. Allison, P.D., (1995): Survival Analysis Using the SAS System: A Practical Guide, SAS Institute, Cary
6. Allen, M. S., Bradford, B. J., Oba. M. (2009): The hepatic oxidation theory of the control of feed intake and its application to ruminants. Journal of Animal Science, 87:3317-3334.
7. Antunac, N., Lukač-Havranek, J., Samardžija, D. (1997): Somatske stanice i njihov utjecaj na kakvoć u i preradu mlijeka. Mljekarstvo 47, (3), 183-193.
8. Babnik, D., Verbič, J., Podgoršek, P., Jeretina, J., Perpar, T., Logar, B., Sadar, M , Ivanovič, B., (2004.) : Priročnik za vodenje prehrane krav molznic ob pomoči rezultatov mlečne kontrole, Kmetijski inštitut Slovenije, Ljubljana.
9. Badinga, L,. Collier, R.J., Thatcher, W.W., Wilcox, C.J. (1985): Effects of climatic and management factors on conception rate of dairy cattle in subtropical environment. Journal of Dairy Science, 68: 78-85.
10. Bačić, G. (2009): Dijagnostika i liječenje mastitisa u goveda, Veterinarski fakultet Sveučilišta u Zagrebu, Zagreb.
11. Barber, M.C., Clegg, R.A.,M.T., Richard G., Vernon,R.G. (1997): Lipid metabolism in the lactating mammary gland. Biochemica et et Biophysica Acta, 1347 : 101–126
12. Barker, A.R., Schrick, F.N., Lewis, M.J., Dowlen, H.H., Oliver, S.P., (1998): Influence of clinical mastitis on reproductive performance of Jersey cows. Journal of Dairy Science, 81: 1285- 1290.
13. Bauman, D. E., Currie, W. B. (1980): Partitioning of nutrients during pregnancy and lactation—A review of mechanisms involving homeostasis and homeorhesis. Journal of Dairy Science 63:1514–1529.
14. Bauman, D.E., Griinari, J.M. (2003): Nutritional regulation of milk fat synthesis. Ann

Rev. Nutr., 23, 203-227.

15. Bauman, D.E., Griinari, J.M. (2003): Nutritional regulation of milk fat synthesis. Ann. Rev. Nutr., 23, 203-227.
16. Bauman, D.E., McGuire, M.A., i Harvatine K.J (2011): Milk Fat , Encyclopedia of Dairy Science,Volume 3, str. 352-258.
17. Bello, N.M., Stevenson, J.S., Tempelman, R.J., (2012): Invited review: Milk production and reproductive performance: Modern interdisciplinary insights into an enduring axiom. Journal of Dairy Science, 95:1–15.
18. Budimir, D., Plavšić, M., Popović-Vranješ, A.(2011): Production and reproduction characteristics of simmental and holstein friesian cows in Semberija area. Biotechnology in Animal Husbandry 27 (3), p 893-899.
19. Bujko, J., Candrak, J., Strapak,P., Žitny, J., Hrnčar, C. (2013): Animal Science and Biotechnologies, 2013, 46 (2).
20. Bendelja, D., Antunac, N., Mikulaec, N., Vnučec, I., Mašek, T., Mikulec, Ž., Havranek, J.(2009): Koncentracija ureje u ovčjem mlijeku. Mljekarstvo, 59(1), 3-10
21. Bendelja, D., Prpić, Z., Mikulec, N., Ivkić, Z., Havranek, J., Antunac, N. (2011): Milk urea concentration in Holstein and Simmental cows
22. Block, E. (2010): Transition cow research - What makes sense today?, High Plants Dairy Conference, Amarillo, Texas. Proceedings, 75-98.
23. Boland, M. P., Lonergan P. (2003): Effects of Nutrition on Fertility in Dairy Cows. Advances in Dairy Technology Volume 15, page 19
24. Broderick, G.A., Clayton, M.K. (1997): A statistical evaluation of animal and nutritional fastors influencing concentrations of milk urea nitrogen. Journal of Dairy Science, 80, 2694-2971.
25. Buckley, F., OSullivan, K., Mee, F., Evans, R.D., Dillon, P., (2003): Relationships Among Milk Yield, Body Condition, Cow Weight, and Reproduction in Spring-Calved Holstein-Friesians. Journal of Dairy Science, 86, 2308-2319
26. Bülbül,B., Ataman, M.B. (2009) The effect of some seasonal conditions on oestrus occurrence in cows. Archiv Tierzucht 52 (2009) 5, 459-465.
27. Burhans, W. S., Bell, A. W., Nadeau, R., Knapp. J. R. (2003): Factors associated with transition cow ketosis incidence in selected New England herds. Journal of Dairy Science, 86 (Suppl. 1):247. (Abstr)
28. Burton, J.L., Madsen, S.A., Chang, L.C., Weber, P.S., Buckham, K.R., van Dorp,

R., Hickey, M.C., Earley, B. (2005): Gene expression signatures in neutrophils exposed to glucocorticoids: A new paradigm to help explain "neutrophil dysfunction" in parturient dairy cows. Vet. Immunol. Immunopathol. 2005; 105: 197–219.

29. Butler, W.R., Calaman, J.J., Beam, S.W. (1996): Plasma and milk urea nitrogen in relation to pregnancy rate in lactating dairy cattle. Journal of Animal Science, 74, 858–865.
30. Butler, W.R. (1998): Review: Effect of protein nutrition on ovarian and uterine physiology in dairy cattle. Journal of Dairy Science, 81:2533–2539.
31. Butler, W.R. (2003): Energy balance relationships with follicular development, ovulation and fertility in postpartum dairy cows. Livestock Production Science, 83:211–218.
32. Butler, W.R., Marr, A.L., Pelton, S.H., Radcliff, P.R., Lucy, M.C., Butler, W.R. (2006): Energy balance, metabolic status, and the first postaprtum ovarian follicle wave in cows administerd propylene glycol. Journal of Dairy Science, 89:2938-2951
33. Buttchereit, N., Stamer, E., Junge, W., Thaller, G. (2010): Evaluation of five lactation curve models fitted for fat**:**protein ratio of milk and daily energy balance. Journal of Dairy Science. 93 :1702–171212.
34. Bylund, G. (1995): Dairy processing handbook. Tetra Pak Processing Systems. Sweeden
35. Caccamo M., Veerkamp R. F., de Jong G., Pool M. H., Petriglieri R., and Licitra G. (2008): Variance components for test-day milk, fat, and protein yield, and somatic cell score for analyzing management information. Journal of Dairy Science. 91:3268-3276.
36. Caput, P. (1996): Govedarstvo. Clebris. Zagreb
37. Caput, P., Ivanković, A., Konjačić, M. (2005): Koncept uzgojnih programa u govedarstvu Hrvatske. Stočarstvo 59:2005 (6) 465-476
38. Cerbulis, J., Farrell, H. M. J. (1975) Composition of milks of dairy cattle. Protein, lactose and fat contents and distribution of protein fraction. Journal of Dairy Science, 58, 817-827.
39. Christie, M. F., Allcock, J., Royal, M. D.(2007) : Reproductive challenges facings today's dairy industry. An International Conference Fertility in Dairy Cows. 30-31

August. Univ. Of Liverpool.

