Određivanje površine dugog leđnog mišića u goveda primjenom različitih metoda

Kućar, Jelena

Master's thesis / Diplomski rad

2021

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Agriculture / Sveučilište u Zagrebu, Agronomski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:204:577356

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-25**

Repository / Repozitorij:

Repository Faculty of Agriculture University of Zagreb

SVEUČILIŠTE U ZAGREBU
AGRONOMSKI FAKULTET

Određivanje površine dugog leđnog mišića u goveda primjenom različitih metoda

DIPLOMSKI RAD

Jelena Kućar

Zagreb, Rujan, 2021.

Sveučilište u Zagrebu
Agronomski fakultet
University of Zagreb
Faculty of Agriculture

Određivanje površine dugog leđnog mišića u goveda primjenom različitih metoda

DIPLOMSKI RAD

Jelena Kućar

Zagreb, Rujan, 2021.

Sveučilište u Zagrebu
Agronomski fakultet

University of Zagreb
Faculty of Agriculture

Diplomski studij:

Proizvodnja i prerada mesa

Određivanje površine dugog leđnog mišića u goveda primjenom različitih metoda

DIPLOMSKI RAD

Jelena Kućar

Mentor:

doc.dr.sc. Nikolina Kelava Ugarković

Zagreb, Rujan, 2021.

Sveučilište u Zagrebu
Agronomski fakultet

University of Zagreb
Faculty of Agriculture

IZJAVA STUDENTA

O AKADEMSKOJ ČESTITOSTI

Ja, **Jelena Kućar**, JMBAG 0178111495, rođena 26.06.1997. u Varaždinu, izjavljujem da sam samostalno izradio diplomski rad pod naslovom:

Određivanje površine dugog leđnog mišića u goveda primjenom različitih metoda

Svojim potpisom jamčim:

- da sam jedina autorica/jedini autor ovoga diplomskog rada;
- da su svi korišteni izvori literature, kako objavljeni tako i neobjavljeni, adekvatno citirani ili parafrazirani, te popisani u literaturi na kraju rada;
- da ovaj diplomski rad ne sadrži dijelove radova predanih na Agronomskom fakultetu ili drugim ustanovama visokog obrazovanja radi završetka sveučilišnog ili stručnog studija;
- da je elektronička verzija ovoga diplomskog rada identična tiskanoj koju je odobrio mentor;
- da sam upoznata/upoznat s odredbama Etičkog kodeksa Sveučilišta u Zagrebu (Čl. 19).

U Zagrebu, dana _____

_____
Potpis studenta / studentice

Sveučilište u Zagrebu
Agronomski fakultet

University of Zagreb
Faculty of Agriculture

IZVJEŠĆE

O OCJENI I OBRANI DIPLOMSKOG RADA

Diplomski rad studentice **Jelene Kućar**, JMBAG 0178111495, naslova

Određivanje površine dugog leđnog mišića u goveda primjenom različitih metoda

obranjen je i ocijenjen ocjenom _____ , dana _____ .

Povjerenstvo:		potpisi:
1. doc.dr.sc. Nikolina Kelava Ugarković	mentor	_____
2. izv.prof.dr.sc. Miljenko Konjačić	član	_____
3. prof.dr.sc. Danijel Karolyi	član	_____

Zahvala

Ovime zahvaljujem svojoj mentorici doc.dr.sc. Nikolina Kelava Ugarković na pomoći, vodstvu, suradnji te korisnim savjetima tijekom izrade ovog diplomskog rada. Također, veliko hvala mojim prijateljima i kolegama zahvaljujući kojima pretekle godine studiranja smatram nezaboravnim periodom života. Ponajviše Heleni, Petri, Mirti, Karlu, Jeleni i Martini u kojima sam stekla prijatelje za cijeli život. Posebice zahvaljujem svojoj obitelji koja mi je omogućila studiranje i život u drugom gradu uz neizmjernu podršku i vjeru u moj uspjeh.

SADRŽAJ

1. Uvod 1
1.1. Cilj istraživanja 2
2. Stanje i trendovi u proizvodnji mesa goveda 3
2.1. Proizvodnja i potrošnja goveđeg mesa u svijetu i Europi 6
2.2. Proizvodnja goveđeg mesa u Hrvatskoj 7
2.3. Meso goveda 9
2.3.1. Kvalitativna svojstva goveđeg mesa 11
3. Ocjena trupova na liniji klanja 13
3.1. Sustav vrednovanja goveđih polovica na liniji klanja 14
3.2. Prikaz podataka s linije klanja u Republici Hrvatskoj 17
4. Parametri procjene uspješnosti tova i udjela tkiva u trupu 19
4.1. Randman 19
4.2. Debljina potkožnog masnog tkiva 20
4.3. Mramoriranost 21
4.4. Površina dugog leđnog mišića 22
5. MATERIJALI I METODE 25
5.1. Pokusne životinje 25
5.2. Obrada trupova 25
5.3. Metode određivanja površine dugog leđnog mišića 27
5.3.1. Metoda određivanja površine dugog leđnog mišića polarnim planimetrom 27
5.3.2. Prilagođena metoda mreže s točkama 28
5.3.3. Metoda najveće dužine i širine iscrtane površine dugog leđnog mišića 29
5.3.4. Metoda određivanja površine dugog leđnog mišića primjenom računalnog programa AutoCAD 31
5.3.5. Statistička analiza 37
6. Rezultati i rasprava 38
6.1. Deskriptivna statistika površina MLD-a određenih različitim metodama i razlike u prosjecima najmanjih kvadrata 38
6.2. Koeficijenti korelacije između površina MLD-a određenih različitim metodama 40
6.3. Regresija između površina MLD-a određenih različitim metodama 42
7. Zaključak 48
8. Popis literature 49

Sažetak

Sažetak diplomskog rada studentice **Jelene Kućar**

Određivanje površine dugog leđnog mišića u goveda primjenom različitih metoda

Cilj ovog diplomskog rada bio je usporediti četiri različite metode mjerenja površine dugog leđnog mišića *(musculus longissimus dorsi;* MLD) goveda. Kao metode mjerenja korišteni su polarni planimetar, prilagođena metoda mreže s točkama, metoda dvije točke te primjena računalnog programa AutoCAD. Površine MLD-a prikupljene su od 131 mladog bika i 19 teladi te preslikane vodootpornim markerom na prozirnu foliju. Za potrebe mjerenja računalnim programom AutoCAD folije su prethodno skenirane i stavljene u JPG oblik. Nakon mjerenja podaci su obrađeni primjenom statističkog paketa SAS V9.4.

U istraživanju je utvrđena značajna ($p<0,05$) razlika u površinama MLD-a goveda određenih različitim metodama. Značajno ($p<0,05$) manja površina MLD-a utvrđena je računalnim programom AutoCAD u odnosu na druge metode. Između površina MLD-a određenih različitim metodama utvrđena je visoka do vrlo visoka značajna pozitivna korelacija ($p<0,0001$) te visoki koeficijenti regresije.

Određivanje površine MLD-a polarnim planimetrom je relativno brza metoda, no uzastopno ponavljanje mjerenja velikog broja uzoraka vizualno je zamorno kao i očitavanje vrijednosti uslijed sitnih oznaka između brojeva. Prednost određivanja površine MLD-a računalnim programom AutoCAD je mogućnost brzih korekcija kao i automatsko preračunavanje površina. Prilagođena metoda mreže s točkama se subjektivno čini najbržom, no potrebno je iskustvo koje će se točke uz vanjski rub iscrtane površine MLD-a uzeti u obzir kao granične. Metoda najveće dužine i širine pogodna je za površine MLD-a eliptičnog oblika, ali ne i za površine MLD-a nepravilnog oblika.

Ključne riječi: dugi leđni mišić, površina, planimetar, prilagođena mreža s točkama, metoda dvije točke, AutoCAD

Summary

Summary of graduate thesis of student **Jelena Kućar**

Determination of *longissimus dorsi* muscle area in cattle using different methods

The aim of this graduate thesis was to compare four different methods of measuring the *longissimus dorsi* muscle (MLD) area in cattle. Polar planimeter, adjusted grid method, two-point method and AutoCAD software were used as measurement methods. The areas of MLD were collected from 131 young bulls and 19 calves and mapped with a waterproof marker on a transparent foil. Before area determination in AutoCAD, the foils were scanned and saved in JPG format. After measurement, the data were processed using the statistical package SAS V9.4. (2013).

Significant ($p< 0.05$) differences were found in area of MLD determined by different methods. The smallest ($p<0.05$) MLD-a area was determined in AutoCAD compared to other methods. Between methods were found high to very high positive significant ($p<0.0001$) Pearson correlation coefficients as well as high linear regression coefficients.

Determining the MLD area with a polar planimeter is a relatively quick method, but repeating measurements of a large number of samples in succession is visually tedious as well as reading the values due to tiny marks between numbers. The advantage of determining the MLD areas with the computer program AutoCAD is the possibility of fast correction as well as automatic surface recalculation. The adjusted point grid method subjectively seems to be the fastest, but experience is required to determine which points along the outer edge of the plotted MLD surface will be considered as boundary. The method of maximum length and width is suitable for elliptical MLD areas, but not for irregularly shaped MLD areas.

Keywords: *longissimus dorsi* muscle, area, planimeter, adjusted grid, two-point method, AutoCAD

1. Uvod

Govedarstvo je jedna od najstarijih grana stočarske proizvodnje koja je započela neposredno nakon udomaćivanja goveda (Ivanković i Mijić, 2020.). Sam opseg proizvodnje, napredak u genetici i hranidbi, mogućnost pretvorbe hrane biljnog podrijetla u visokokvalitetne izvore energije, proteina i drugih hranjivih tvari svrstavaju govedarstvo u vodeću granu stočarstva (Domaćinović i sur., 2015.). Proizvodnja mlijeka i goveđeg mesa u suvremenom gospodarskom okruženju, glavni su motivi govedarske proizvodnje, dok sporedni proizvodi također nalaze svoje uporabne vrijednosti (Ivanković i Mijić, 2020.).

Proizvodnja goveđeg mesa sastavni je dio ukupne govedarske proizvodnje koji se temelji na dugoj tradiciji uzimajući u obzir podneblje, genotip i tržišnu konkurentnost. Osnovna podjela tehnologije proizvodnje goveđeg mesa je: tov teladi, tov mlade junadi, tov mladih bikova, tov junica, tov starijih bikova, tov volova i tov starijih krava. Po pitanju nasljedne osnove, proizvodnja mesa se temelji na mesnim i kombiniranim pasminama goveda, posebice kod traženijih robnih marki. Važnost goveđeg mesa u ljudskoj prehrani proizlazi iz njegove nutritivne vrijednosti, sadržaja i strukture proteina, masti, vitamina i minerala. Razina potrošnje goveđeg mesa upućuje na gospodarsku razvijenost države, sociološke i prehrambene navike potrošača. Potrošači su danas pretežno usredotočeni na proizvodne sustave, utjecaj na okoliš i dobrobit životinja (Ivanković i Mijić 2020.).

Za osiguravanje goveđih trupova visoke kvalitete potrebno je razumjeti kako se mjere pojedina svojstva trupova i kako ona utječu na ocjene trupova i vrijednost proizvoda. Neka od svojstava koje se mjere su mramoriranost, debljina potkožnog masnog tkiva, randman i površina dugog leđnog mišića (Troxel i Gadberry, 2009.). Površina dugog leđnog mišića najčešće se određuje na presjeku *m. longissimus dorsi* između 12. i 13. rebra. Navedena mjera se najčešće uzima za procjenu ukupnog udjela mišića u trupu te se koristi za izračun mesnatosti trupa (Kelava i sur., 2007.).

1.1. Cilj istraživanja

Cilj ovog diplomskog rada je utvrditi razlike u površini MLD-a goveda određene polarnim planimetrom, metodom prilagođene mreže s točkama, metodom dvije točke te primjenom računalnog programa AutoCAD.

2. Stanje i trendovi u proizvodnji mesa goveda

Glavno načelo proizvodnje goveđeg mesa je da se temeljem raspoložive genetske osnove i optimalnim korištenjem raspoloživih resursa u određenom vremenu prihvatljivom tehnologijom proizvede meso poželjnih nutritivnih, organoleptičkih, higijenskih i sigurnosnih odlika (Ivanković i Mijić, 2020.). Kao gospodarska djelatnost, proizvodnja goveđeg mesa, temelji se najvećim dijelom na korištenju procesa rasta mlađih životinja koje nakupljaju biomasu iz hranjivih sastojaka raspoložive hrane. Uz mlađa grla, za proizvodnju mesa koriste se i starije životinje koje se većinom izlučuju iz uzgoja. U navedenom slučaju proces rasta je završen, te se tov temelji na kraćem razdoblju intenzivne hranidbe prilikom čega dolazi do povećanja težine grla. Provedbom tova, u najvećem broju slučajeva, koriste se koncentrirana krmiva budući da se želi postići što je mogući veći dnevni prirast (Jakopović i sur., 2005.).

Mesne pasmine goveda nastale su kao odgovor na povećane zahtjeve tržišta za mesom. Bitne karakteristike mesnih pasmina su: ranozrelost, brza dinamika rasta, povoljan omjer tkiva u trupu te dobra kvaliteta mesa. Kod ranozrelih pasmina dolazi do rane pojave puberteta što rezultira ranijim ulaskom u fazu intenzivnog razvoja i nakupljanja mišićne mase (Ivanković i Mijić, 2020.). Navedene pasmine goveda specijalizirane su za proizvodnju mesa te se kod njih osobina mliječnosti koristi isključivo za othranu teladi (Jakopović i sur., 2005.). Važno je da mesne pasmine imaju laka teljenja te da su prilagodljive na različite okolišne uvjete. Najpoznatije mesne pasmine velikog okvira su Charolaise (Slika 2.1.) i Blonde d'Aquitaine te su one pogodne za intenzivnu proizvodnju mesa zbog većih zahtjeva u pogledu menadžmenta, krmiva i smještajnih uvjeta. Od pasmina umjerene veličine okvira najznačajnije su Limousin, Angus, Hereford, Salers. Spomenute pasmine iziskuju skromniji menadžment, smještaj i krmiva te ostvaruju dobru kakvoću mesa uz niže dnevne priraste i završnu masu trupa. Pasmine manjeg okvira kao što je Highland, otporne su i prilagodljive na različite agroekološke uvjete no postižu manju masu (Ivanković i Mijić, 2020.). Kod brojnih mesnih pasmina, često se koriste sustavi međusobnih križanja kako bi se dobila grla boljih proizvodnih osobina, ali isto tako da bi se postigao heterozis učinak na potomstvu (Jakopović i sur., 2005.).

Slika 2.1. Bik pasmine Charolais

Izvor: https://www.aces.edu/wp-content/uploads/2021/03/ANR-2671-Bull-Scrotal-Circumference_032221L-A.pdf - pristupljeno 13.7.2021.