40. Ciszuk, A.U., Gebregziaber, T. (1994): Milk urea as an estimate of urine nitrogen of dairy cows and goats. Acta Agricultural Scandinavica, 44:87-95
41. Coffey, M.P., Simm,G., Oldham,J.D., Hill,W.G., Brotherstone,S.(2004): Genotype and diet effects on energy balance in the first three lactations of dairy cows. Journal of dairy sscience, 87 (12), 4318-4326.
42. Collard, B.L., Boettcher, P.J., Dekkers, J.C.M., Petitclerc, D., Schaeffer, L.R. (2000): Relationships between energy balance and health traits of dairy cattle in early lactation. Journal of Dairy Science, 83: 2683–2690
43. Crettenand J. (1999): Icar: A worldwide organization for standardization of animal recording and evaluation. Icar Tehnical series No.2: 5-16.
44. Cutullic, E., Delaby, L., Causeur, D., Michel, G., Disenhaus, C. (2009): Hierarchy of factors affecting behavioural signs used for oestrus detection of Holstein and Normande dairy cows in a seasonal calving system. Animal Reproduction Science, 113(1-4), 22-37.
45. Čejna, V., Chladek, G. (2005): The importance of monitoring changes in milk fat to milk protein ratio in holstein cows during lactation. Journal of Central European Agriculture, Vol. 6, No. 4, 539-546.
46. DeLorenzo,M.A., Wiggans,G,G.R.(1986): Factors for Estimating DailyMilk Yiekd, Fat and Protein from a Single Milking for Herds Milked Twice a Day. Journal of Dairy Science, 69:2386-2394.
47. de Vries, M.J., Veerkamp, R.F. (2000): Energy balance of dairy cattle in relation to milk production variables and fertility. Journal of Dairy Science, 83(1):62-9.
48. Deneš, S. (1999): Razvoj govedarstva – proizvodnje i otkupa mlijeka u granicama današnje Republike Hrvatske od 1857. i od 1921. Godine. Mljekarstvo, 47 (4) 306-330, 1997.
49. DePeters, E.J., Ferguson, J.D. (1992): Non protein nitrogen and protein distribution in the milk of cows. Journal of Dairy Science. 75:3192-3209
50. DeRensis, F., Scaramuzzi R.F. (2003): Different factors contribute to this situation; the most important are a consequence of increased temperature and humidity that result in a decreased expression of overt estrus and a reduction in appetite and dry matter intake. Theriogenology 60, 1139–1151.
51. Djedović , R., Bogdanović, V., Trifunović,G., Petrović, M. D., Petrović, M.,

Stanojević, D. (2012) : The effect of the level of milk yield on the reproduction traits in black and white cows. Biotechnology in Animal Husbandry 28 (3), p 487-496 , 2012.

52. Dodenhoff, J., Sprengel, Duda, J., Dempfle, L. (1999): Zucht auf Eutergesundheit mit Hilfe des LactoCorders. Züchtungskunde 71 (6) 459-472.
53. Dodenhoff, J., Emmerling, R. (2008): Genetic correlations between somatic cell score and milkability int he first three lactations in Fleckvieh. Interbull Buletin, 38, dairy cattle. Canadian Veterinary Journal., 38: 713 – 718.
54. Drackley, J.K. Nutrition and Management During the Transition Period in Dairy Cows *http://ansci.ilinois.edu/directory* (10.12.2011)
55. Državni zavod za statistiku (DSZ) *http://www.dzs.hr (16.10.2014) Tablica 1 Broj goveda*
56. Đorđević, J. (1987): Mleko. Naučna knjiga. Beograd
57. Eicher, R. (2004) Evaluation of the metabolic and nutritional situation in dairy herds : Diagnistic use of milk components. World Buiatrics Congress (23rd), Québec, Canada.
58. Everett, R. W., Carter, H. W. (1968): Accuracy of the test interval method of calculating Dairy Herd Improvement Association records. Journal of Dairy Science, 51: 1936.
59. Eorostat Statistic Database *http://epp.eurostat.ec.europa.eu/portal/page/portal/statistics/search_database* (15.10.2014)
60. Fahey, J., O'Sullivan, K., Crilly, J., Mee. J. F. (2002):.The effect of feeding and management practices on calving rate in dairy herds. Animal Reproduction Science, 74:133–150.
61. Farin, P. W., Slenninq, B. D., Correa, M. T.,. Britt, J. H. (1994) : Effects of Calving Season and Milk Yield on Pregnancy Risk and Income in North Carolina Holstein Cows. Journal of Dairy Science, 77: 1848-1855
62. Ferguson, J.D., Galligan, D.T., Blanchard, T., Reeves, M. (1993): Serum urea nitrogen and conception rate: The usefulness of test information. Journal of Dairy Science, 76, 3742–3746.
63. Ferguson, J.D. (1999): Milk Urea Nitrogen, June 29, 1999, pp. 1–6. http://cahpwww.nbc.upenn.edu/mun/mun info.html. (15.11.2013)

64. Francisco, C.C., Spicer, L.J., Payton, M.E., (2003). Predicting Cholesterol, Progesterone, and Days to Ovulation Using Postpartum Metabolic and Endocrine Measures. Journal of Dairy Science, 86, 2852-2863

65. French, P.D., Nebel, R. L. (2003): The simulated economic cost of extended calving intervals in dairy herds and comparison of reproductive management programs. Journal of Dairy Science 86, (Suppl. 1):54 (abstract).

66. Gagne, P., Dayton,C.M.(2002), Best Regression Model Using Information Criteria, Journal of Modern Applied Statistical Methods, Journal of Modern Applied Statistical Methods. 2002, Vol. 1, No 2, 479-488.

67. Gantner, V.,Kuterovac, K., Jovanovac, S., Solić, D., Dakić, A. (2006) : Vrednovanje hranidbenog statusa mliječnih krava na osnovu sadržaja bjelančevina i ureje u mlijeku. 41. hrvatski i 1. Međunarodni simpozij agronoma ,Opatija , Hrvatska str 577-578

68. Gantner, V. (2007): Točnost procjene dnevne količine i sastava mlijeka krava po alternativnoj shemi kontrole mliječnosti. Doktorski rad,Poljoprivredni fakultet. Osijek.

69. Gantner**, V.,** Jovanovac, S., Raguž, N., Solić D., Kompan D. (2009): Utjecaj sheme AT kontrole mliječnosti na točnost procjene laktacijske količine mlijeka i sastava mlijeka. Mljekarstvo, 59, (1) : 42-48.

70. Gantner, V., Potočnik, K., Kuterovac, K., Gantner, R., Antunović, B. (2010): Metods for early prediction of flow in Holstein heifers. Mljekarstvo, 60 (4), 260-265

71. Garcia-Bojalil, C.M., Staples, C.R., Risco, C.A., Savio, J.D., Thatcher, W.W. (1998): Protein degradability and calcium salts of long-chain fatty acids in the diets of lactating dairy cows: reproductive responses. Journal of Dairy Science, 81, 1385.

72. Garcia-Peniche, T.B. (2004): Comparisons of Holstein, Brown Swiss, and Jersey cows for age at first calving, first calving interval, and true herd-life up to five years in seven regions of the United States. PhD Dissertation Virginia Polytechnic Institute and State University

73. Gelebiewski, M., Brzozowski, P., Gelebiewski, L (2011): Analysis of lactation curves, milk constituents, somatic cell count and urea in milk of cows by the mathematical model of Wood. Acta Vet Brno 80, 73-80.

74. Godden, S.M., Kelton, D.F., Lissemore, K.D., Walton, J.S., Leslie, K.E., Lumsden, J.H. (2001b): Milk urea testing as a tool to monitor reproductive

performance in Ontario dairy herds. Journal of Dairy Science, 84, 1397–1406.

75. Godden, S. M., Stewart, S. C., Cady, R., Eicker, S. W., Fetrow, J. F., Rapnicki, P., Weiland, W., Spencer. H. (2003): The relationship between herd rBST-supplementation and other factors and risk for removal for cows in Minnesota Holstein dairy herds. Pages 55-64 in Proc. Four-State Applied Dairy Nutr. & Mgmt. Conf. MWPS-4SD16. La Crosse,WI.
76. Gressley, T. F. (2008): Managing the transition cow: recent research and recommendations. Delaware Dairy Newsletter. Spring 2008: pages 1-7.
77. Grohn, Y.T., Rajala-Schultz, P.J.(2000): Epidemiology of reproductive performance in dairy cows. Animal Reproduction Science 60–61 (2000) 605–614
78. Grozdić, G. (2011): Primjenjenja logistička regresija. Master rad. Prirodno-matematički fakutet. Novi Sad.
79. Grubić, G., Đorđević, N., Stojanović,B. (2007) Zbornik naučnih radova, Vol. 13 br. 3-421- 32
80. Grummer, R.R. (1995): Impact of changes in organic nutrient metabolism on feeding the transition dairy cow. Journal of Dairy Science, 1995, 73:2820-2833
81. Grummer, R. R., and D. G. Mashek. 2004. Dry matter intake and energy balance in the transition period. Veterinary Cliniccs of North America:. Food Anim. 20:447-470.
82. Grummer, R.R.,Wiltbank, M.C., Fricke,P.M., Watters,R.D.,Silva-del-rio,N.(2010): Management od dry and transition cows to improve energy balance and reproduction. Journal of reproduction and development, 56, S22- S28
83. Guo, K., Russek, E., Cohen, M., Varner, A., Kohn, R.A. (2004): Effects of milk urea nitrogen and other factors on probability of conception of dairy cows. Journal of Dairy Science, 87,1878-1885
84. Haile-Mariam, M., Bowman, P. J., Goddard, M. E. (2003): Genetic and environmental rela tionship among calving interval, survival, persistency of milk yield and somatic cell count in dairy cattle. Livestock Production Science, 80(3), 189 - 200.
85. Hanuš, O., Vyletělová, M., Genčurová, V., Bjelka M., Kopecký, J., Jedelská, R. (2004b): The importance of the raw milk laboratory testing for the dairy farmers. Mljekarstvo, 35, 31–38.
86. Harmon, R.J. (1994): Physiology of mastitis and factors affecting somatic cell

counts. Journal of Dairy Science 77, 2103-2112.

87. Havranek, J., Rupić,V.(2003): Mlijeko od farme do mljekare . Hrvatska mljekarska udruga. Zagreb
88. Hayirli, A., Grummer, R. R., Nordheim, E. V., Crump. P. M. (2002): Animal and Dietary Factors Affecting Feed Intake During the Prefresh Transition Period in Holsteins. Journal of Dairy Science, 85:3430-3443.
89. Hayirli, A., Grummer, R. R., Nordheim, E. V., Crump. P. M. (2002): Animal and Dietary Factors Affecting Feed Intake During the Prefresh Transition Period in Holsteins. Journal of Dairy Science, 85:3430-3443.
90. Heck, J. M. L., van Valenberg , H. J. F., Dijkstra , J., van Hooijdonk, A. C. M. (2009): Journal of Dairy Science, 92:4745-4755
91. Heuer, C., Schukken, Y.H., Dobbelaar, P. (1999): Postpartum Body Condition Score and Results from the First Test Day Milk as Predictors of Disease, Fertility, Yield, and Culling in Commercial Dairy Herds. Journal of Dairy Science, 82:295-304.
92. Hojman, D., Kroll, O., Adin, G., Gips, M., Hanochi, B., Ezra, E. (2004): Relationships between milk urea and production, nutrition, and fertility traits in Israeli dairy herds. Journal of Dairy Science, 87, 1001–1011.
93. Holt, C. (1985): The milk salts: Their secretion, concentrations and physical chemistry. In: Fox PF (ed.) Developments in Dairy Chemistry, Vol. 3: Lactose and Minor Constituents, pp. 143–181.
94. Hosmer, W. David., Lemeshow, Stanley. (2000): Applied Logistic Regression-second edition, Wiley Series in probability and statistics.
95. Howard, H.J., Aalseth, E.P., Adams, G.D., Bush, L.J., McNew, R.W., Dawson, L.J. (1987): Influence of dietary protein on reproductive performance of dairy cows. Journal of Dairy Science, 70, 1563–1571.
96. Howard, H.J., Aalseth, E.P., Adams, G.D., Bush, L.J., McNew, R.W., Dawson, L.J. (1987): Influence of dietary protein on reproductive performance of dairy cows. Journal of Dairy Science, 70, 1563–1571.
97. Hrvatska poljoprivredna agencija (2013): 100 godina organiziranog uzgojno-selekcijskog rada u stočarstvu Hrvatske. Zagreb
98. Hrvatska poljoprivredna agencija (2015): Godišnje izvješće za 2014. godinu. Zagreb.
99. Hudson, C. D., Bradley,A.J., Breen,J.E., Green. M.J. (2012): Associations between

udder health and reproductive performance in United Kingdom dairy cows. Journal of Dairy Science, 95:3683–3697.

100. ICAR - International Committee for Animal Recording (2012): Guidelines approved by the General Assembly held in Cork, Ireland
101. http://www.icar.org Historic info; The yearly cow milk survey (28.10.2013)
102. http://www.pmfst.hr Transkripcija. pdf (15.9.2102)
103. http://www.sciencephoto.com/media/305849/view (15.8.2013)
104. Inchaisry, C., Jorritsma,R.,Vos, P.L.A.M., van der Weijden, G.C., Hogeveen, H.(2010): Economic consequences of reproductive performance in dairy cattle. Theriogenology, 74: 835–846
105. Ingvartsen, K.L., Andersen, J.B. (2000): Integration of metabolisam and intake regulation: a review focusing on periparturient animals. Journal of Dairy Science, 83(7). 1573-1597
106. Ivkić, Z. (2011): Utjecaj genetskih i okolišnih čimbenika na broj somatskih stanica u kravljem mlijeku. Doktorski rad. Poljoprivredni fakultet. Osijek.
107. Ivkić**,** Z., Špehar, M., Bulić, V., Mijić, P., Ivanković, A., Solić, D. (2012): Utjecaj genetskih i okolišnih parametara na broj somatskih stanica u mlijeku simentalske i holstein pasmine goveda. Mljekarstvo, 62, (2): 143-150.
108. Ižaković, T., Gantner, V., Tolušić, Z., Mijić, P., Solić, D. (2011): Kalkulacija cijene koštanja provedbe kontrole mliječnosti krava u Republici Hrvatskoj. Stočarstvo, 65 (4) 317-329.
109. Jagusiak W**.** (2006): Fertility measures in Polish Black-and-White cattle. 3.Phenotypic and genetic correlations between fertility measures and milk production traits. Journal of Animal Feed Science, 15 : 371–380.
110. Jakopović, I. (1989.): Organizacija kontrole mliječnosti AT – metodom. PCH – RJ Stočarski selekcijski centar, Zagreb.
111. Jazbec, A (2001): Interakcija kardiovaskularnih i respiratornih čimbenika, te životnih navika u procjeni doživljenja. Doktorski rad. Medicinski fakultet. Zagreb.
112. Jenness, R., Sloan,R.E,.(1970): The composition of milk of various species: A review. Dairy Sciences Abstract 32: 599–612.
113. Jensen, R. G., i D. S. Newberg,. (1995): Bovine milk lipids. Pages 543–575 in Handbook of Milk Composition. R. G. Jensen, ed. Academic Press, San Diego, CA
114. Johnson, R.G., Young, A.J. (2003): The association between milk urea nitrogen and

DHI production variables in commercial dairy herds. Journal of Dairy Science, 86: 3008-3015.