Tehnologije tova dijele se na ekstenzivne, intenzivne i poluintenzivne (Ivanković i Mijić 2020.). Odabir tehnologije tova ovisi i o ciljanoj kategoriji mesa te se time dijeli na tov teladi, tov junadi i tov goveda. Unutar navedenih tehnologija postoje različiti podtipovi koji su posljedica različitih prilagodbi u vezi dostupne krme, klimatskih uvjeta i dr. Primjena ekstenzivnih tehnologija opravdana je prisutnošću velikih pašnjačkih površina, dok je uvjet za provedbu intenzivnih tehnologija dostupnost veće količine voluminozne i koncentrirane krme. Ukoliko postoji interes potrošača za specifičan asortiman mesa kao što je meso volova i teleće meso, primjenjuju je specijalne tehnologije proizvodnje mesa koje su u većini slučajeva skuplje (Ivanković i Mijić 2020.).

Prema Ferizbegoviću i sur. (2009.) možemo razlikovati sljedeće tehnologije tova:

1. INTENZIVAN TOV TELADI MLIJEKOM

Telad se hrani mlijekom u trajanju od 2 mjeseca prilikom čega je za jedan kilogram prirasta potrebno utrošiti oko 10 litara mlijeka. Primjenom navedenog tova, telad se hrani *ad libitum* do postizanja tjelesne mase 100 – 110 kg.

2. TOV TELADI OD 140 – 160 KG

Navedenu tehnologiju tova karakterizira trajanje od 3 – 3,5 mjeseca uz postizanje prirasta od 1200 – 1300 g/dan. Telad se hrani mlijekom ili mliječnom zamjenom u količini od ukupno 300 – 450 litara, koncentratom *ad libitum* i sijenom (oko 135 kg).

3. PRODUŽENI TOV TELADI

Trajanje tova je od 5 – 5,5 mjeseci prilikom čega telad postigne mase od 200 – 220 kg, uz priraste 1200 – 1400 g/dan. Teladi se do odbića daju smanjene količine mlijeka, koncentrata i sijena. Nakon odbića slijedi intenzivna hranidba koncentratima *ad libitum* uz davanje sijena od

0,1 – 1 kg/dan. Za jedan kilogram prirasta potrebno je utrošiti oko 4 kg koncentrata i 0,5 kg sijena. Navedena tehnologija tova je pogodna za telad koja se kasnije tovi kao junad.

4. TOV JUNADI OD 400 – 450 KG

Tov se provodi od rođenja do 12 mjeseci života prilikom čega intenzitet prirasta ovisi o načinu hranidbe.

5. TOV JUNADI OD 450 – 550 KG

Navedena tehnologija tova se provodi kada tržište zahtjeva težu i masniju junad. Tov se provodi na način da se junad do mase od 300 kg hrani voluminoznim obrocima što rezultira prirastima od 700 – 800 g/dan, nakon čega se postepeno prelazi na polukoncentratne obroke s prirastima preko 1200 g/dan. Prilikom provedbe navedene tehnologije tova, junad se kolje u dobi od 16 – 18 mjeseci.

6. TOV JUNADI NA PAŠI

Trajanje tova iznosi obično od 3 – 5 mjeseci te se najčešće provodi od svibnja do listopada koristeći grla starija od godine dana. U navedenom periodu postižu se prirasti od 1000 – 1200 g/dan te se junad prihranjuje s 1 – 2 kg koncentrata.

7. TOV ODRASLIH GOVEDA

Trajanje tova iznosi od 3 – 3,5 mjeseci prilikom čega prirast čini isključivo masno tkivo. Provedbom navedenog tova goveda dobivaju oko 100 kg mase uz hranidbu voluminoznom krmom te eventualnim prihranjivanjem manjom količinom žitarica.

2.1. Proizvodnja i potrošnja goveđeg mesa u svijetu i Europi

Zadnjih desetljeća u svijetu je zabilježen kontinuirani rast proizvodnje i potrošnje goveđeg mesa. Na području Južne Amerike se odvija glavnina proizvodnje goveđeg mesa kojoj doprinose povoljni agroekološki uvjeti. Slijedi područje Azije koje karakteriziraju niži prinosi mesa po grlu (162 kg) u odnosu na Južnu Ameriku (237 kg) i Sjevernu Ameriku (350,4 kg) (Tablica 2.1.1). Najviši prinosi mesa po proizvodnoj jedinici postižu se u Sjevernoj Americi zahvaljujući korištenju mesnih genotipova i primjeni sintetskih hormona rasta u cilju stimulacije rasta goveda. Proizvodnja goveđeg mesa u Africi se zasniva na korištenju genotipova koji ostvaruju niže završne mase, ekstenzivnom uzgoju i nepovoljnim agroekološkim uvjetima iz čega proizlazi skromni udio u ukupnoj proizvodnji goveđeg mesa u svijetu. Na globalno tržište najveću količinu govedine plasira SAD, zatim slijede Brazil i Kina (Ivanković i Mijić, 2020.).

Tablica 2.1.1. Proizvodnja goveđeg mesa u Svijetu i po kontinentima u periodu od 1965. do 2019.

	Broj grla u proizvodnji (tis.)			*Proizvodnja mesa (tone)*		
Godina	1965.	1997.	2019.	1965.	1997.	2019.
SVIJET	191.607	268.262	324.518	31.856	54.747	68.313
EUROPA	72.579	62.847	39.987	10.917	13.155	10.584
Istočna	39.760	30.161	14.558	4.897	4.561	3.126
Sjeverna	7.484	7.038	6.444	1.404	1.906	2.045
Južna	6.893	9.436	6.749	1.165	2.257	3.609
Zapadna	18.440	16.211	12.234	3.450	4.430	3.609
AMERIKA	75.268	102.801	136.396	15.514	25.746	33.067
Sjeverna	45.629	41.741	63.350	9.824	12.668	13.737
Centralna	3.957	8.321	11.175	665	1.703	2.580
Južna	24.188	51.485	60.507	4.778	11.178	16.539
AZIJA	20.359	64.412	93.274	2.045	9.409	15.054
AFRIKA	14.132	25.907	41.654	2.071	3.977	6.555
OCEANIJA	9.267	12.292	13.206	1.307	2.458	3.051

Izvor: FAOSTAT (2021.)

Na području Europe najveća zastupljenost tovnih goveda je u predjelima Zapadne i Istočne Europe (Tablica 2.1.1.). Međutim, područje Sjeverne Europe postiže najveći prinos po proizvodnoj jedinici od oko 317 kg što je u usporedbi s područjem Istočne Europe više u prosjeku za oko 90 kg. Dvije trećine proizvodnje goveđeg mesa u Europi se temelji na uporabi mesnih pasmina goveda i njihovih križanaca dok je trećina izravno ili neizravno podrijetlom iz mliječnih stada. Nakon mljekarske proizvodnje, sektor proizvodnje i prerade goveđeg mesa je drugi prema prinosima u ukupnoj vrijednosti poljoprivredne proizvodnje (Ivanković i Mijić 2020.). Pet vodećih proizvođača goveđeg mesa u Europi su: Francuska, Njemačka, Italija, Španjolska i Irska (Tablica 2.1.2.).

Tablica 2.1.2. Deset vodećih proizvođači goveđeg mesa u Europi 2020. godine

Država	Količina mesa (tis. tona)	Goveda (u tis. grla)
Francuska	1.435	4.486
Njemačka	1.090	3.263
Italija	732	2.694
Španjolska	678	2.422
Irska	633	1.882
Poljska	559	1.851
Nizozemska	433	2.089
Belgija	255	783
Austrija	218	645
Švedska	141	434

Izvor: EUROSTAT (2021.)

Prema podacima iz FAOSTAT -a (2018.), prosječna potrošnja goveđeg mesa u svijetu je 9,1 kg/stanovniku. Najveća konzumacija zabilježena je na prostoru Sjeverne (36,1 kg) i Južne Amerike (30,46 kg), dok populacije na području Afrike i Azije konzumiraju znatno skromnije količine goveđeg mesa (5,96 kg; 4,72 kg). Na području Europe prosječna godišnja potrošnja je 13,59 kg što je manje u odnosu na države EU gdje je prosjek 14,31 kg. Najveća konzumacija zabilježena je na području Zapadne (17,08 kg) i Južne Europe (14,4 kg). Što se tiče pojedinačne potrošnje u državama, dominiraju Argentina s potrošnjom od 55,44 kg/stanovniku i Brazil s potrošnjom od 37,47 kg/stanovniku. U zemljama EU, stanovništvo Danske konzumira najviše goveđeg mesa (23,52 kg).

2.2. Proizvodnja goveđeg mesa u Hrvatskoj

U zadnjih pola stoljeća, govedarska proizvodnja u Republici Hrvatskoj prolazila je kroz dinamičnu prilagodbu geopolitičkom i tržišnom okruženju, socijalnim trendovima te inovacijama koje se događaju. Kretanje broja goveda u Republici Hrvatskoj u zadnjih šest godina prikazano je na grafikonu 2.2.1. Od ukupnog broja goveda, najveći udio čini kategorija krava (35%), potom teladi i mlade junadi (< 1 god. 35%), mlađe junadi (1 do 2 god. 22%), starije junadi (7%) te bikova i volova (1%). Godišnje se uveze oko 138 tisuća grla, ponajviše teladi za tov, a izveze se oko 50 tisuća grla, uglavnom utovljene junadi i starijih grla. Ukoliko sagledamo odnos broja stanovnika naspram broja goveda utvrđuje se omjer 9:1 (Ivanković i Mijić, 2020.). Prema podacima EUROSTATA za 2020. godinu, u Republici Hrvatskoj proizvedeno je 434 tisuća tona kravljeg mlijeka i 43,3 tisuće tona goveđeg mesa. Što se tiče pasminske strukture, dominiraju goveda simentalske pasmine (59,4 %), slijedi Holstein pasmina (21,7 %), mesne pasmine (5,8%), smeđe govedo (2, 2 %), izvorne pasmine (2,2%), križanci (8,4 %) i ostale mliječne pasmine (0,3 %) (HAPIH, 2021.).

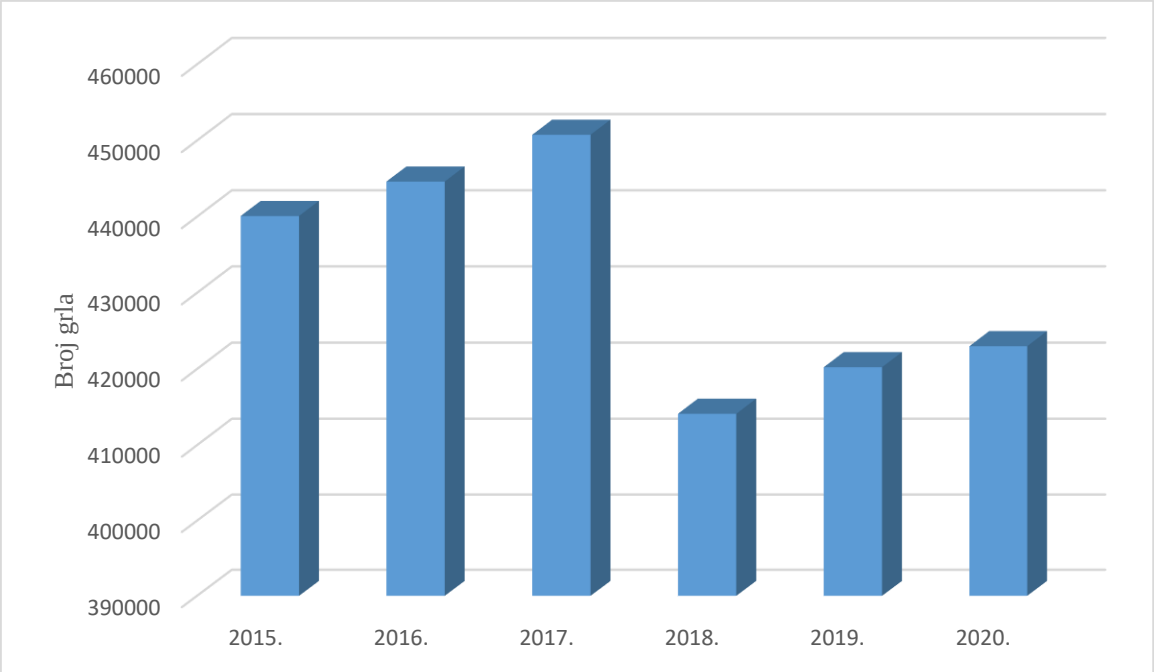

Grafikon 2.2.1. Broj goveda u Republici Hrvatskoj u razdoblju od 2015. – 2020. godine

Izvor: DZZS(2015. – 2019.), EUROSTAT(2020.)

Proizvodnja mesa goveda na prostoru Hrvatske ima dugu tradiciju te se zasniva na kapacitetima podneblja, genotipa i potrebama tržišta. Osamdesetih godina prošlog stoljeća bila je najvažnija poljoprivredna grana, a oko polovica tadašnje proizvodnje izvezilo se u zapadnoeuropske zemlje (Ivanković i Mijić, 2020.). Prepoznatljiv brend na europskom tržištu mesa bila je proizvodnja mlade junetine (baby beef) kojoj je kao genetska osnova služila simentalska junad odlične kvalitete mesa i visokog randmana (Senčić i sur., 2010.). Aktualne tehnologije tova u velikoj su mjeri usklađene sa simentalskim genotipom, no nisu u potpunosti kompatibilne sa suvremenim mesnim genotipovima, tehnologijama i potrebama tržišta što dovodi do redukcije biološke osnovice mesnog govedarstva. Proteklih godina, razvojem interesa za proizvodnju goveđeg mesa, introducirane su nove mesne pasmine goveda za sustave intenzivne proizvodnje i sustave proizvodnje krava – tele (Ivanković i Mijić, 2020.). Dominiraju pasmine umjerene veličine okvira, Angus i Hereford, te Charolais kao pasmina većeg okvira, no javljaju se i druge pasmine kao što su Limousin, Salers, Aubrac i dr. (HAPIH, 2021.).

Trendovi u potrošnji goveđeg mesa u velikoj mjeri oblikuju potrebe domaćeg tržišta i određuju kapacitete plasmana proizvoda (Ivanković i Mijić, 2020.). Prema DZZS (2019.) prosječna potrošnja goveđeg mesa po članu kućanstva u Hrvatskoj je iznosila 8 kg.

2.3. Meso goveda

Meso goveda je izrazito vrijedna namirnica koja se koristi u prehrani ljudi od davnina. Važnost goveđeg mesa proizlazi iz njegove nutritivne vrijednosti (Tablica 2.3.1.), sadržaja i strukture proteina, masti, minerala i vitamina. Nakon konzumacije navedene komponente bivaju resorbirane u probavnom sustavu čovjeka u obliku jednostavnih spojeva, aminokiselina, masnih kiselina, minerala i vitamina (Ivanković i Mijić, 2020.).