115. Jonker, J.S., Kohn, R.A, Erdman, R.A. (1998): Using milk nitrogen to predict nitrogen excretion and utilization efficiency in lacating dairy cattle. Journal of Dairy Science. 81: 2681-2692.
116. Jovanovac, S., Gantner, V., Raguž ,N., Kuterovac, K., Solić, D. (2007) : Omjer mliječne masti i bjelančevina kao indikator hranidbenog statusa holstein krava pri različitom stadiju i redoslijedu laktacije. Krmiva , 49, (4): 189-198.
117. Jovanović, M. (1988.): Fiziologija i anatomija domaćih životinja. Medicinska knjiga, Beograd-Zagreb.
118. Jovanović, R., Dujić, D., Glamočić, D. (2001):Ishrana domaćih životinja. Drugo dopunjeno izdanje. Symbol. Novi Sad.
119. Juozaitiene, V., Juozaitis, A. (2006): Relationship between somatic cell count and milk production or morphological traits of udder in Black and White cows. Turkish Journal of Veterinary and Animal Sciences, 30: 47-51.
120. Kabalin, H., Grizelj, J., Dobranić, T., Štoković, I., Kabalin, A.E. (2013) : Ultrasound examination of cows during the puerperium in everyday veterinary practice. World Journal of Veterinary Science, 1: 8-12.
121. Kalbfleish, J. D., Prentice, R.L., (2002): The Statistical Analysisi of Failure Time Data. 2nd e. New York: John Wiley and Sons.
122. Kehrli, M. E., and D. E. Shuster. (1994): Factors affecting milk somatic cells and their role in health of the bovine mammary gland. Journal of Dairy Science, 77:619–627.
123. Kelly, A. L., D. Tiernan, C. O'Sullivan, and P. Joyce. 2000. Correlation between bovine milk somatic cell count and polymorphonuclear leukocyte level for samples of bulk milk and milk from individual cows. Journal of Dairy Science, 83:300–304.
124. Kohn, R. (2007): Use of milk or blood urea nitrogen to identify feed management inefficiencies and estimate mnitrogen excretion by dairy cattle and other animals. Florida ruminant nutrition symposium, Gainensville
125. Kompan, D., Gantner, V., Kovač, M., Klopčič, M., Jovanovac ,S.(2006): Estimation of daily milk yield from alternative milk recording schemes in dairy sheep. Acta Agraria Kaposváriensis (2006) Vol 10 No 2, 169-176
126. Konjačić,M., Kelava,N., Ivkić,Z., Ivanković,A., Prpić, Z.,Vnučec,I., Ramljak,J.,

Mijić,P.(2010): Non-nutritional factors of milk urea concentration in Holstein cows from large dairy farms in Croatia. Mljekarstvo 60 (3), 166-174

127. Kristula, M. A., M. Reeves, H. Redlus, and C. Uhlinger. 1995. A preliminary investigation of the association between the first postpartum milk fat test and first insemination pregnancy rates. Preventive Veterinary Medicine 23:95–100.
128. Kruip, T.A.M., Meijer, G.A.L., Rukkwamsuk, T., Wensing, T. (1998). Effects of feed in the dry period on fertility of dairy cows post partum. Reproduction in Domestic Animals 33: 165-168.
129. Kumlu, S.(2012): Reproduction and mangagement, Dairy farm managementand advisory systems in EU and Turkey, Volume1, str. 81-97
130. Kuterovac, K., Balaš, S., Gantner, V., Jovanovac, S., Dakić, A. (2005): Evaluation of nutritional status of dairy cows based on milk analysis results. Italian Journal of Animal Science. Vol. 4. (Suppl. 3), 33-35.
131. Lavon, Y., Ezra,E,. Leitner,G., Wolfenson,D. (2011):. Association of conception rate with pattern and level of somatic cell count elevation relative to time of insemination in dairy cows. Journal of Dairy Science, 94: 4538–4545.
132. Le Blanc, S. (2005) Using DHI Records On-Farm to Evaluate Reproductive PerformanceAdvances in Dairy Technology .Volume 17, page 319-330
133. Le Blanc, S., Lissemore, K., Kelton, D., Duffield, T., Leslie, K. (2006): Major advances in disease prevention in dairy cattle. Journal of Dairy Science 89: 1267-1279.
134. Le Blanc, S. (2010): Assessing the association of the level of milk production with reproductive performance in dairy cattle. Journal of Reproduction and Developpment. 56:S1–S7
135. Le Blanc, S. (2010): Health in the Transition Period and Reproductive Performance. WCDS Advances in Dairy Technology. 22: 97-110.
136. Leroy J.L.M.R., Opsomer G., Van Soom A., Goovaerts I.G.F., Bols P.E.J. (2008a): Reduced fertility in high yielding dairy cows: Are the oocyte and embryo in danger? Part I – The importance of negative energy balance and altered corpus luteum function to the reduction of oocyte and embryo quality in high-yielding dairy cows. Reproduction in Domestic Animals, 43, 612–622.
137. Linn, J.G. (1988): Factors affecting the composition of milk from dairy cows. Designing Foods. Natl. Acad. Sci.,Washington, DC; (str 224-41)

138. Löf, E., Gustafsson, H., Emanuelson, U. (2007): Associations between herd characteristics and reproductive efficiency in dairy herds. Journal of Dairy Science, 90: 4897–4907.
139. López-Gautius (2003): Is fertility declining in dairy cattle ? A retrospective study in northeastern Spain. Theriogenology 60: 89-99
140. López-Gatius, F., Garcia-Ispierto, I., Santolaria P., Yaniz, J., Nogareda, C., Lopez-Bejar.M.(2006): Screening for high fertility in high-producing dairy cows. Theriogenology 65:1678–1689
141. Lomander, H., Svensson,C.,Hallén-Sandgren C.,Gustafsson,H.,Frössling,J. (2013): Associations between decreased fertility and management factors, claw health, and somatic cell count in Swedish dairy cows. Journal of Dairy Science, 96: 6315–6323
142. Lomander,H., Svensson,C.,Hallén-Sandgren C.,Gustafsson,H.,Frössling,J.(2013): Associations between decreased fertility and management factors, claw health, and somatic cell count in Swedish dairy cows. Journal of Dairy Science, 96: 6315–6323
143. Lucy, M.C., Staples, C.R., Thatcher, W.W., Erickson, P.S., Cleale, R.M., Firkins, J.L., Clark, J.H., Murphy, M.R., Brodie, B.O. (1992): Influence of diet composition, dry matter intake, milk production and energy balance on time of postpartum ovulation and fertility in dairy cows. Animal Production 54:323–331
144. Lucy, M.C. (2001): Reproductive loss in high-producing dairy cattle: where will it end? Journal of Dairy Science 84(6): 1277-93.
145. Lucy, M.C**.** (2007) :Fertility in high-producing dairy cows: reasons for decline and corrective strategies for sustainable improvement. Society of Reproduction and Fertility Supplement. 64:237-54.
146. Lujerdean, A., Bunea, A., Miresan, V. (2007): Seasonal related changes in the major nutrients of bovine milk (total protein, lactose, casein, total fat and dry matter). Scientific Papers University of Agricultural Science and Veterinary Medicine Iasi 52:372-374.
147. Macmillan, K.L., Lean, I.J., Westwood, C.T. (1996): The effects of lactation on the fertility of dairy cows. Australian Veterinary Journal, 73 : 141-147.
148. Madouasse, A. (2009): An Evaluation of Milk Recording, Somatic Cell Counts and Reproductive Performance in a Large Cohort of Dairy Herds in England and Wales. Doktorska disertacija
149. Madouasse, A., Huxley, J.N., Brown, W.J., Bradley, A.J., Dryden ,I.L., Green, M.J.

(2010): Use of individual cow milk recording data at the start of lactation to predict the calving to conception interval. Journal of Dairy Science, 93: 4677–4690

150. Majeskie, J.L. (1981.): Monitor needed for Official AM – PM test. Hoards Dairyman, 126: 333.
151. Mansson, H.L. (2008): Fatty acids in bovine milk fat. Food Nutr. Res. 52:10-34.
152. Marenjak,T., Poljičak-Milas,N., Stojević, Z.(2004): Svrha određivanja koncentracije ureje u kravljem mlijeku. Praxis veterinaria 52 (3), 233-241.
153. Marenjak, T., Poljičak-Milas,N., (2007): Seasonal variations in raw milk quality and milk production on small-holder dairy farms in Croatia. Milcwissenschaft, 62, 273-275
154. Masilo, B. S., Stevenson, J. S,. Schalles, R R,. and Shirley, J,. E,. 1992. Influence of genotype and yield and composition of milk on interval to first postpartum ovulation in milked beef and dairy cows. Journal of Animal. Science, 70: 379–385
155. Mellado, M., Antonio-Chirino, E., Meza-Herrera, C., Veliz, F. G., Arevalo, J. R., Mellado , J., de Santiago, A.(2011): Effect of lactation number, year, and season of initiation of lactation on milk yield of cows hormonally induced into lactation and treated with recombinant bovine somatotropin. Journal of Dairy Science 94 :4524–4530
156. Melendez, P., Donovan, A., Hernandez, J. (2000): Milk urea nitrogen and infertility in Florida Holstein cows. Journal of Dairy Science, 83 : 459–463.
157. Miglior, F., Sewalem, A., Jamrozik, J., Lefebvre, D. M.,. Moore, R. K. (2006): Analysisof milk urea nitrogen and lactose and their effect on longevity in Canadian dairy cattle. Journal of Dairy Science 89, 4886-4894
158. Miller, R.H., Clay, J.S., Norman, H.D., (2001): Relationship of somatic cell score with fertility measures. Journal of Dairy Science 84, 2543-2548.
159. Miletić, S. (1994): Mlijeko i mlječni proizvodi. Hrvatsko mljekarsko društvo. Zagreb.
160. Mitić, N., Ferčej, J., Zeremski, D., Lazarević, LJ. (1987). Govedarstvo. Zavod za udžbenike i nastavna sredstva. Beograd
161. Morek-Kopić, M., Žarnecki,A., Jagusiak,W.(2008): Associations between somatic cell score of milk and fertility traits in Polish Holstein-Friesian cows. Animal Science Papers and Reports vol. 27 (2009) no. 1, 15-22
162. Morton, J.M. (2001): High geneticmerit and high-producing dairy cows in

commercial Australian herds don't have substantially worse reproductive performance. British Society of Animal Science 26:305–311.

163. Nagamine, J., Sasaki, O. (2008): Effect of environmental factors on fertility of Holstein-Friesian cattle in Japan. Livestock science. Volume 115, Issue 1, 89-93
164. Narodne novine (2005): Pravilnik o metodama za ispitivanje osobina I procjenu uzgojnih vrijednosti uzgojno valjanih goveda (NN 134/2005 od 11.11.2005)
165. Nebel, R.L., McGilliard, M.L. (1993): Interactions of high milk yield and reproductive performance in dairy cows. Journal of Dairy Science 76: 3257-3268.
166. Negussie, E., Strandén, I.,Mäntysaari, E.A. (2013): Genetic associations of test-day fat:protein ratio with milk yield, fertility, and udder health traits in Nordic Red cattle. Journal of Dairy Science, 96:1237-1250.
167. Nguyen, T.C., Nakao, T., Gautam, G., Su,L.T., Ranasinghe, R.M.,Yusuf, M.(2011): Relationship between milk somatic cell count and postpartum ovarian cyclicity and fertility in dairy. Acta Vet Hung. 2011 Sep;59(3):349-62
168. Norman, H.D., Wright, J.R., Kuhn, M.T., Hubbards, S.M., Cole, J.B.,VanRaden, P.M..(2009): Genetcic and enviromental factors that affect gestation length in dairy cattle. Journal of Dairy Science, 92:2259-2269.
169. Olson, K.M., Cassell, B.G., Hanigan., M.D. (2010): Energy balance in first-lactation Holstein, Jersey, and reciprocal F1 crossbred cows in a planned crossbreeding experiment. Journal of Dairy Science, 93:4374-4385.
170. Overton, T.R., Waldron, M.R. (2004): Nutritional Management of Transition Dairy Cows: Strategies to Optimize Metabolic Health. Journal of Dairy Science, 87:(E. Suppl.):E105–E119
171. Overton, T.R. (2012): Managing Energy Metabolism in Transition Dairy Cows. 4-State Dairy Nutrition & Management Conference, Proceeding : 86-91.
172. Paura, L., Jonkus, D., Ruska, D. (2012) Evaluation of the milk fat to protein ratio and fertility traits in Latvian Brown and Holstein dairy cows. Acta agriculturae Slovenica, Supp. 3, 155-159.
173. Pantelić, V,. Skalicki, Z., Petrović, M. M., Aleksić, Ostojić-Andrić, S.D., Novaković, Ž.(2008): The effect of breeding region on certain fertility parameters of simmental cows. Biotechnology in Animal Husbandry 24 (3-4), p 1-8.
174. Patton, J., Kenny, D.A.,McNamara, S., Mee, J. F., O'Mara, F. P.,Diskin, M.G., Murphy J.J. (2007): Relationships Among Milk Production, Energy Balance,

Plasma Analytes, and Reproduction in Holstein-Friesian Cows. Journal of Dairy Science 90:649–658

175. Peters, M.W., Pursley, J.R. (2002): Fertility of lactating dairy cows treated with Ovsynch after presynchronization injections of PGF2α and GnRH. Journal of Dairy Science, 85:2403–2406.
176. Petrač B., Zmaić K., Tolušić Z., Jadranka Deže (2002): Tržnost mlijeka u Republici Hrvatskoj. Poljoprivreda, Vol. 7(1), str. 56-60.
177. Petz, B. (2004): Osnovne statističke metode za nematematičare, Naklada Slap, Zagreb, V. izdanje 384.
178. Podpecan, O., Mrkun, J., Zrimsek, P. (2008): Diagnostic evaluation of fat to protein ratio in prolonged calving to conception interval using receiver operating characteristic analyses. Reproduction in Domestic Animals 43:249–254.
179. Podpecan, O., Mrkun, J., Zrimsek, P. (2010): The evaluation of fat to protein ratio in milk as an indicator of calving to conception interval in dairy cows using various biostatistical methods. Acta Veterinaria (Beograd), Vol. 60, No. 5-6, 541-550, 2010
180. Pollot, G.E. (2004): Deconstructing Milk Yield and Composition During Lactation Using Biologically Based Lactation Models. Journal of Dairy Science, 87: 2357-2387.
181. Prpić, Z., Konjačić, M., Vnučec,I., Ramljak. J., Ivanković, A. (2005): Nehranidbeni čimbenici sadržaja ureje u mlijeku. Stočarstvo, 59 (3), 189-198.
182. Pryce, J.E., Nielsen, B.L., Veerkamp, R.F., Simm, G. (1999): Genotype and feeding system effects and interactions for health and fertility traits in dairy cattle. Livestock Production Science 57: 193-201.
183. Pryce, J.E., Coffey, M.P., Brotherstone, S. (2000): The genetic relationship between calving interval, condition score and linear type and management traits in pedigree registered Holstein dairy cows. Journal of Dairy Science, 83:2664–2671
184. Quinn, N., Killen, L., Buckley, F. (2006): Irish Journal of agricultural and food research 45: 13-23
185. Raguž, N. , Gantner,V., Potočnik, K., Jovanovac,S. (2010) : Procjena dugovječnosti primjenom metode analize preživljavanja u populacijama mliječnih goveda u Hrvatskoj. Proceedings of 45 intrenational Symposium on Agriculture, 15-19 feb., Opatija, 1063-1067
186. Rajala-Schultz, P.J., Saville, W.J.A., Frazer,Gs., Wittum, T.E. (2001): Association

between milk urea nitrogen and fertility in Ohio dairy cows. Journal of Dairy Science, 84: 482-489