Tablica 2.3.1. Nutritivna vrijednost goveđeg mesa (u 100 g)

Hranjiva tvar	Goveđe meso
Voda (g)	60,3
Protein (g)	27,3
Mast (g)	11,4
Energija (kcal)	219
Pepeo (g)	1,02
Vitamin B12 (mg)	1,88
Vitamin B6 (mg)	0,753
Niacin	6,37
Riboflavin	0,27
Ca	19,00
Mg	20,00
Na (mg)	67,0
Zn (mg)	4,69
P (mg)	211,0
Fe (mg)	3,53

Izvor: USDA (2019.)

Goveđe meso se proizvodi tehnološkim procesom tova životinja koje su smještene u posebnim uvjetima držanja i hranidbe (Jakopović i sur., 2005.). Važno je napomenuti da kako bi se postigla željena kvaliteta mesa, goveđi trupovi ne smiju biti prekomjerno subkutano zamašćeni već masno tkivo treba biti infiltrirano intramuskularno (Ivanković i Mijić, 2020.). Završetkom tova od utovljenih životinja postupkom klanja dobivamo različite kategorije mesa koje se mogu svrstati u tri glavne skupine: teletina, junetina i govedina (Jakopović i sur., 2005.).

Teletina je meso podrijetlom od grla starih do osam mjeseci koja su najmanje tijekom prva 2 – 3 mjeseca života hranjena mlijekom ili mliječnim nadomjeskom, voluminoznom i krepkom krmom. Navedenu vrstu mesa karakterizira svijetloružičasta boja, mekoća, sočnost i niska kalorijska vrijednost. Sastoji se od ≈ 75% vode, ≈ 22 % proteina, ≈ 1% minerala i 2% masti koja mesu daje bogatu aromu i pomaže pri apsorpciji vitamina A, D, K i E (Ivanković i Mijić, 2020.).

Junetina predstavlja najvažniju skupinu goveđeg mesa na tržištu jer se u ovoj proizvodnji najviše koristi proces rasta, te se na kraju dobiva prepoznatljivo meso koje se može pripremiti na različite načine. Kao rezultat tova dobivamo meso mlađe ili starije junadi koje sadrži veće ili manje udjele masnog tkiva (Jakopović i sur., 2005.). Meso se dobiva od životinja starosti 12 do 24 mjeseca koje se nikada nisu telile. Meso je svijetlo do tamno ružičaste boje, vrlo sočno,

mekano i kalorično. Fiziološka starost mesa određuje se na temelju stupnja okoštavanja hrskavice, presjeka kostiju, strukture i boje mišićnog i masnog tkiva.

Govedina je meso koje se dobiva od grla starijih od dvije godine, izraženije je granulacije, tamno crvene boje, veće tvrdoće, žute boje masnog tikva i većeg stupnja okoštavanja hrskavice (Ivanković i Mijić, 2020.). Navedena kategorija mesa se najvećim djelom koristi u industriji prerade (Jakopović i sur., 2005.).

Slika 2.3.1. Teletina

Izvor: https://www.coolinarika.com/namirnica/teletina-405c5782-610e-11eb-9bde-0242ac12002e - pristupljeno: 29.8.2021.

Slika 2.3.2. Junetina

Izvor: https://petason.hr/proizvodi/svjeze-meso/junetina/ - pristupljeno: 29.8.2021.

Slika 2.3.3. Govedina
Izvor: https://hr.andamanislandtrip.com/koristi-i-stete-od-govedine-za-tijelo-169 - pristupljeno: 29.8.2021.

Prema Hoffmanu (1994.) kakvoću mesa definiramo kao sumu čimbenika koji uključuju senzorička, nutritivna, higijenska i toksikološka te tehnološka svojstva.

Senzorička kakvoća podrazumijeva određivanje izgleda, boje, mekoće, sočnosti, arome, mirisa i tekstura. Tako kupac, prilikom odabira mesa najčešće posebnu pažnju usmjerava na boju, sposobnosti zadržavanja vode i mekoću (Civille i Liski, 1975.).

Nutritivna vrijednost mesa proizlazi iz njegovog kemijskog sastava što podrazumijeva vrstu i količinu proteina, masti, ugljikohidrata, vitamina, minerala te njegovu iskoristivost i probavljivost u ljudskom organizmu. Potrošači u razvijenim zemljama preferiraju meso s većim sadržajem proteina, esencijalnih vitamina i minerala, a izbjegavaju meso sa visokim sadržajem masti (Ivanković i Mijić, 2020.).

Higijenska i toksikološka ispravnost mesa podrazumijeva odsustvo bilo kakvog štetnog kontaminata u mesu kao što su bakterije, gljivice, spore, rezidue lijekova i drugo (Ivanković i Mijić 2020.).

Tehnološka svojstva se odnose na pogodnost mesa u preradi, a najvažnija su čvrstoća i struktura mesa, boja i pH vrijednost, sadržaj i stanje kolagena, sadržaj i sposobnost vezanja vode, odlike u kuhanju i pečenju i dr. (Ivanković i Mijić 2020.).

2.3.1. Kvalitativna svojstva goveđeg mesa

Boja je bitan indikator kakvoće mesa jer većinu potrošača upućuje na svježinu mesa. Brojni potrošači preferiraju svijetloružičastu do sjajno crvenu boju, dok ih tamno obojeno meso asocira na stare i bolesne životinje. Boja goveđeg mesa, primarno je uvjetovana koncentracijom pigmenta te drugim čimbenicima genetske i negenetske prirode (Ivanković i Mijić, 2020.). Glavni mišićni pigment je mioglobin koji igra važnu ulogu u fiziologiji mišića, jer se na njega veže kisik. U prisutnosti kisika, mioglobin se transformira u dva različita pigmenta: oksimioglobin i metmioglobin. Također, mioglobin se pod utjecajem različitih faktora može transformirati i u nitrozilmioglobin, karboksimioglobin, sulfmioglobin i dr. (Ilančić, 1975.).

Prema istraživanju koje su proveli Faustman i Cassens (1990.), na brzinu promjene boje i nakupljanje metmioglobina utjecaj imaju: brzina difuzije i potrošnje kisika, autooksidacija pigmenta u prisutnosti kisika i brzina redukcijske aktivnosti metmioglobina.

Drugi važan pigment koji utječe na boju mesa je hemoglobin koji u mesu prilikom klanja čini 20 – 30 % od ukupnih pigmenata. Prilikom oksidacije prelazi u oksihemoglobin, odnosno methemoglobin koji je odgovoran za tamniju boju mesa (Ilančić, 1975.). Prema istraživanju koje je proveo Hood (1980.) utvrđeno je da je tip mišića jedan od glavnih faktora koji kontroliraju brzinu promjene boje mesa prilikom izlaganja kisiku. Navedenim istraživanjem je utvrđeno da je *longissimus* vrlo stabilan mišić, a *psoas major* nestabilan. Navedeno je u suglasju s istraživanjem koje su proveli Klont i sur. (1998.) na ova dva mšića u teladi.

Značajan utjecaj na boju mesa ima i sam tip hranidbe koji se provodi u tovu. Prema Lawrieju i sur. (2006.), tamnija boja mesa uočena je kod goveda hranjenih na pašnjacima u odnosu na goveda u intenzivnom načinu držanja.

pH vrijednost je izrazito bitan indikator kakvoće mesa jer utječe na boju, nježnost i okus te na sposobnost vezanja vode prirode (Ivanković i Mijić, 2020.). Prema Honikelu i Kimu (1985.) pH vrijednost mišića u trenutku klanja iznosi oko 7,0. Nakon klanja pH vrijednost u mišićima se u roku od 24 h *post mortem* spusti na vrijednosti manje od 5,7. Približavanjem pH vrijednost od 5,4, endogene proteinaze (katepsin B i L) se aktiviraju i počinju omekšavati meso (Spanier i Miller 1993.). Navedeni pad pH vrijednosti je rezultat *post mortalnih* biokemijskih procesa koji se događaju u trupu goveda nakon klanja. Jedan od najvažnijih procesa je anaerobna razgradnja glukoze koja rezultira stvaranjem i akumuliranjem mliječne kiseline. Anaerobna glikoliza direktno ovisi o rezervama mišićnog glikogena neposredno prije klanja te o uvjetima u kojima se taj proces odvija 24 h *post mortem* (Ivanković i Mijić, 2020.). Ukoliko su životinje prije klanja izložene stresu i nemaju dovoljne zalihe glikogena u mišićima dolazi do ometanja procesa anaerobne glikolize što rezultira pH vrijednošću mesa višom od 5,8 (Viljoen i sur., 2002.). Spori i nedovoljan pad pH vrijednosti dovodi do pojave tzv. tamnog, tvrdog i suhog mesa u čijem mišićnom tkivu nema dovoljno mliječne kiseline, a samim time konačna pH vrijednost ostaje visoka što uzrokuje brže kvarenje (Ivanković i Mijić, 2020.). Prema Lawrenceu i Fowleru (2002.) kod nekih pasmina goveda nakon klanja dolazi do izlučivanja visokih koncentracija katekolamina čime se potiče brza potrošnja mišićnih energetskih rezervi, nakupljanje mišićne kiseline, brzi pad pH i brzi razvoj *rigora mortisa*. U navedenom slučaju razvija se blijedo, meko i vodenasto meso nepoželjnih senzornih svojstava.

Sposobnost vezanja vode u mesu se odnosi na sposobnost mišića da *post mortem* zadrži vodu spontano i pod utjecajem vanjskih čimbenika kao što su gravitacija ili termička obrada. Nakon postupka klanja, količina vode u mesu podložna je promjenama ovisno o procesima u mišićnom tkivu ili postupcima kojima je meso izloženo prilikom prerade. Jedan od problema koji se javlja kod prerade je veliki gubitak tekućine iz svježeg mesa što rezultira brojnim ekonomskim gubicima i mesom loših prerađivačkih osobina (Karolyi, 2004.).

Električna provodljivost je indirektna mjera gubitka vode ili mišićne mekoće koja se javlja kao posljedica napuknuća struktura membrane, što dovodi do prolaska vode između intracelularnog i ekstracelularnog prostora (Pliquett i sur. 1990.). Prema Byrneu i sur. (2000.) denaturacijom mišićnog tkiva, povećava se vrijednost električne provodljivosti.

3. Ocjena trupova na liniji klanja

Kako bi se uvažila dobrobit životinja, klanje goveda treba se provesti prema pravilima sukladno legislativnim normama. Neposredno prije klanja vrši se omamljivanje pneumatskim pištoljem s penetrirajućim klinom koji se postavlja na sjecište zamišljenih pravaca koji spajaju oči i bazu rogova. Nakon omamljivanja slijedi proces iskrvarenja koji se provodi u visećem položaju trupa presijecanjem velikih vratnih krvnih žila (*vena jugularis* i *arteria carotis*). Provedba iskrvarenje završava dekapitacijom nakon čega slijedi klaonička obrada trupova. Klaonički obrađen trup je trup bez kože, glave i distalnih dijelova nogu, bez organa prsne, trbušne i zdjelične šupljine (osim bubrega i bubrežnog masnog tkiva), bez spolnih organa i vimena, bez leđne moždine duž kanala kralježnice, s pripadajućom ušnom markicom koja je u odgovarajućoj privjesnici obješena za prednju nogu. Nakon primarne obrade trupa, tople polovice se kategoriziraju sukladno važećoj zakonskoj legislativi sustavom EUROP klasifikacije goveđih polovica (Ivanković i Mijić, 2020.).

Slika 3.1. Klaonički obrađena goveđa polovica

Izvor: Osobna arhiva

3.1. Sustav vrednovanja goveđih polovica na liniji klanja

Životinje za proizvodnju mesa, kao i njihovi trupovi, razlikuju se zbog različitih utjecaja kao što su način uzgoja, hranidba, proizvodni sustavi te drugih čimbenika (Lipavić, 2018.). Trupovi se razvrstavaju na temelju dobi i fiziološkog stanja u tri osnovne skupine: telad, junad i starija grla. Unutar navedenih skupina, utvrđuju se sljedeće kategorije (Ivanković i Mijić 2020.):

- V – telad koja je u trenutku klanja nisu starija od 8 mjeseci
- Z – mlada junad koja je u trenutku klanja u dobi od 8 do 12 mjeseci
- E – jedinke ženskog spola koje su u trenutku klanja starije od 12 mjeseci a nisu se telile
- A – jedinke muškog spola koje su u trenutku klanja stare 12 do 24 mjeseca
- B – jedinke muškog spola koje su u trenutku klanja starije od 24 mjeseca
- C – kastrirane jedinke muškog spola
- D – jedinke ženskog spola koje su u trenutku klanja starije od 24 mjeseca ili nakon što su se otelile

Kako bi se utvrdila kakvoću trupova na osnovi stvarne količine mesa provodimo postupak razvrstavanja (kategorizacija i klasifikacija). Provedbom navedenih postupaka, ocjenjuje se s jedne strane uzgojno proizvodni rad proizvođača životinja, a s druge strane kakvoća i vrijednost klaoničkih obrađenih trupova dobivenih od tih životinja. Sustav razvrstavanja klaonički obrađenih trupova omogućio je ostvarenje boljeg pregleda trgovine i prometa, stvaranje osnove za objektivno određivanje proizvodnih ciljeva prema stupnjevima vrijednosti klaonički obrađenih životinja, kao i usmjeravanje proizvođača prema zahtjevima tržišta. U Republici Hrvatskoj je u cilju uvođenja jedinstvenih mjerila za objektivno razvrstavanje goveđih trupova, objavljen 2004. godine prvi propis u području razvrstavanja koji se uključio sva opća pravila za jedinstveno razvrstavanje goveđih trupova (E, U, R, O, P sustav) (KOLK, 2020.). Navedeni sustav je dvodimenzionalan; na jednoj osi je opisana konformacija trupa, a na drugoj razina površinskog masnog tkiva. Os konformacije trupa podijeljena je na pet klasa (E, U, R, O i P) s dodatnom opcijom S za superiorne mesnate trupove, dok klasa P predstavlja trupove slabo razvijene mišićne komponente. Os masnog tkiva se sastoji od pet klasa koje se numerički označavaju od 1 za nisku prekrivenost trupa masnim tkivom do 5 za vrlo masne trupove Također u Republici Hrvatskoj se pri razvrstavanju goveđih trupova u klase ne koristi klasa S (Lipavić, 2018.).