187. Rajala-Schultz, P.J., Saville, W.J.A. (2003): Sources of variation in milk urea nitrogen in Ohio dairy herds. Journal of Dairy Science, 86: 1653-1661.
188. Ray, D. E., Halbach, T. R.,Armstrong., D. V. (1992) Season and lactation number effects on milk production and reproduction in dairy cattle in Arizona**.** Journal of Dairy Science, 75:2976.
189. Reents, R., Dekkers, J.C.M., Schaeffer, L. R. (1995): Genetic evaluation for somatic cell score with a test day model for multiple lactations. Journal of dairy science, 78, (12), 2858-2870.
190. Řehák, D., Rajmon, R., Kubešová, M., Štípková, M., Volek J., Jílek, F. (2009): Relationships between milk urea and production and fertility traits in Holstein dairy herds in the Czech Republic Czech Journal of Animal Science 54, 2009 (5) : 193–200.
191. Reksen, O., Havrevoll, Q., Grohn, Y.T., Bolstad, T., Wakldmann, A,, Ropstad, E. (2002): Relationships Among Body Condition Score, Milk Constituents,and Postpartum Luteal Function in Norwegian Dairy Cows. Journal of Dairy Science, 85, 1406-1415.
192. Rhoads, M.L., Rhoads, R.P., Gilbert, R.O., Toole, R., Butler, W.R. (2006): Detrimental effects of high plasma urea nitrogen levels on viability of embryos from lactating dairy cows. Animal Reproduction Science, 91, 1–10.
193. Richardt, W.(2004):Milk composition as an indicator of nutrition and health. In The Breeding I, 2004, vol.11, p. 26–27
194. Roche, J.F., Mackey, D., Diskin. M.D.(2000): Reproductive management of postpartum cows. Animal Reproduction Science 60–61:703–712.
195. Rodriguez-Martinez H, Hultgren J, Bage R, Bergqvist AS, Svensson C, Bergsten C, Lidfors L, Gunnarsson S, Algers B, Emanuelson U, Berglund B, Andersson G, Lindhe B, Stalhammar H, Gustafsson H. 2008. Reproductive performance in high-producting dairy cows: can we sustain it under current practice? In: IVIS Reviews in Veterinary Medicine. Ithaca, NY. http://pub.epsilon.slu.se/3502/ (29.9.2014)
196. Roseler, D.K., Ferguson, J.D.,Sniffen, C.J., Herrema, J. (1993): Dietrary protein degradability effects on plasma and milk urea nitrogen and milk nonprotein nitrogen in Holstein cows. Journal of Dairy Science 76:525-534

197. Royal, M.D., Darwash, A.O., Lamming, G.E. (1999):. Trends in the fertility in dairy cows in the United Kingdom. Proceedings of the Annual Meeting of the British Society of Animal Science. Abstr.: 1.
198. Royal, M.D., Darwash, A.O., Flint, A.P.E., Webb, R., Woolliams, J.A., Lamming, G.E. (2000): Declining fertility in dairy cattle: Changes in traditional and endocrine parameters of fertility. Animal Science, 70:487–501.
199. Royal, M.D., Flint, A.P.F., Woolliams, J.A (2002a). Genetic and phenotypic relationships among endocrine and traditional fertility traits and production traits in Holstein-Friesian dairy cows. Journal of Dairy Science, 85: 958-967.
200. Saad, A. M. (1987): Flow cytometric measurement of bovine milk neutrophil phagocytosis. Acta Veterrinaria Scandinavica, 28:333–342.
201. Santos, J.E.P., Rutigliano, H.M., Sá Filho, M.F. (2009): Risk factors for resumption of postpartum cyclicity and embryonic survival in lactating dairy cows. Animal Reproduction Science, 110:207-221.
202. SAS Inst.Inc (2011) : The SAS system for Windows, Version 9.3. Cary, NC, SAS Institute
203. Schutz, M.M., Hansen, L.B., Steuernagel, G.R., Kuck, A.L. (1990): Variation in milk, fat, protein and somatic cells for dairy cattle. Journal of DairyScience, 73: 484-493
204. Schutz, M.M., VanRaden, P.M., Wiggans, G.R. (1994): Genetic variation in lactation means of somatic cell scores for six breeds of dairy cattle. Journal of Dairy Science, 77, 284-293
205. Schepers, A. J.; Lam, T. J. G. M.; Schukken, Y. H., Wilmink, J. B., Hanekamp, W. J. (1997): Estimation of variance components for somatic cell counts to determine thresholds for uninfected quarters. Journal of Dairy Science, 80, (8), 1833-1840.
206. Schirmann, K., Chapinal,N., Weary,D.M., Heuwieser,W., von Keyserlingk, M.A.G (2011) : Short-term effects of regrouping on behavior of prepartum dairy cows. Journal of Dairy Science, 94 :2312–2319
207. Sechrist, R.S. (1981.): Testing strategies: What about AM – PM? Dairy, 37, 7: 12.
208. Shtatland, E. S., Kleinman K., and Cain E. M. (2002). One more time about R2 measures of fit in logistic regression. NESUG 2002 Proceeding, 742 - 747, NorthEast SAS Users Group, Inc.
209. Stanton, T.L., Jones, L.R., Everett, R.W., Kachman, S.D. (1992): Estimating milk,

fat, and protein lactation curves with a test day model. Journal of Dairy Science, 75: 1691–1700.

210. Stelwagen (2011): Lactose , Encyclopedia of Dairy Science, Volume 3, str. 367-372
211. Silva, H. M., Wilcox, C. J., Thatcher, W. W., Becker, R. B., Morse., D. (1992) : Factors affecting days open, gestation length, and calving interval in Florida dairy cattle. Journal of Dairy Science, 75:288
212. Silvestre, A.M., Martins, A.M., Santos, V.A., Ginja, M.M., Colaco,J.A. (2009): Lactation curves for milk, fat, protein in dairy cows: A full approach. Livestock science, 122, 308-313
213. Sinclair, K.D., Kuran, M., Gebbie, F.E., Webb, R., McEvoy, T.G. (2000): Nitrogen metabolism and fertility in cattle: II. Development of oocytes recovered from heifers offered diets differing in their rate of nitrogen release in the rumen. Journal of Animal Science, 78, 2670–2680.
214. Skyva, J. (2004): A breeding and economic impact of milk analyses for ketone bodies, somatic cells and urea, including elaboration of advisory sheet.. RIFCB, Ltd., Rapotin, Proceedings of contributions: The actual problems of management in the cattle keeping., 62-67.
215. Sordillo L.M., Shafer-Weaver K., DeRosa, D. (1997): Immunobiology of the mammary gland, Journal of Dairy Science, 80, 1851–1865.
216. Spohr, M., Beening, J., Scholz, H.(1992): Information aus der Milch des Rindes zur Überprüfung von Fütterung und Gesundheit. Der Prakt. Tierarzt. 74, (Coll. Vet. XXIII), 52-56.
217. Swenson, M.J., Reece ,W.O. (1993): Water balance and excretion. Dukes' physiology of domestic animals. 11.ed. Cornel university. Ithaca.
218. Symonds, H.W., Mather, D.L., Collis, K.A. (1981): The maximum capacity of liver of the adult dairy cow to metabolize ammonia. British Journal of Nutrition, 46:481-486.
219. Špehar, M. (2010): Prediction of breeding values for milk traits in Croatian dairy cattle. Magistarki rad. Biotehnical faculty. Ljubljana
220. Špehar, M., Štepec, M.,, Ivkić,Z., Bulić,V., Lučić,M., Gorjanc,G., Potočnik, K., Barać, Z.(2012): Ocjena genetskih parametara za dužinu međutelidbenog razmaka u simentalske pasmine goveda u Hrvatskoj. 47. Hrvatski i 7.Međunarodni simpozij agronoma (Sažeci str. 214)