Prema Pravilnik o razvrstavanju i označivanju goveđih, svinjskih i ovčjih trupova te označivanju mesa koje potječe od goveda starih manje od 12 mjeseci (NN 71/2018) pri razvrstavanju goveđih trupova svaka klasa i svaki razred stupnja zamašćenosti razdijeljen je u tri potklase odnosno podrazreda pri čemu se uz oznaku klase odnosno razreda dodjeljuju dodatne oznake:

- »+« ako je konformacija trupa odnosno zamašćenost bolja;
- » – « ako je konformacija trupa odnosno zamašćenost slabija;
- »=« ako je konformacija trupa odnosno zamašćenost jednaka toj klasi ili razredu, a trup se ne može svrstati u višu ili nižu potklasu odnosno podrazred

Tablica 3.1.1. Klasiranje goveđih trupova i polovica temeljem konformacije trupa

Klasa	Obilježja trupa	Osnovni dijelovi trupa
E	Svi profili su izuzetno visoko zaobljeni; izrazita zaobljenost mišića	But: izrazito popunjen i oblikovan, visoko zaobljen Leđa: vrlo široka, izrazito izbočena po cijeloj dužini Lopatica: izrazito popunjena i oblikovana
U	Profili dobro u cijelosti zaobljeni; vrlo dobra punoća mišića	But: dobro oblikovan i popunjen Leđa: široka i izbočena Lopatica: oblikovana i popunjena
R	Profili u cijelosti ravni; dobra punoća mišića	But: dobro razvijen Leđa: izbočena ali manje široka Lopatica: srednje razvijena
O	Profili su ravni do udubljeni; osrednja punoća mišića	But: srednje razvijen Leđa: srednje razvijena Lopatica: srednje razvijena do skoro ravna
P	Svi profili vrlo udubljeni; slaba punoća mišića	But: slabo razvijen Leđa: uska s izbočenim kostima Lopatica: ravna s izbočenim kostima

Izvor: NN 71/2018.

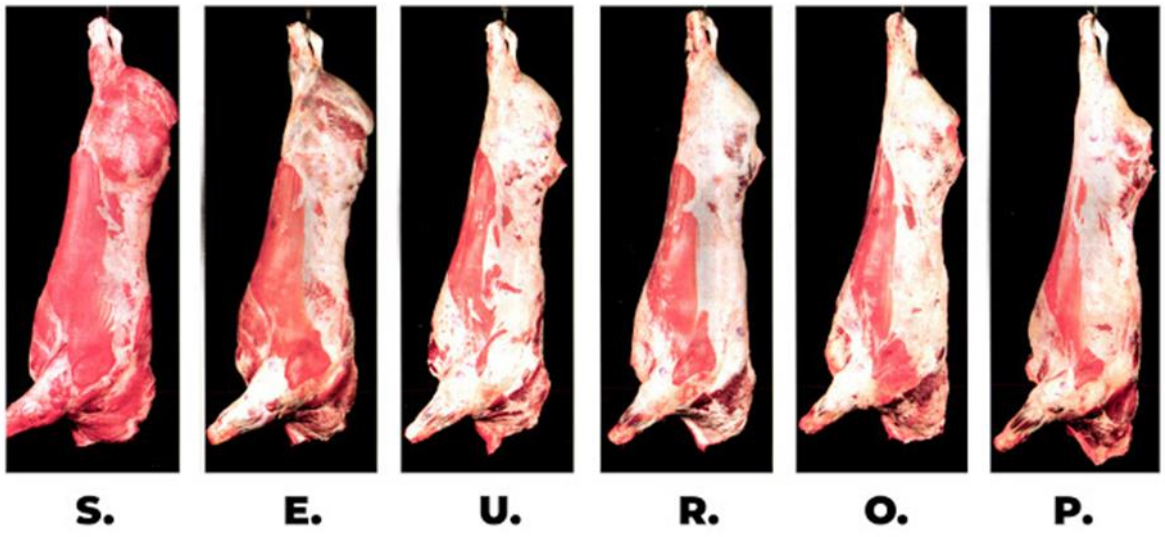

Slika 3.1.1. Klase goveđih trupova

Izvor: https://www.bloc-notes-culinaire.com/2020/09/le-classement-europ-des-viandes-de-boucherie.html - pristupljeno: 2.8.2021.

Tablica 3.1.2. Stupnjevanje prekrivenosti masnim tkivom goveđih trupova

Razred	Na površini trupa	U šupljinama trupa
1	Neznatna prekrivenost trupa masnim tkivom	Bez vidljivih naslaga masnog tkiva u prsnoj šupljini
2	Tanki sloj masnog tkiva na trupu a mišići gotovo svugdje vidljivi	Međurebreni mišići unutar prsne šupljine jasno vidljivi
3	Mišići su, osim na butu i lopatici, gotovo svugdje prekriveni masnim tkivom	U prsnoj šupljini vidljive neznatne naslage masnog tkiva, međurebreni mišići blago prorašteni masnim tkivom
4	Mišići na butu i lopatici samo su mjestimično vidljivi između naslaga masnog tkiva a nešto izrazitije naslage su na prsima	U prsnoj šupljni vidljive naslage masnog tkiva, međurebreni mišići prorašteni masnim tkivom
5	Trup u cijelosti prekriven masnim tkivom a deblje naslage masnog tkiva vidljive su na prsima	U prsnoj šupljini vidljive velike naslage masnog tkiva, međurebreni mišići jako prorašteni masnim tkivom

Izvor: NN 71/2018.

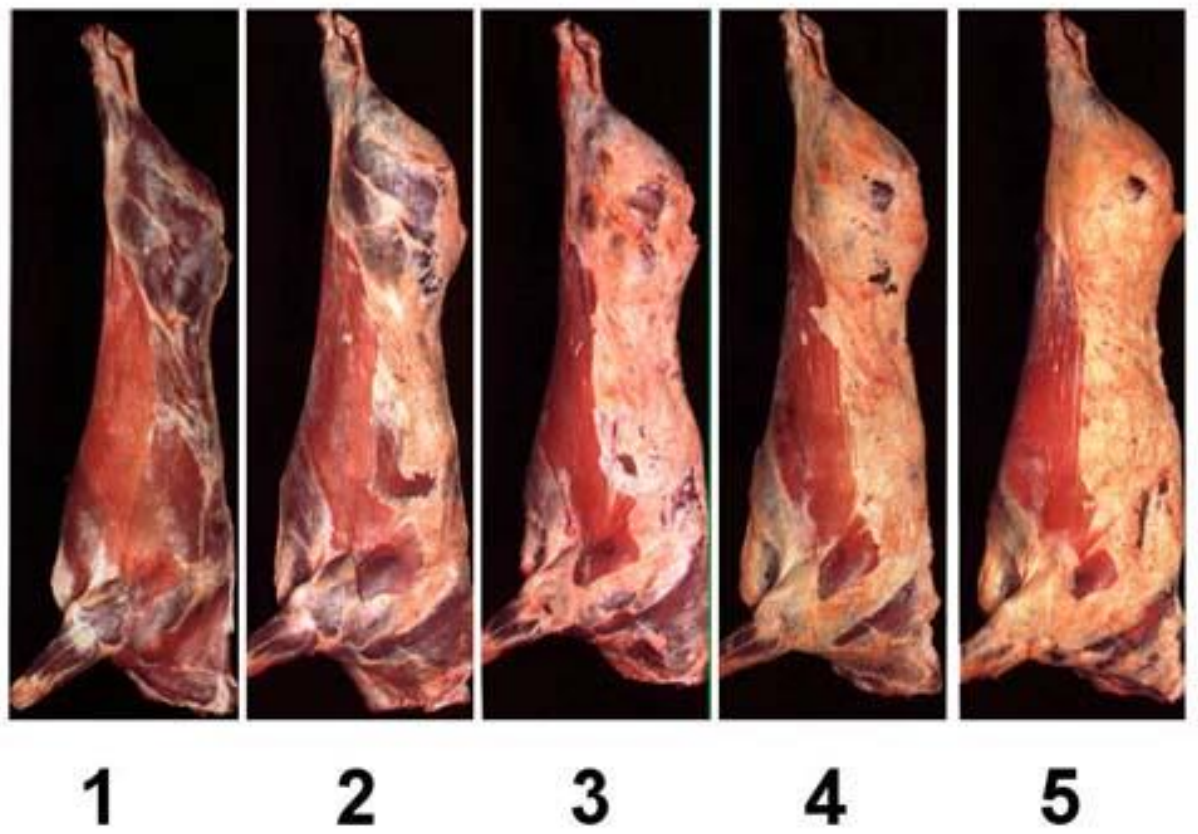

Slika 3.1.2. Stupnjevanje prekrivenosti masnim tkivom goveđih trupova

Izvor: https://dunbiafarmers.com/members-area/livestock/beef-grading/carcass-fat-classification/ - pristupljeno: 4.8.2021.

Postupak klasiranja provode ovlaštene i akreditirane osobe, a nakon što obave klasiranje, dodijeljenu EUROP klasu i ostale podatke bilježe u središnji informacijski sustav, tiskaju etiketu i lijepe na obrađeni trup goveda (Ivanković i Mijić, 2020.).

Prema Pravilniku NN 71/2018 oznake kojima se označavaju goveđi trupovi moraju sadržavati sljedeće podatke:

- serijski broj oznake,
- posjednik životinje,
- životni broj životinje,
- datum rođenja životinje,
- identifikacijski broj klasifikatora, te
- država/države rođenja, tova i klanja životinje

3.2. Prikaz podataka s linije klanja u Republici Hrvatskoj

Prema podacima iz grafikona 3.2.1. najviše goveđih trupova u proteklih pet godina je klasirano 2016. godine. U odnosu na navedenu godinu, 2020. godine klasirano je za oko 20 000 trupova manje. Period od 2017. – 2019. godine karakterizirao je gotovo konstantan broj klasiranih trupova od oko 183 000.

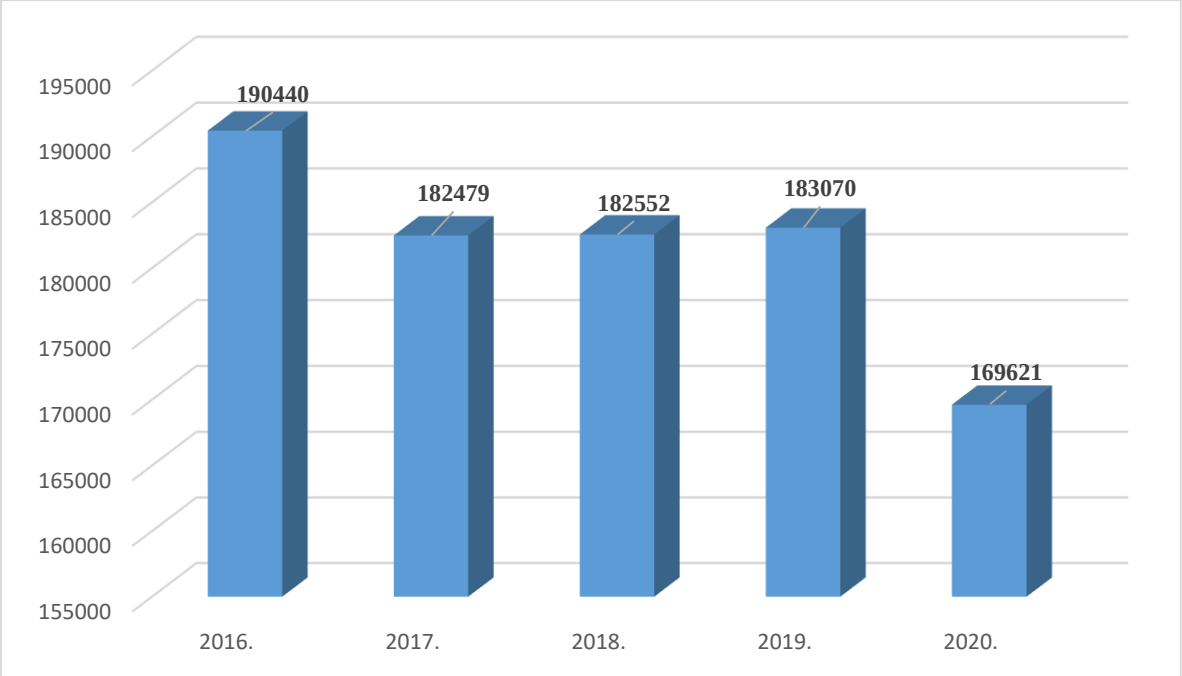

Grafikon 3.2.1. Ukupni broj klasiranih goveđih trupova za period 2016. – 2020. godine
Izvor: KOLK, 2020.

Ukupna masa klasiranih goveđih trupova u periodu od 2016. - 2020. godine varira. Prema podacima iz grafikona 3.2.2. najveća ukupna masa goveđih trupova je postignuta 2019. godine i iznosila je 45 416 t. Najmanja masa klasiranih goveđih trupova zabilježena je 2017. godine i iznosila je 42 564 t.

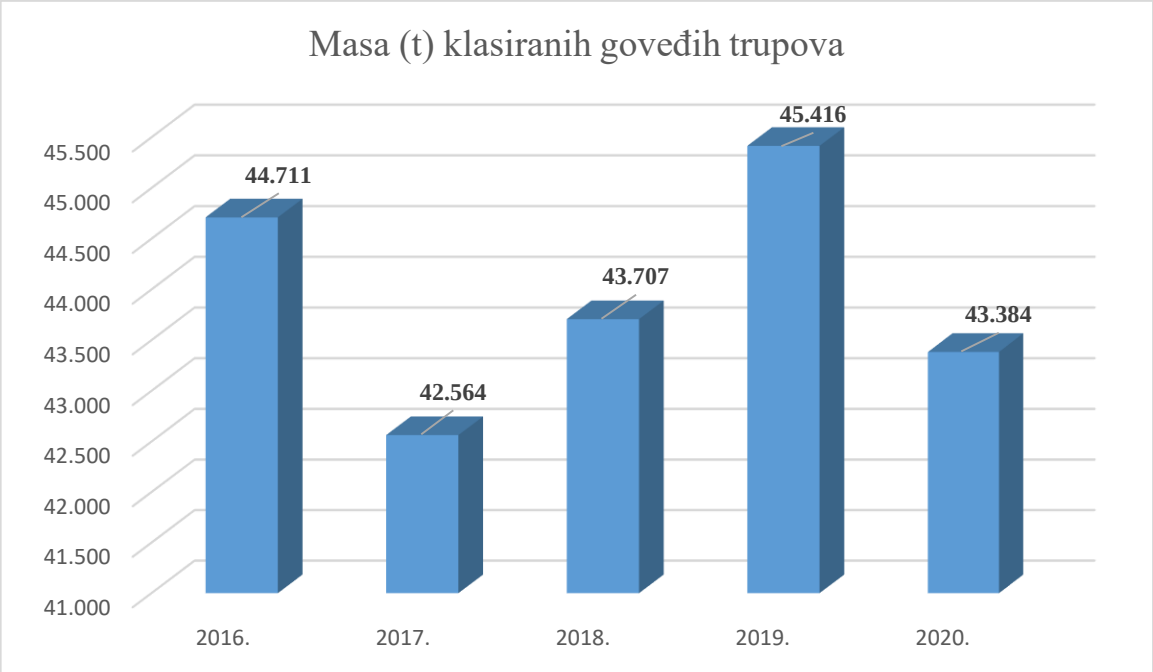

Grafikon 3.2.2. Ukupna masa (t) klasiranih goveđih trupova za period 2016. – 2020. godine
Izvor: KOLK, 2020.

4. Parametri procjene uspješnosti tova i udjela tkiva u trupu

4.1. Randman

Prema Uremoviću (2002.) randman je varijabla kojom se ocjenjuje učinak proizvodnje goveđeg mesa nakon klanja randmanom hladnih i toplih polovica. Randman se izračunava pomoću formule:

$$Randman, \% = \frac{masa\ polovica, kg}{\check{z}iva\ masa, kg} \times 100$$

- masa polovica predstavlja polovice trupa, s bubrezima, a bez glave, donjeg dijela nogu ispod skočnog i koljenog zgloba, kože, repa, krvi i sadržaja prsne, zdjelične i trbušne šupljine
- živa masa je tjelesna masa junadi prije klanja

Vrijednost randmana raste pri tjelesnim masa od 100 kg do 400 kg žive mase, a nakon toga ostaje ista. Na randman utječe mnogo čimbenika:

- Pristup životinje hrani i vodi prije klanja što snižava randman
- Transport – veći randman kod duljeg transporta
- Utovljenost grla – utovljeno grlo iste mase kao manje utovljeno grlo ima veći randman
- Način klaoničke obrade – zadržava li se ili uklanja zdjelični i bubrežni loj (razlika i do 6%)
- Randman hladnih polovica je za oko 2% manji od randmana hladnih polovica
- Pasmina – mesne pasmine imaju veći randman
- Vrsta hrane

Prilikom određivanja randmana razlikujem topli i hladni randman. Topli randman predstavlja odnos mase toplih polovica kod kojih su odstranjeni klaonički nusproizvodi i mase životinje neposredno pred klanje. Nakon klanja i klaoničke obrade polovice se smještaju u komoru za hlađenje gdje dolazi do određenih gubitaka u težini uslijed cijeđenja vode i krvi iz polovica. Navedeni gubitak se zove kalo hlađenja i iznosi 1,5 – 2 %. Hladni randman se dobije kada se od toplog randmana oduzme kalo hlađenja (Senčić i sur., 2010.).

4.2. Debljina potkožnog masnog tkiva

Masti su energijom najbogatija komponenta mesa koja sadrži vitamine topive u mastima i esencijalne masne kiseline (Feiner, 2006.). Prema Webbu (2003.) masti su lokalizirane na četiri anatomske lokacije: unutar tjelesnih šupljina, ispod kože (potkožna), između mišića (intermuskularna) i unutar mišića (intramuskularna). Važnost masnog tkiva proizlazi iz njegovog utjecaja na okus, sočnost i vizualne karakteristike mesa. Meso s malim sadržajem masnog tkiva kod potrošača ima lošiju organoleptičku ocjenu. Također, preveliki udio masnog tkiva nije poželjan jer je preveliki unos masnoća povezana s pojavom nekih bolesti (kardiovaskularne bolesti, pretilost i rak) (Cobos i Diaz, 2015.). Na sam okus masnog tkiva značajan utjecaj imaju oleinska, linoleinska i stearinska masna kiselina. Masno tkivo je najčešće bijele boje s mogućnošću pojave nijansa žute boje kod starijih grla te grla na paši (Feiner, 2006.).

Rastom i razvojem životinje najprije se popunjavaju masni depoi bubrežnog loja, potom intermuskularni i potkožni te na kraju intramuskularni masni depoi. Potkožni i intermuskularni masni depoi nastavljaju stvaranje novih masnih stanica i popunjavaju lipidima postojeće masne stanice. U završnoj fazi tova intermuskularni masni depoi završavaju svoj razvoj i popunjavaju masne stanice (Hammond, 1955.).

Debljina potkožnog masnog tkiva je najčešća mjera ekstramuskularne masti na trupu i izravno utječe na klasifikaciju trupova goveda. S povećanjem debljine potkožnog masnog tkiva, smanjuje se iskoristivost trupa zbog većeg obrezivanja suvišnog masnog tkiva prilikom obrade i rasijecanja što rezultira manjim prinosima maloprodajnog proizvoda. Pretjerano niske količine potkožnog masnog tkiva na govođem trupu također su nepoželjne jer se povećava rizik od pojave tzv. hladnog skraćivanja pri hlađenju trupova u hladnjači što dovodi do povećane žilavosti mesa. Optimalni raspon za debljinu potkožne masti je od 0,5 do 1,3 cm (Troxel i Gadberry, 2009.), a mjeri se na klaonički obrađenim polovicama nakon 24-satnog hlađenja polovica (4°C) u visini 12. i 13. rebra na ¾ udaljenosti od medijalne linije kralježnice (slika 4.2.1.; Boggs i sur., 1998). Debljina potkožnog masnog tkiva određena je različitim čimbenicima, kao što su pasmina, dob, hranidba i tehnologija tova.

Slika 4.2.1. Mjesto mjerenja debljine potkožnog masnog tkiva
Izvor: Boggs i sur., 1998

4.3. Mramoriranost

Mramoriranost mesa važna je sastavnica arome, sočnosti i mekoće mesa, a određuje je sadržaj intramuskularne mast koja se odlaže unutar intramuskularnih masnih stanica. Prema Pethicku i sur. (2004.) razvoj intramuskularnog masnog tkiva događa se nakon određene dobi, zbog održavanja ili pada sinteze masti u kombinaciji s usporavanjem rasta mišića starijih životinja.

Ocjene stupnja mramoriranosti izražavaju se opisno i kreću se od „nemramorirano“ do „obilno mramorirano“ te ocjenama, ovisno o sustavu 0-9 (Australija) ili 0-12 (Japan i SAD). Nemramorirano meso predstavlja mišićno tkivo s manje od 2% intramuskularne masti, a obilno mramorirano mesa ima više od 10% masnog tkiva u *m. longissimus dorsi*. Ocjena stupnja mramoriranosti još nije uvedena u zemljama Europske unije u odnosu na naprimjer SAD, Australije i Japan. Liu i sur. (2020.) nakon provedenog istraživanja na području Europe i korištenja australskog sustava ocjene mramoriranosti (slika 4.3.1.) navode kako su europski sustav ocjene konformacije i stupnja prekrivenosti masnim tkivom trupova goveda u niskoj korelaciji s mramoriranošću. Ujedno, zaključuju kako postoji potreba uvođenja sustava ocjene mramoriranosti govođeg mesa u Europi u cilju osiguravanja dodatni informacija o kvaliteti govođih trupova.

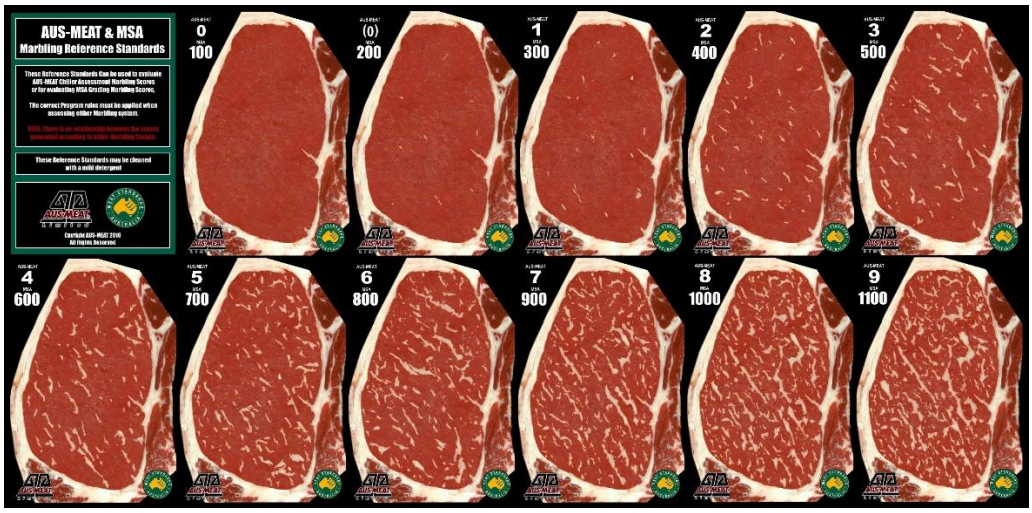

Slika 4.3.1. Ocjene mramoriranosti govođeg mesa u Australiji

Izvor: https://www.australianbutchersguild.com.au/butchery/marbling-meat/ - pristupljeno 17.09.2021.

U istraživanjima koje su proveli Berry (1993.) i Killinger (2004.) utvrđeno je da se tvrdoća govođeg mesa povećava pri manjoj mramoriranosti mesa. Navedeno je u suglasju s istraživanjem koje su proveli Nishimura i sur. (1999.) gdje je utvrđeno da je razvoj intramuskularne masti u leđnom mišiću narušio strukturu vezivnog tkiva, što je dovelo do veće mekoće mesa pri većim ocjenama mramoriranosti.

Kad se govori o mramoriranosti mesa goveda kao specifična slučaj navodi se japanska pasmina goveda Wagyu. Osnovna karakteristika mesa Wagyu goveda je visoka mramoriranost radi koje dostiže najviše cijene u svijetu (slika 4.3.2.). Mišićno tkivo je prožeto slojevima masnoće koja sadrži visoki udio mononezasićenih masnih kiselina. Spomenuta struktura mesa daje specifičan okus, sočnost i nježnost, tzv. osjećaj „topljenja u ustima“ (Ivanković i Mijić, 2020.).

Slika 4.3.2. Meso Wagyu goveda

Izvor: https://simple.wikipedia.org/wiki/Wagyu_beef - pristupljeno: 6.8.2021.

4.4. Površina dugog leđnog mišića

Površina dugog leđnog mišića podrazumijeva određivanje površine presjeka dugog leđnog mišića između 12. i 13. rebra (Osório i Osório, 2005. cit. Ferreira i sur., 2012.). Ukoliko se uzima na presjeku između drugih rebara onda je to potrebno naglasiti. Navedena mjera se najčešće uzima za procjenu ukupnog udjela mišića u trupu te se koristi za izračun mesnatosti trupa. Prema Williamsu (2002.) površina dugog leđnog mišića je izravno povezana s količinom mišića u trupu, osobito u slabinama i butu i treba ga uzeti u obzir u istraživanjima kao pokazatelj razvoja mišićnog tkiva i visoko vrijednih dijelova trupa. Optimalnim površinama MLD-a smatraju se one od 70 do 96 cm^2. S povećanjem površine dugog leđnog mišića raste prinos mesa pa bi kod goveda tjelesnih masa između 550 i 900 kg za svako povećanje tjelesne mase od 100 kg površina MLD-a trebala rasti za 1,6 do 1,9 cm^2 (Troxel i Gadberry, 2009.). Površina dugog leđnog mišića određena je različitim čimbenicima kao što su dob, spol, pasmina pa i polovici trupa. Veće površine MLD-a na desnim u odnosu na lijeve goveđe polovice navode Waylan i sur. (1997.), no manje površine MLD-a desne polovice goveda navode Unruh i sur. (1997). Manje površine nalazimo kod mlađih grla, ženskog spola te pasmina koje nisu primarno namijenjene proizvodnji mesa.

Mjerenje površine dugog leđnog mišića može se provesti različitim metoda koje se razlikuju obzirom na brzinu, preciznost i pouzdanost.

Iscrtavanje površine dugog leđnog mišića na pergamenti papir i određivanje iscrtane površine korištenjem planimetra primjenjuje se u znanstveno-istraživačke svrhe već desetljećima. Ovu metodu još 1937. godine uvodi D. L. Mackintosh. Naumann (1951) je uveo metodu vrlo sličnu Mackintosh-u, no umjesto permanentnog papira koristi prozirni papir za precrtavanje koji se koristio u slikarstvu što je uvelike olakšalo postupak precrtavanja, Nakon toga, ovo postaje raširena i vrlo prihvaćena metoda određivanja površine MLD-a goveda. Primjena ove metode kao pouzdane ostala je do današnjih dana te je u svojim istraživanjima koriste brojni znanstvenici, kao naprimjer Steiner i sur. (2003), Karolyi i sur. (2006), Yanez i sur. (2006), Mojto i sur. (2009), Ferreira i sur. (2012) i drugi.

Primjenu najveće dužine i najveće širine za određivanje površine MLD-a predstavio je još 1939. godine Hirzel. Metoda podrazumijeva određivanje najveće duljine i širine MLD-a u okomitom odnosu jedno prema drugom. Do sada je ova metoda uspoređivanja s drugim

metodama u istraživanju Standford i sur. (1995.), Bergen i sur. (2003), Yanez i sur. (2006.), Ferreira i sur. (2012.) i drugi.

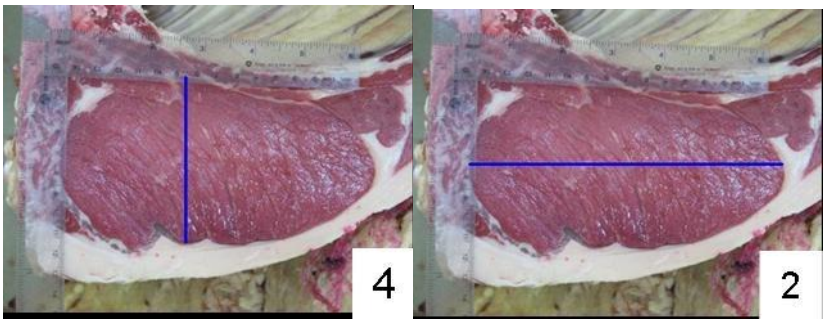

Slika 4.4.1. Određivanje najveće duljine i širine površine MLD-a
Izvor: http://www.omafra.gov.on.ca/english/livestock/beef/news/vbn0209a1.htm - pristup 17.09.2021.

Metoda mreže s točkama (engl. *USDA ribeye grid*) tradicionalno se od 1968. godine koristi za određivanje površine MLD-a goveda u SAD-u. Folija s mrežom se nasumično postavlja na MLD. Potom se broje sve točke koje se nalaze unutar iscrtane linije MLD-a. Potom se broje sve točke koje graniče s iscrtanom površinom MLD-a i njihov broj podijeli s dva. Potom se zbrajaju točke iz prvog i drugog brojanja i umanje za 1. U Americi obzirom na izražavanje površina u inčima dobivena vrijednost se množi s 0,1 i podrazumijeva površinu MLD-a u inčima kvadratnim. U osnovi ova metoda koristiti Pickov teorem koji u Euklidskoj geometriji služi za računanje površine mnogokuta koji se nalazi u pravokutnom koordinatnom sustavu te kojemu su vrhovi točke s cjelobrojnim koordinatama. Razvoj digitalne i kompjutorske tehnologije potiskuje ovu metodu iz upotrebe u klaonicama. Naime, pored točnosti, u klaonicama je vrlo važno da se informacije mogu dobiti na praktičan i brz način te da su ekonomične (Yanez i sur., 2006). Površine MLD-a određene metodom mreže uspoređivali su s drugim metodama u svojim istraživanjima Unruh i sur. (1997), Bergen i sur. (2003), Steiner i sur. (2003), Yanez i sur. (2006), Ferreira i sur. (2012.) i McGilchrist i sur. (2012) i drugi.