221. Taylor, V., Beever, D., Bryant, M., Wathes, D. (2003): Metabolic profiles and progesterone cycles in first lactation dairy cows, Theriogenology, 59, 1661-77.
222. Tratnik, Lj., Božanić,R. (2012) : Mlijeko i mliječni proizvodi. Hrvatska mljekarska udruga, Zagreb
223. Uremović, Z. (2004): Govedarstvo. Hrvatska mljekarska udruga. Zagreb.
224. Vasconcelos, J., Martins, A., Petim-Batista, MF., Colaço, J., Blake, RW., Carvalheira, J. (2004): Prediction of daily and lactation yields of milk, fat and protein using an autoregressive repeatability test day model. Journal of Dairy Science, 87, 2591-2598.
225. Varnam A.H., Sutherland J.P., (1994) : Milk and Milk Products. Technology, Chemistry and Microbiology. Chapman Hall. London, New York, Tokyo, Melbourne, Madras.
226. Veerkamp, R.F., Brotherstone, S. (1997): Genetic correlations between linear type traits, food intake, liveweight and condition score in Holstein-Friesian dairy cattle. Animal Science, 64:385-392.
227. Veerkamp, R. F., Oldenbroek, J. K., Gaast H. J. van der., Werf, J. H. J. van der. (2000):Genetic correlation between days until start of luteal activity and milk yield, energy balance and live weights. Journal of Dairy Science, 83: 577-583.
228. Veerkamp R.F., Koenen E.P.C., De Jong G. (2001): Correlations among body condition score, yield, and fertility in first-parity cows estimated by random regression models. Journal of Dairy Science, 84, 2327-2335.
229. Vicario, D., Carnier, P (2008): Contenuto in cellule somatiche in allevamenti misti di Pezzata Rossa e Frisona. *http://www.apa.cn.it/Sezioni/PezzRossa/News.htm* (10.02.2011)
230. Walsh, S.W., Williams E.J., Evans A.C.**(**2011) : A review of the causes of poor fertility in high milk producing dairy cows. Animal Reproduction Science 123: 127-138
231. Washburn, S.P., Silvia, W.J., Brown, C.H., McDaniel, B.T., McAllister, A.J.(2002): Trends in reproductive performance in southeastern Holstein and Jersey DHI herds. Journal of Dairy Science, 85: 244-251.
232. Wattiaux, M.A.(1995): Dairy essentials Chapter 20 : Milk Secretion in the Udder of a Dairy Cow http://babcock.wisc.edu/node/202 Babcock institute (15.9.2013)
233. Wattiaux,M.A. (1995): Dairy essentials Chapter 13 : Reproduction and genetic

selection http://babcock.wisc.edu/node/174, Babcock institute (15.10.2013)

234. Weigel K.A. 2004. Improving the reproductive efficiency of dairy cattle through genetic selection. Journal of Dairy Science, 87: E86-92

235. West, J. W., Mullinix, B. G., Bernard, J. K. (2003):. Effects of hot, humid weather on milk temperature, dry matter intake and milk yield in lactating dairy cows. Journal Dairy Science, 86:232–242.

236. Westwood, C.T., Lean, I.J., Garvin, J.K. (2002): Factors influencing fertility of Holstein dairy cows: a multivariate description. Journal of Dairy Science, 85:3225-3237.

237. Wood, P.D.P. (1976): Algebraic models of the lactation curves for milk, fat and protein production, with estimates of seasonal variation. Animal Production**,** 22: 35–40.

238. Zagorec, D., (2009): Utjecaj upravljanja na gospodarske učinke obiteljskih mliječnih farmi, Stočarstvo, vol. 63, br. 1/2009 , str. 3-33.

239. Yang, L., Lopez-Villaloboz, N., Berry, D.P., Parkinson, T. (2010): Phenotypic relationships between milk protein percentage and reproductive performance in three strains of Holstein Friesian cows in Ireland. Proceedings oft he New Zealand society of Animal Production, 70: 29-32.

240. Yang, M., Goldstein, H. (2003): Modelling survival data in MLwiN 1.20. Institute of education, London

6. SAŽETAK

Ciljevi su ovoga istraživanja bili determinirati značajne utjecaje na trajanje razdoblja od teljenja do koncepcije (servis razdoblje), zatim utvrditi povezanost između trajanja servis razdoblja i svojstava rezultata provedbe kontrole mliječnosti te razviti sustav predviđanja trajanja servis razdoblje temeljem rezultata kontrole mliječnosti na početku laktacije (prve dvije kontrole) u populaciji holstein i simentalske pasmine krava čime bi se u konačnici povećala konkurentnost i financijski učinak farme.

Utvrđivanje i procjenjivanje trajanja dužine servis razdoblja u vrijeme dok krava još nije bređa, a na osnovu već dostupnih podataka o proizvodnji i sastavu mlijeka u razdoblju tranzicije i početku laktacije, značajno bi poboljšalo upravljanje proizvodnjom mlijeka i podizanje profitabilnosti mliječnih farmi. Utvrđivanje trajanja dužine servis razdoblja krava holstein i simentalske pasmine provedeno je u vremenskom razdoblju od 01.01.2008. do 31.12.2012. godine na svim gospodarstvima u Republici Hrvatskoj kod kojih je provođena kontrola mliječnosti. U analizi su korišteni podaci krava za koje je u navedenom razdoblju bilo moguće izračunati trajanje servis razdoblja. Izračun trajanja dužine servis razdoblja, te datuma koncepcije obavljen je kod krava koje su imale najmanje dva teljenja, oduzimanjem prosječnog trajanja graviditeta (Norman i sur., 2009., ICAR 2012) od posljednjeg teljenja.

Statističkom obradom metodom analize preživljavanja i metodom logističke regresije obuhvaćeno je 14.864 krave holstein pasmine s ukupno 29.278 zapisa rezultata kontrole mliječnosti, te 18.708 krava simentalske pasmine s ukupno 37.416 zapisa rezultata kontrole mliječnosti. Utvrđene srednje vrijednosti za dnevnu količinu mliječne masti, dnevni sadržaj mliječne masti, dnevnu količinu bjelančevina, dnevni sadržaj bjelančevina, omjer mast : bjelančevine te broj somatskih stanica bile su veće pri kontrolnom danu 1. negoli pri kontrolnom danu 2. kod obje analizirane pasmine (holstein, simentalska). Utvrđene srednje vrijednosti za dnevni sadržaj ureje i dnevni sadržaj laktoze bile su veće kontrolnom danu 2. negoli pri kontrolnom danu 1. kod obje analizirane pasmine. Utvrđene srednje vrijednosti za dnevnu količinu mlijeka kod holstein pasmine bile su veće kontrolnom danu 2. negoli pri kontrolnom danu 1. dok su kod simentalske pasmine veće kontrolnom danu 1. negoli pri kontrolnom danu 2. Kod obje pasmine utvrđene su statistički vrlo značajne ili značajne korelacije između trajanja servis razdoblje i dnevnog sadržaja bjelančevina, broja somatskih stanica te omjer mast/bjelančevine pri oba kontrolna dana.

Vrijednosti koeficijenata korelacija kretale su se unutar raspona ±0,00 do ±0,20 što upućuje na zanemarivu povezanost između trajanja servis razdoblja i svojstava rezultata provedbe kontrole mliječnosti. Kod obje je pasmine evidentan je najveći udio teljenja u jesenskom razdoblju odnosno od rujna do studenog te najmanji udio teljenja u proljetnom razdoblju odnosno od ožujka do svibnja dok je kod obje pasmine evidentan najmanji udio koncepcija u ljetnom razdoblju odnosno od lipnja do kolovoza te najveći u zimskom razdoblju odnosno od prosinca do veljače. Veća vjerojatnost koncepcije po svim razredima trajanja servis razdoblja u simentalske u odnosu na holstein pasminu utvrđena je analizom kretanja krivulje preživljavanja trajanja servis razdoblja. Provedbom logističke regresije izrađena su dva statistička modela.