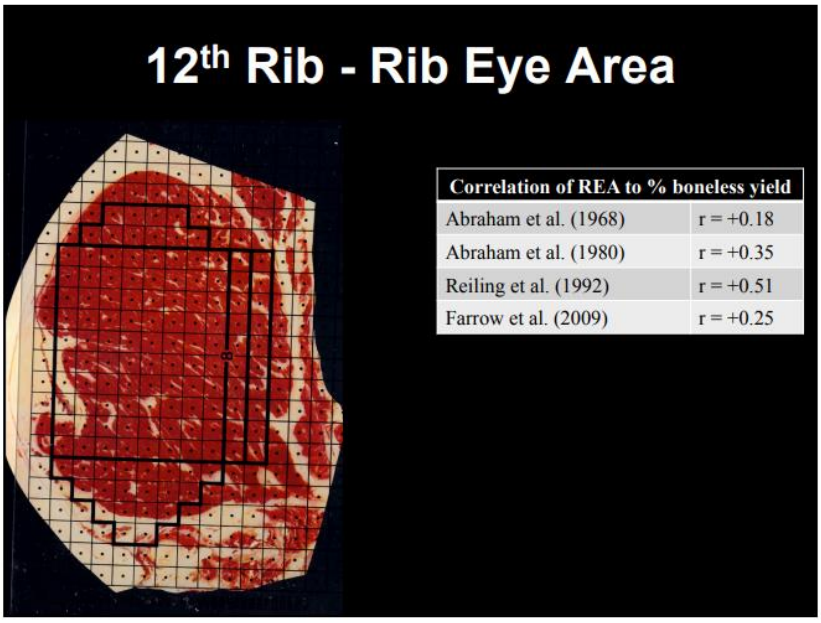

Slika 4.4.2. Određivanje površine MLD-a metodom mreže s točkama
Izvor: http://www.bifconference.com/bif2016/documents/EPI-BIF16-Lawrence.pdf - pristup 17.09.2021.

Kako bi se smanjile greške i razlike u rezultatima pri korištenju do sada opisanih metoda, započelo je korištenje dostupnih kompjutorskih tehnologija i u ove svrhe. Tako se različiti računalni programi i kompjutorski sustavi počinju intenzivno primjenjivati u određivanju površine MLD-a preživača tijekom zadnjeg desetljeća. Primjer takove primjene nalazimo u istraživanjima Cannell i sur. (1999.; ViaScan Carcass System), Macedo i sur. (2000.; AutoCAD), Karolyi i sur. (2006.; Image tool program), Yanez i sur. (2006.; Delta–T software), Ferreira i sur. (2012.; DDA software), Akbaş i sur. (2018.; AutoCAD) i drugi.

5. MATERIJALI I METODE

5.1. Pokusne životinje

Površine dugog leđnog mišića (*musculus longissimus dorsi*; MLD) prikupljene su od 131 mladog bika i 19 muške teladi. Pri tome je 59 bikova bilo Hereford pasmine, 30 bikova simentalske pasmine, 9 bikova Charolais pasmine, 33 bika križanci simentalske i Holstein pasmine, dok je 5 teladi bilo simentalske pasmine, 6 Holstain pasmine te 8 teladi križanci simentalske i Holstein pasmine.

5.2. Obrada trupova

Prijevoz bikova i teladi do klaonice obavljen je u skladu s važećom zakonskom regulativom (NN 39/08). Klanje i obrada trupova obavljeni su u ovlaštenoj klaonici, odobreni broj 10, po standardnom postupku. Junad i telad su omamljena pneumatskim pištoljem (Schermer) s penetrirajućim klinom postavljenim na sredinu čeone kosti odnosno na sjecištu zamišljenih dijagonala koji spajaju bazu rogova s očima uz zračni potisak dostatan za trenutačno omamljivanje životinje. Nakon omamljivanja, iskrvarenje je obavljeno presijecanjem velikih vratnih krvnih žila (*vena jugularis* i *arteria carotis*). Zatim je izvršena dekapitacija i obrada trupova prema standardnom postupku (NN 45/14). Klaonički obrađeni trupovi su izvagani, a ovlašteni klasifikatori su obavili ocjenu konformacije trupova (EUROP sustav) i prekrivenosti trupova masnim tkivom (ocjene 1-5). Prosječna konformacija trupova bikova bila je U uz stupanj prekrivenosti masnim tkivom 3, dok je konformacija teladi bila R uz stupanj prekrivenosti masnim tkivom 2. Prosječna dob pri klanju bikova iznosila je 15,56±1,82 mjeseci, a teladi 6,08±0,80 mjeseci. Prosječne završne tjelesne mase bikova iznosile su 547,76±78,04 kg, a prosječne mase hladnih polovica 313,92±50,84 kg. Prosječne završne tjelesne mase teladi iznosile su 160,76±16,40 kg, a prosječne mase hladnih polovica 94,44±12,10 kg (tablica 5.2.1).

Tablica 5.2.1. Podaci s linije klanja o trupovima bikova i teladi

Kategorija	Stupanj prekrivenosti masnim tkivom (ocjena 1-5)	Dob pri klanju (mjeseci)	Završna tjelesna masa (kg)	Masa hladnih polovica (kg)
	prosjek ± SD			
Bikovi	3,15±0,55	15,56±1,82	547,76±78,04	313,92±50,84
Telad	1,95±0,40	6,08±0,80	160,76±16,40	94,44±12,10

Slika 5.2.1. Klaonički obrađene polovice bikova
Izvor: osobna arhiva

Nakon 24-satnog hlađenja polovica (4°C) provedeno je rasijecanje između 12. i 13. rebra te je sa svake desne polovice na razini 12. rebra izvršeno iscrtavanje površine dugog leđnog mišića. Korištenjem vodootpornog markera površina dugog leđnog mišića je iscrtana na prozirne folije (slika 5.2.2.).

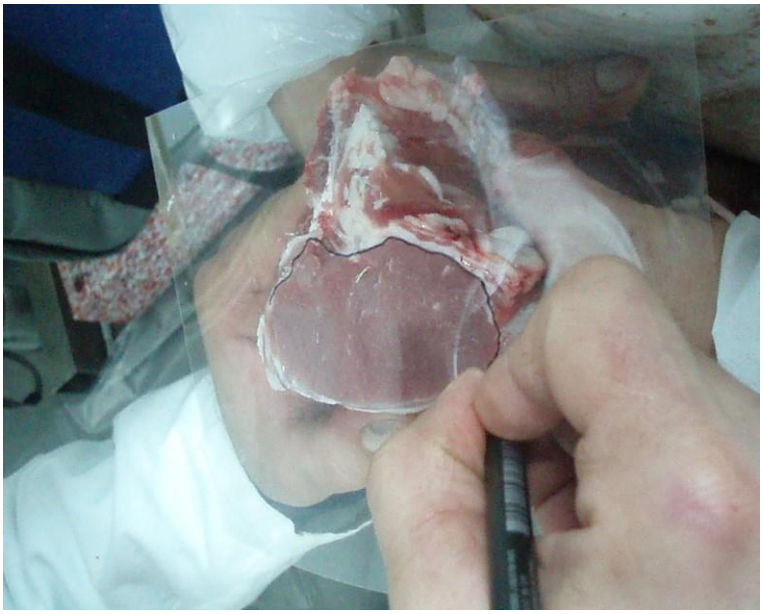

Slika 5.2.2. Iscrtavanje površine dugog leđnog mišića teladi na prozirnu foliju
Izvor: Osobna arhiva

5.3. Metode određivanja površine dugog leđnog mišića

Za određivanje površine dugog leđnog mišića bikova i teladi korištene su sljedeće metode: određivanje površine polarnim planimetrom, mreža s točkama, određivanje najveće dužine i širine iscrtane površine MLD-a te primjena računalnog programa AutoCAD. Za svaku metodu provedeno je pet ponavljanja po uzorku.

5.3.1. Metoda određivanja površine dugog leđnog mišića polarnim planimetrom

Za određivanje površine dugog leđnog mišića korišten je polarni planimetar Reiss Precission 3005. Za potrebe određivanja površine dugog leđnog mišića na stol je postavljen bijeli papir dimenzija 100 x 100 cm kako bi se osigurala ravna i ujednačena podloga za provođenje mjerenja. Na svakom iscrtanom uzorku je označena markerom jedna točka koja je služila kao početna i završna točka mjerenja (slika 5.3.1.1). Krak planimetra s iglicom je pritisnut u papir kako bi bio fiksiran, dok je krak s povećalom vučen rukom po iscrtanoj površini (slika 5.3.1.2.). Dobivene vrijednosti su korigirane faktorom 0,9960159.

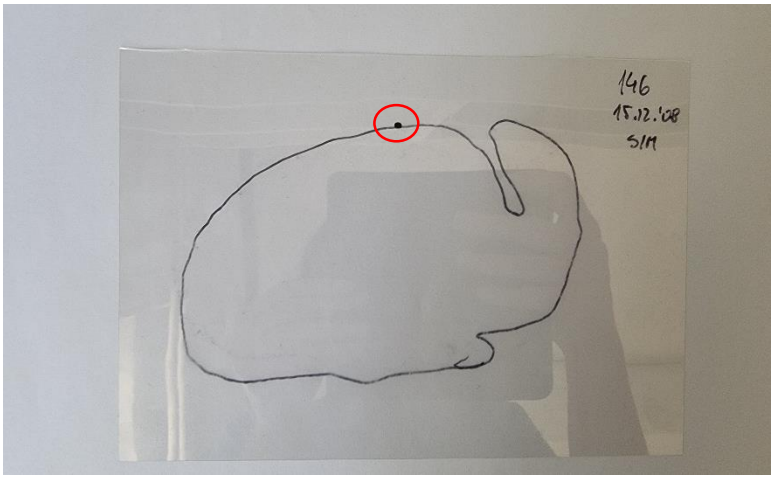

Slika 5.3.1.1. Polazna i završna točka na iscrtanoj površini dugog leđnog mišića
Izvor: Osobna arhiva

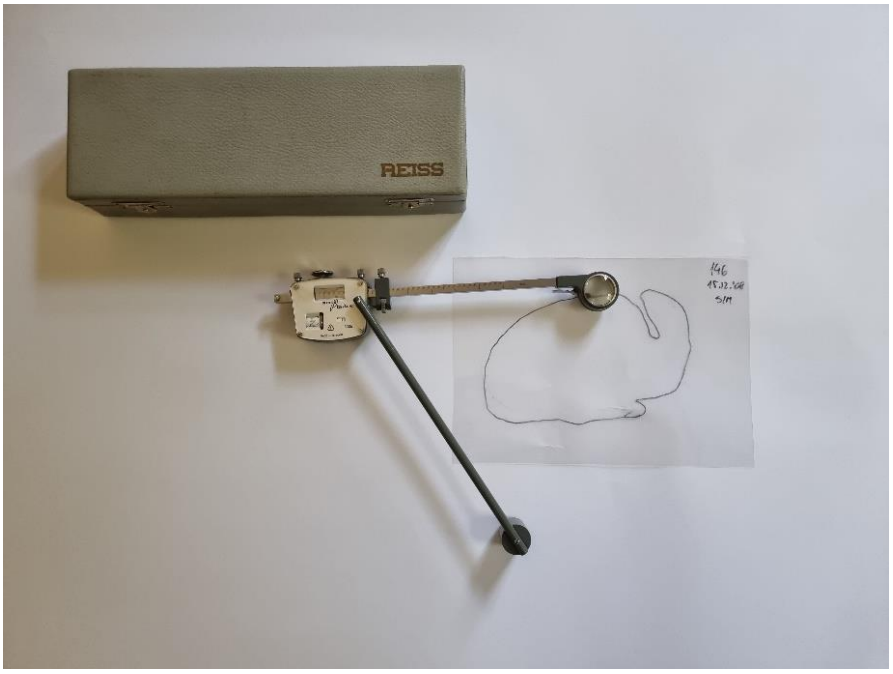

Slika 5.3.1.2. Određivanje površine dugog leđnog mišića polarnim planimetrom Reiss Precisison 3005

Izvor: Osobna arhiva

5.3.2. Prilagođena metoda mreže s točkama

Metodom mreže s točkama, površina MLD-a određena je prema O´Connor-u (2011.) uz prilagodbu. Za određivanje površine korištena je mreža s točkama isprintana na A4 papiru. Unutar mreže svaka točka se nalazila u kvadratu površine 1 cm^2. Postupak se provodio na način da se folija nasumično stavljala na navedenu mrežu te fiksirala selotejpom radi veće stabilnosti. Nakon fiksiranja brojale su se točke koje su potpunosti unutar granica linije MLD-a te nakon toga točke koje su djelomično unutar linije (slika 5.3.2.1.). Za svaku foliju provedeno je pet ponavljanja mjerenja kako bi se dobila što točnija vrijednost. Površine su dobivene nakon uvrštavanja dobivenih vrijednosti u sljedeću formulu:

$$P = unutanje\ točke + \left(\frac{granične\ točke}{2}\right) - 1$$

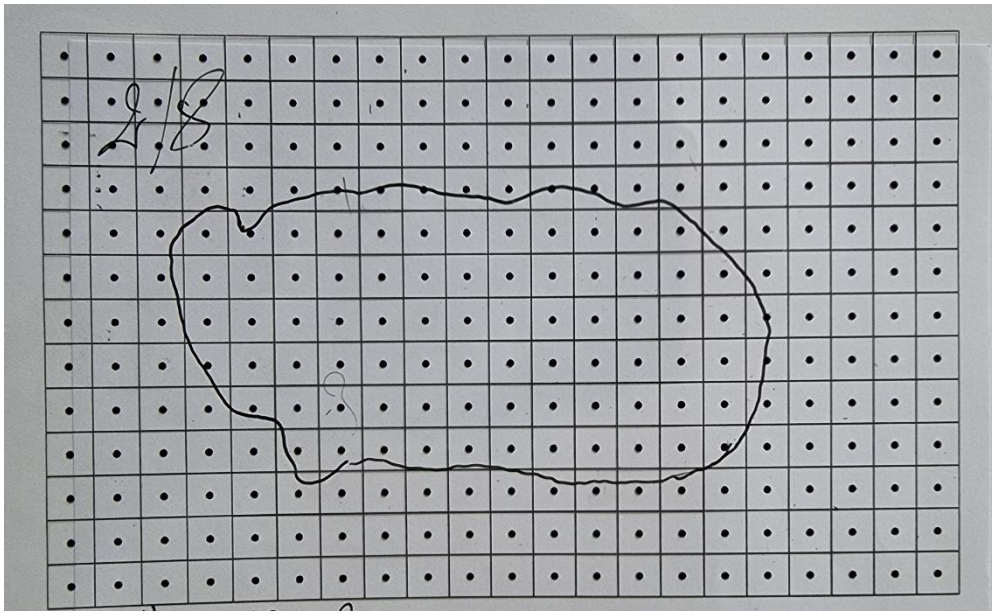

Slika 5.3.2.1. Određivanje površine dugog leđnog mišića prilagođenom metodom mreže s točkama