Model 1. koji uključuje varijable rezultata provedbe kontrole mliječnosti zasebno za svaku pasminu i svaki kontrolni dan. Kod holstein pasmine u model su uključene varijable dnevni sadržaj bjelančevina i broj somatskih stanica pri kontrolna dana te dnevni sadržaja laktoze pri kontrolnom danu 1. Kod simentalske pasmine pri oba kontrolna dana u model su uključene varijable dnevni sadržaj bjelančevina te indeks masti i bjelančevina. Varijable dnevni sadržaj ureje i dnevni sadržaj laktoze uključene su pri procjeni temeljem kontrolnog dana 1., a broj somatskih stanica pri procjeni temeljem kontrolnog dana 2.

Model 2. koji pored varijabli iz prvog modela uključuje i utjecaje regije, sezone i veličine stada, sezone koncepcije i sezone teljenja. Kod holstein pasmine u modelom su obuhvaćene varijable dnevni sadržaj bjelančevina, sezona koncepcije, sezona teljenja, veličina stada i regija kod holstein pasmine pri oba kontrolna dana, te dnevni sadržaj laktoze pri kontrolnom danu 1. Kod simentalske pasmine pri oba kontrolna dana u model su uključene varijable dnevni sadržaj bjelančevina, sezona teljenja, sezona koncepcije i veličina stada. Varijable indeks masti i bjelančevina, dnevni sadržaj laktoze i dnevni sadržaj ureje uključene su pri procjeni temeljem kontrolnog dana 1., dok je indeks bjelančevina i ureje te broj somatskih stanica uključen pri procjeni temeljem kontrolnog dana 2.

Ispitivanje snage modela za predviđanje događaja prikazano je pomoću indeksa konkordancije koji predstavlja sukladnost slaganja registriranih i predviđenih podataka unutar svakog modela. Utvrđeno je povećanje vrijednosti indeksa konkordancije za svaki model s većim rednim brojem u odnosu na početni model kao i povećanje vrijednosti indeksa konkordancije za kontrolni dani 2. u odnosu na kontrolni dan 1.

7. SUMMARY

The objectives of this research were to determine significant effects on the duration of the period from calving to conception (service period), then the relationship between the duration of the service periods and the traits recorded during the milk recording and develop a system of predicting the duration of service period based on the results milk recording in early lactation (the first two control) in a population of Holstein and Simmental cows, which would consequently increase competitiveness and financial performance of the farm.

Determination and estimation of the duration of the length of service period, when a cow is not yet pregnant, and on the basis of already available data on the milk production and composition during the transition period and early lactation, would significantly improve the management of milk production and raising the profitability of dairy farms.

Determination of the duration of the length of service period of Holstein and Simmental cows was conducted in the period from 01.01.2008 till 31.12.2012 in all farms in Croatia in which milk recording was performed. The data of cows for which in the defined period was possible to calculate the duration of the service period was used in the analysis. The calculation of the duration of the length of service period and the date of conception was carried out in cows that have had at least two calving, subtracting the average duration of pregnancy (Norman et al., 2009; ICAR, 2012) since last calving.

Statistical analysis using survival analysis and logistic regression method included 14,864 Holstein cows with a total of 29,278 milk recording records, and 18,708 Simmental cows with a total of 37,416 milk recording records. The determined mean values for the daily fat yield and content, the daily protein yield and content, fat/protein ratio and somatic cell count were higher in the control day 1 than in control day 2 for both analysed breed (Holstein, Simmental). The determined mean values for the daily urea and lactose content were higher in the control day 2 than in control day 1 for both analysed breed. The determined mean values of daily milk yield in Holstein breed were higher in the control day 2 than in control day 1, while in Simmental breed determined values were opposite. The statistically highly significant or significant correlation between the duration of the service period and the daily protein content, somatic cell count and the fat/protein ratio in both control days were determined in both breeds. Correlation coefficient values were

within the range ± 0.00 to ± 0.20 which indicates a negligible correlation between the duration of the service periods and the traits recorded during the milk recording.

For both breeds, that the largest calving quota was observed in the fall that is from September to November and the lowest calving quota was observed in the spring period that is from March to May. Regarding the conception rate, in both breeds lowest value was observed in summer that is from June to August and the largest value in the winter period that is from December to February. Higher conception probability at all classes of duration of service periods in the Simmental compared to the Holstein breed was determined using the analysis of movement survival curves for duration of service period. Based on results of logistic regression two statistical models were created.

Model 1 includes traits recorded during the milk recording separately for each breed and each test day. In the Holstein breed the model included daily protein content and somatic cell count in control day 1 and 2 and daily lactose content in control day 1. In the Simmental breed during the both control days the model included daily protein content and fat/protein ratio. The daily urea and lactose content were included when prediction was based on records during the control day 1, while somatic cell count was included when prediction was based on records during the control day 2.

Model 2 besides traits from model 1 also included effects of region, season of recording, herd size classes, parity, season of conception and season of calving. In the Holstein breed the model included daily protein content, conception season, calving season, herd size and region in both control days, and additionally daily lactose content in control day 1. In the Simmental breed during the both control days the model included daily protein content, conception season, calving season, and herd size. The fat/protein ratio, daily urea and lactose content were included when prediction was based on records during the control day 1, while fat/protein ratio, daily urea content and somatic cell count were included when prediction was based on records during the control day 2.

The power testing of models for prediction of incident was shown using the concordance index which represents the compliance agreement of recorded and predicted data within each model. The increase of the concordance index value was determined for each model with a higher number in comparison to the initial model. Additionally, the increase of the concordance index value was determined for control day 2 compared to the control day 1.

8. ŽIVOTOPIS

Rođen sam 27.5.1966. godine u Novoj Gradiški, gdje sam završio osnovnu školu. Srednju poljoprivrednu školu, smjer veterinarski pomoćnik završio sam u Slavonskom Brodu. Godine 1986. upisao sam studij na Poljoprivrednom fakultetu u Osijeku (smjer stočarstvo), a diplomirao sam 1990. godine. Nakon završenog studija zaposlio sam se u mljekari Slavija u Starom Petrovom Selu na radnom mjestu voditelja sirovinske i selekcijske službe, zaduženog za organizaciju otkupa i kvalitetu otkupljenog mlijeka, te organizaciju poslova kontrole mliječnosti.

Godine 1998. prešao sam u tvrku Agroinženjering, gdje sam radio na poslovima prodaje stočne hrane i savjetodavnim uslugama u području hranidbe domaćih životinja. Godine 2000. prešao sam u Hrvatski stočarsko selekcijski centar (današnja Hrvatska poljoprivredna agencija) na radno mjesto Voditelja selekcijske službe za područje brodsko posavske županije. Od 2003 -2009. godine bio sam zaposlen na radnom mjestu Voditelja odjela stočarskih službi nadkontrole u Hrvatskoj poljoprivrednoj agenciji, a od 2009. sam na radnom mjestu pomoćnika ravnatelja U vrijeme osnivanja Središnjeg laboratorija za kontrolu mlijeka obavljao sam edukaciju sabirača mlijeka o postupcima pravilnog uzorkovanja mlijeka za plaćanje mlijeka na osnovu kvalitete.

Tijekom postupka certifikacije poslova kontrole mliječnosti temeljem procedura ICAR-a (International Committee for Animal Recording) izradio sam procedure za provedbu kontrole mliječnosti i poslove nadkontrole kontrole mliječnosti.

Za vrijem uspostave rada Laboratorija za stočnu hranu radio sam na izradi procedura i edukaciji djelatnika za pravilno uzimanje uzoraka stočne hrane za analizu. Sudjelovao sam u provedbi istraživanja vezanih za metode i postupke kontrole mliječnosti, primjene rezultata kontrole mliječnosti u procjeni energetskog statusa mliječnih krava te sam objavio 15 znanstvenih i stručnih radova.