Izvor: Osobna arhiva

5.3.3. Metoda najveće dužine i širine iscrtane površine dugog leđnog mišića

Metoda mjerenja najveće dužine i širine iscrtane površine MLD-a provedena je prema opisu Ferreira i sur. (2012.). Za potrebe određivanja površine dugog leđnog mišića na stol je postavljen bijeli papir dimenzija 100 x 100 cm kako bi se osigurala ravna i ujednačena podloga za provođenje mjerenja nakon čega je folija fiksirana selotejpom. Mjerenje je provođeno pomoću ravnala uz ponavljanje od pet puta za svaku foliju. Dužina (A) je predstavljala najveću duljinu MLD-a (Slika 5.3.3.1.), dok je širina (B) bila najveća vrijednost okomita na dužinu (Slika 5.3.3.2.). Površina presjeka MLD-a dobivena je uvrštavanjem navedenih vrijednosti u sljedeću formulu:

$$P = \left(\frac{A}{2} \times \frac{B}{2}\right) \times \pi$$

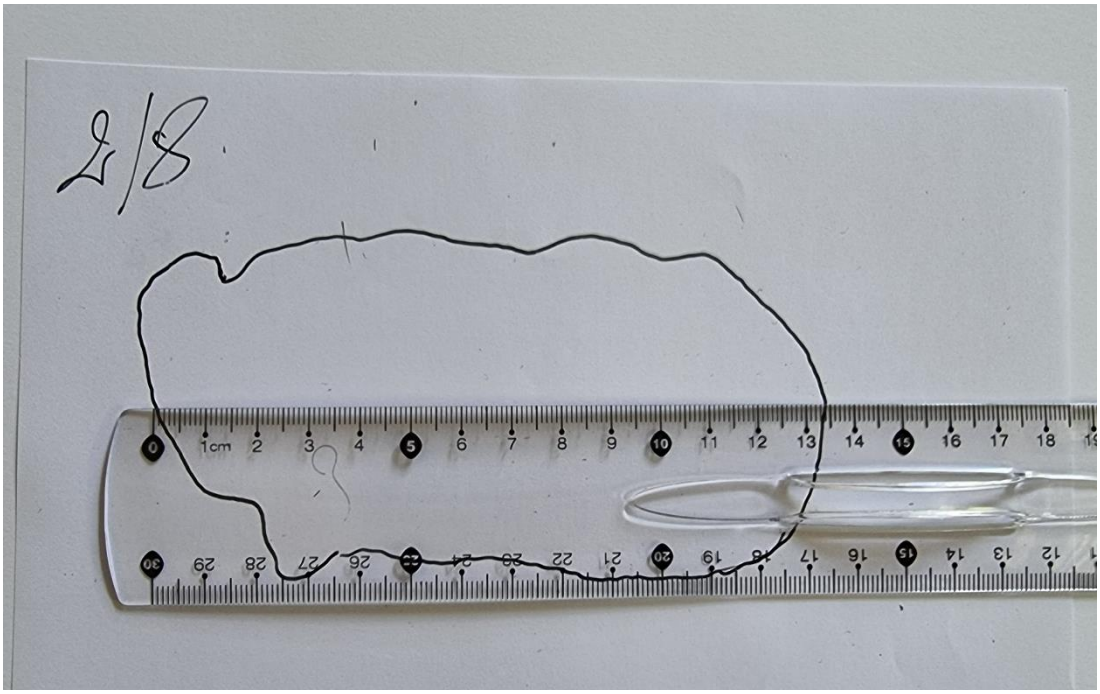

Slika 5.3.3.1. Određivanje najveće dužine iscrtane površine dugog leđnog mišića

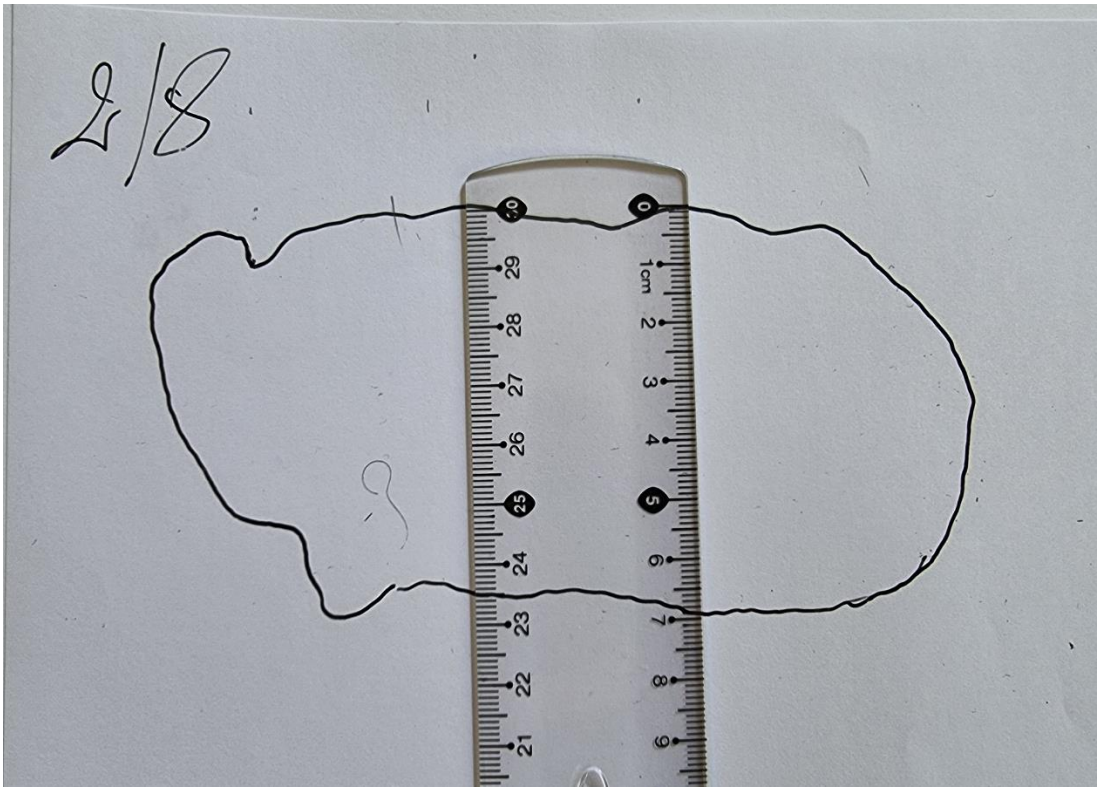

Slika 5.3.3.2. Određivanje najveće širine iscrtane površine dugog leđnog mišića

5.3.4. Metoda određivanja površine dugog leđnog mišića primjenom računalnog programa AutoCAD

Za potrebe mjerenja, folije s iscrtanim presjecima MLD-a su skenirane kako bi se u JPG obliku mogle otvoriti u programu AutoCAD. Navedene slike su otvarane u verziji Map 3D 2022. programa AutoCAD. Postupak mjerenja proveden je na sljedeći način:

1. Nakon otvaranja programa u polje za upisivanje naredbi upisana je naredba „RECTANGLE“ koja je omogućila stvaranje okvira dimenzije 2970 x 2100 mm (Slika 5.3.4.1).

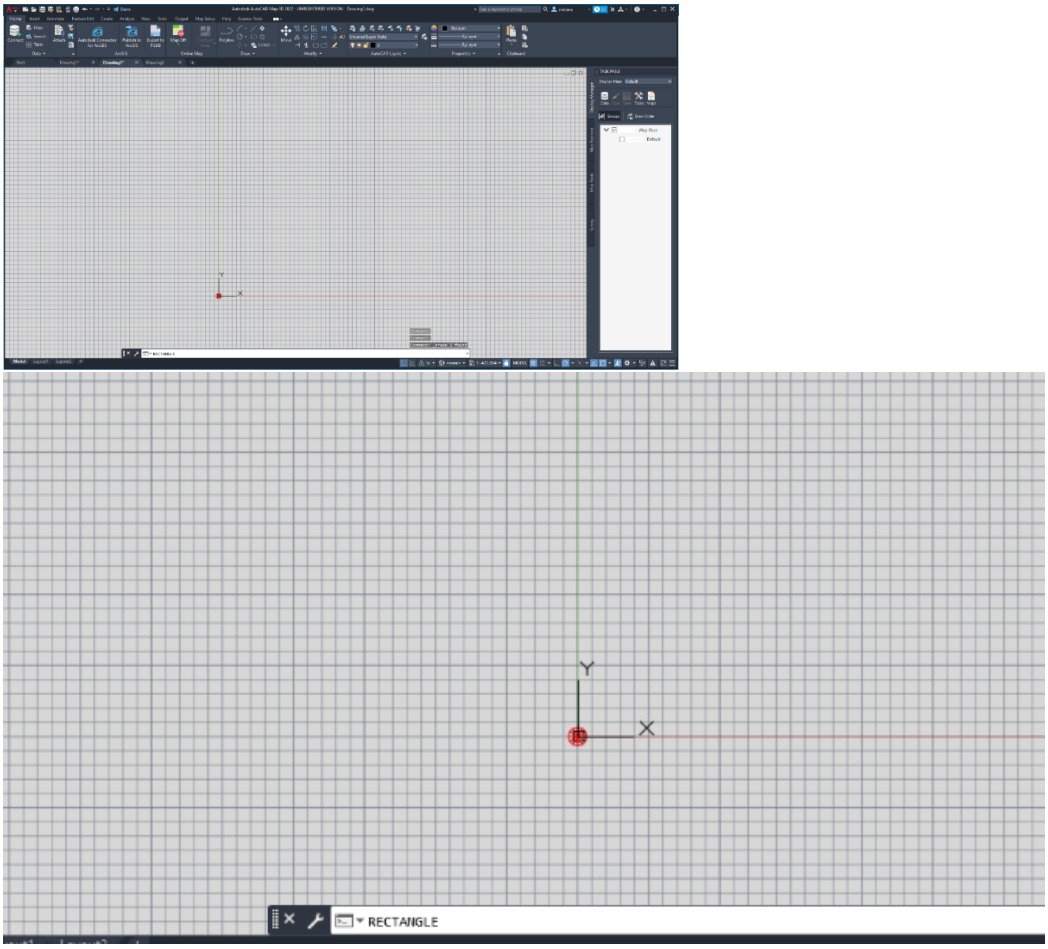

Slika 5.3.4.1. Naredba RECTANGLE

2. Nakon odabira naredbe „RECTANGLE“ bilo je potrebno stisnuti na površinu za crtanje te u polje za upisivanje naredbi upisati „d“ i stisnuti tipku ENTER. Upis slova „d“ označio je upisivanje željenih dimenzija okvira (Slika 5.3.4.2.): 2970 i 2100 nakon čijeg je upisa bilo potrebno pritisnuti ENTER te kliknuti na površinu za crtanje kako bi se prikazao željeni okvir (Slika 5.3.4.3).

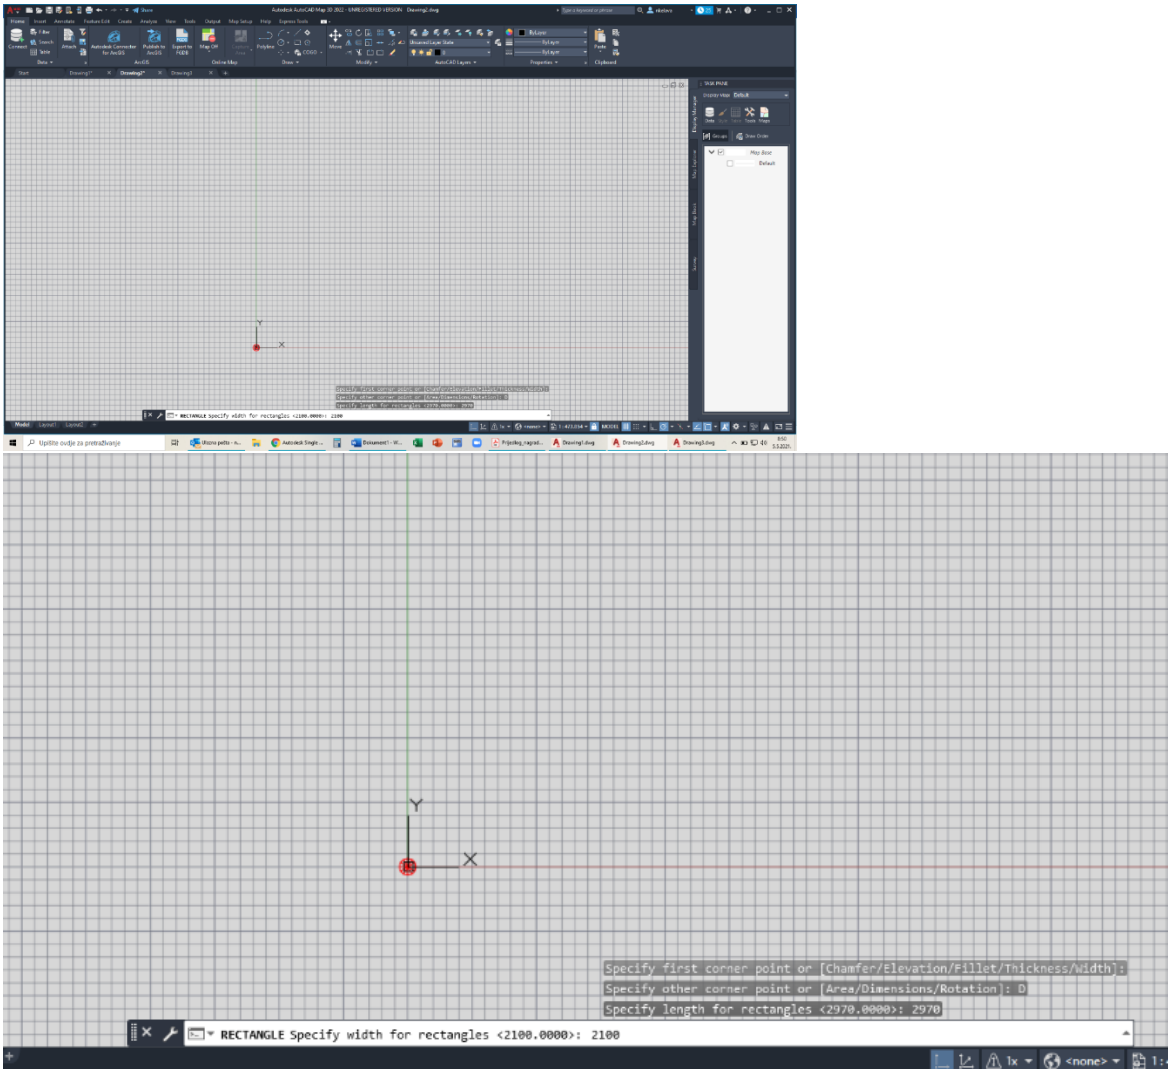

Slika 5.3.4.2. Upisivanje dimenzija okvira

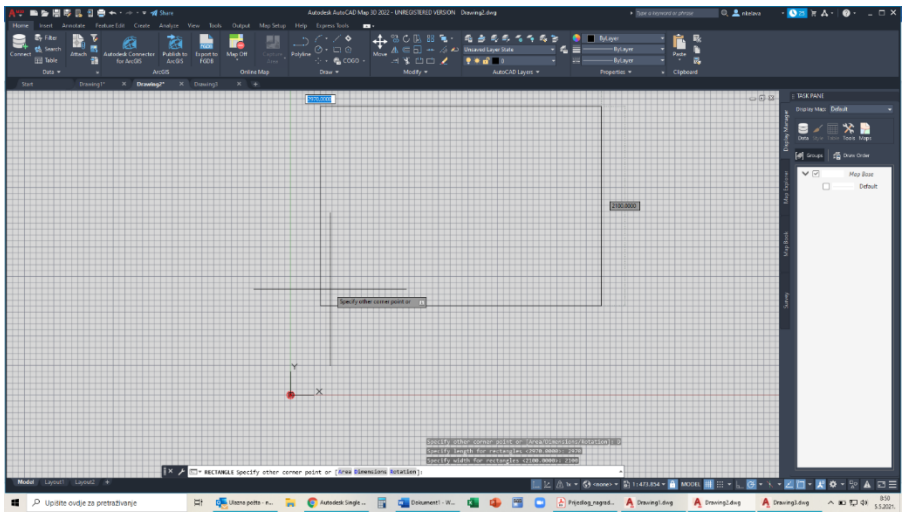

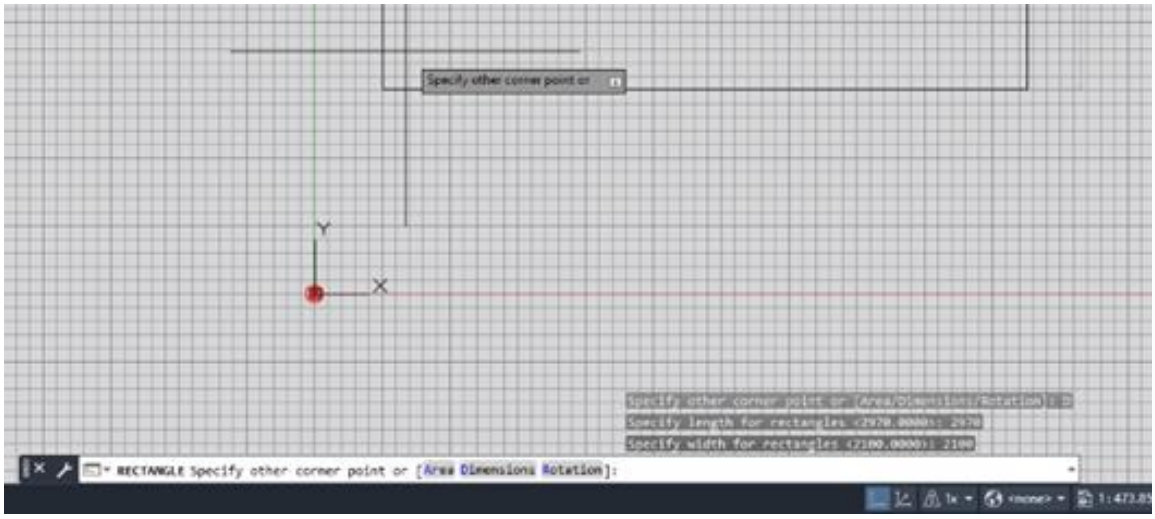

Slika 5.3.4.3. Okvir

3. Formiranje okvira omogućilo je umetanje skenirane površine MLD-a. Na alatnoj traci odabran je izbornik „Insert“ te opcija „Image“ (Slika 5.3.4.4). Odabirom željene slike na računalu, otvorio se dijaloški okvir „Image Correlation“ (Slika 5.3.4.4).

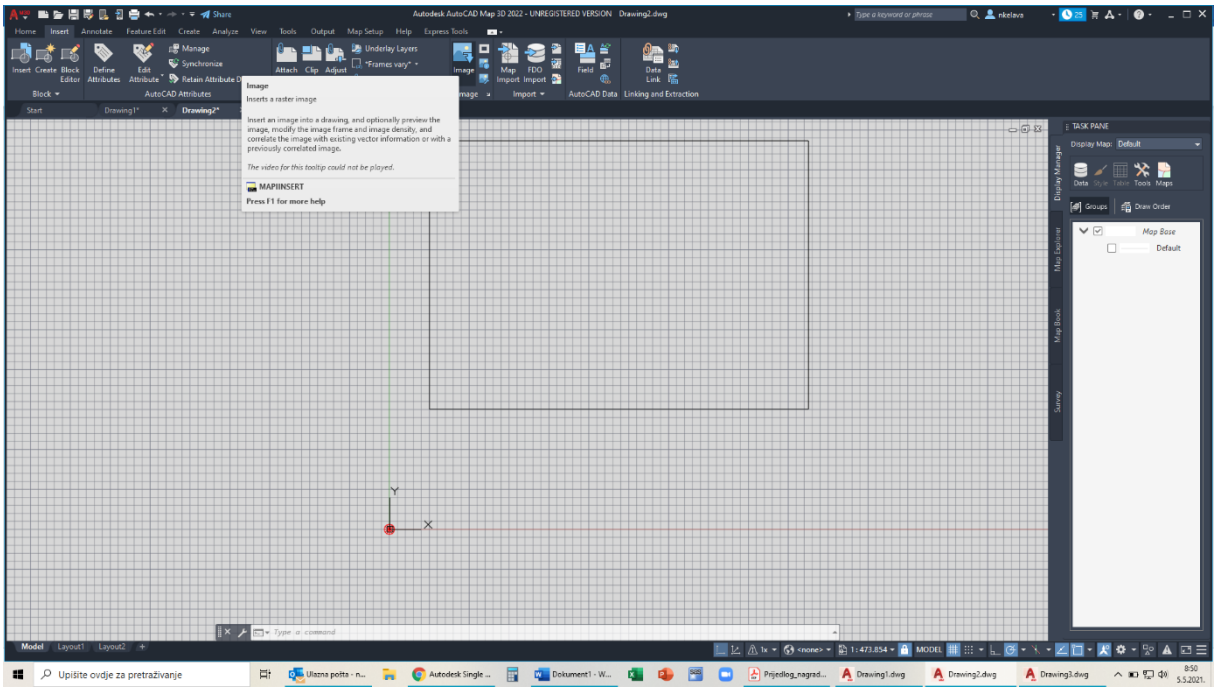

Slika 5.3.4.4. Umetanje slike

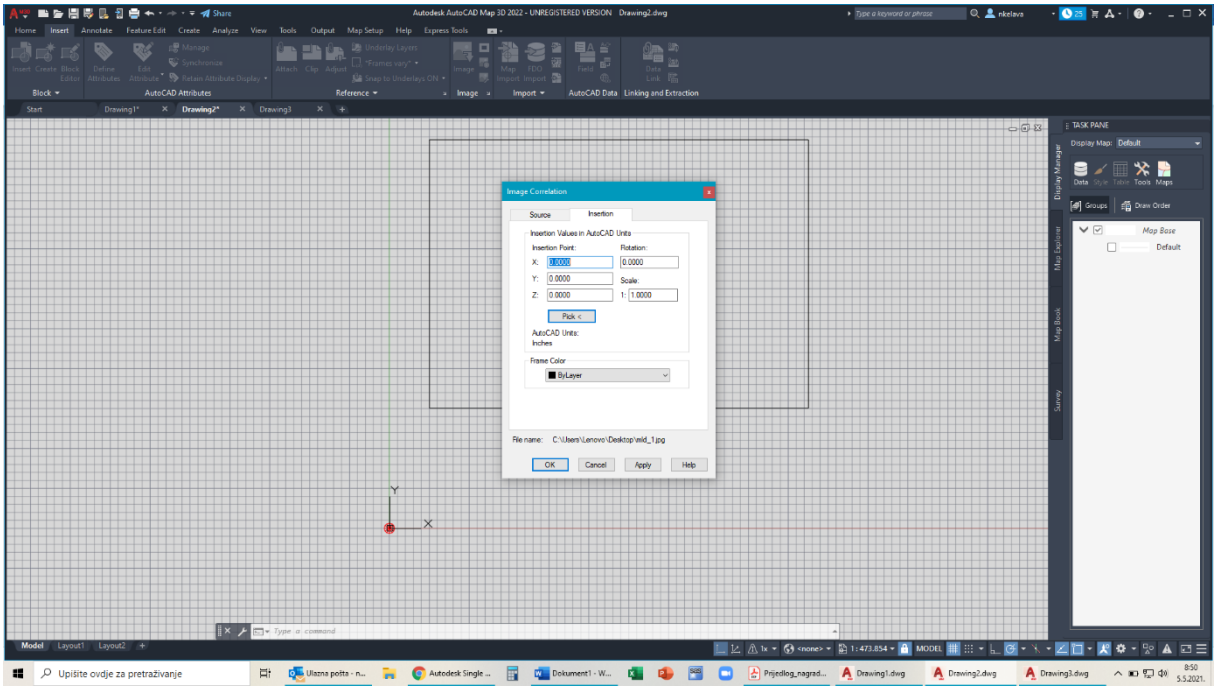

Slika 5.3.4.5. Umetanje slike

4. U dijaloškom okviru „Image Correlation“ odabrali smo izbornik „Insertion“ i unutar njega naredbu PICK. Nakon odabira naredbe PICK bilo je potrebno odabrati tri točke (Shema 5.3.4.1) unutar okvira kako bi se slika pozicionirala (Slika 5.3.4.6.).

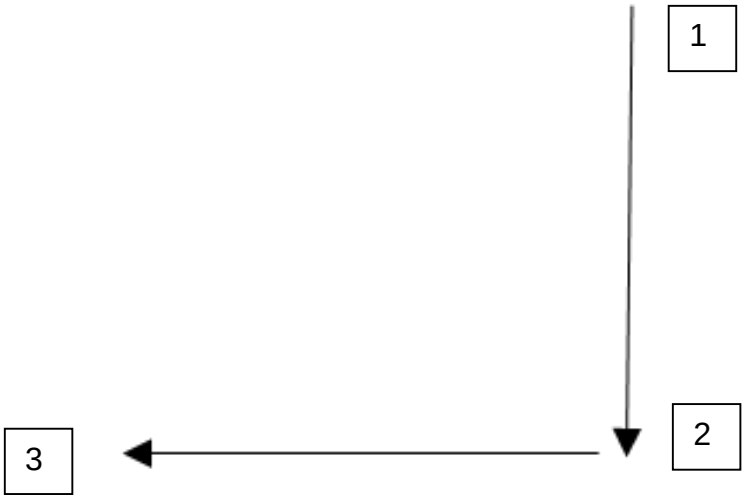

Shema 5.3.4.1. Redoslijed odabira točaka unutar okvira

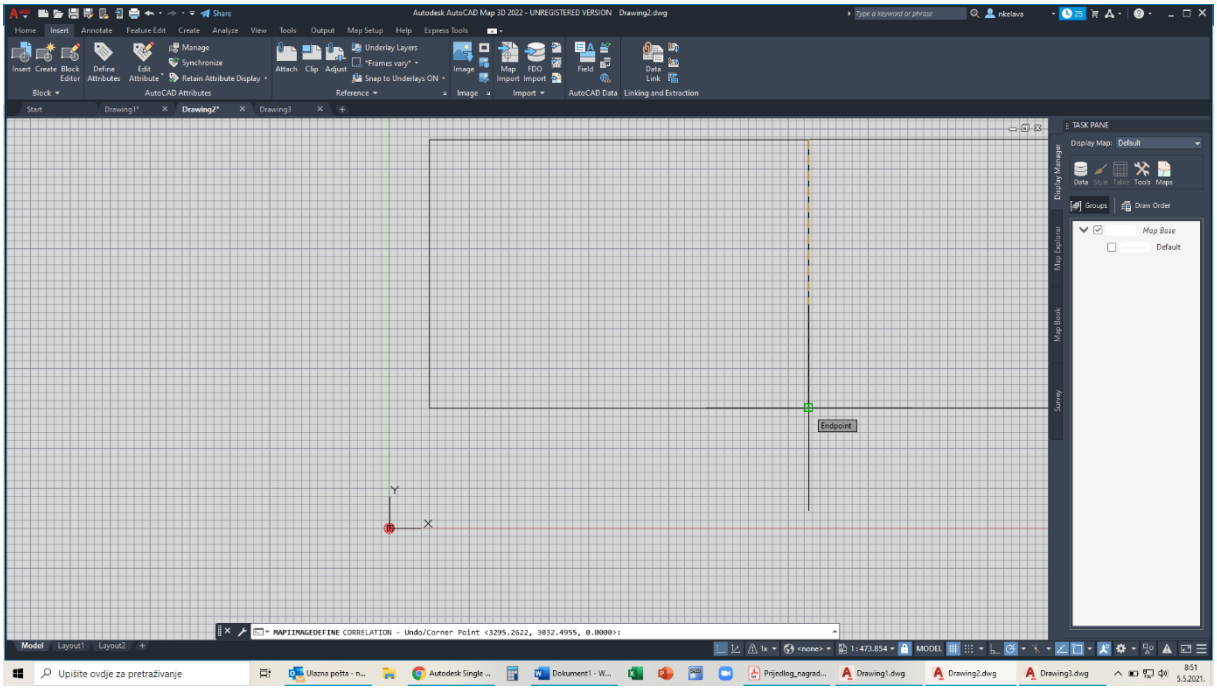

Slika 5.3.4.6. Pozicioniranje slike unutar okvira

5. Nakon pozicioniranja slike u polje za upisivanje naredbi upisana je naredba „PLINE“(Slika5.3.4.7.). Odabirom početne točke na slici započelo je iscrtavanje granične linije koja je omeđivala površinu MLD-a. Spajanjem početne i krajnje točke dobivena je cjelina unutar koje se mogla očitati površina (Slika 5.3.4.8).

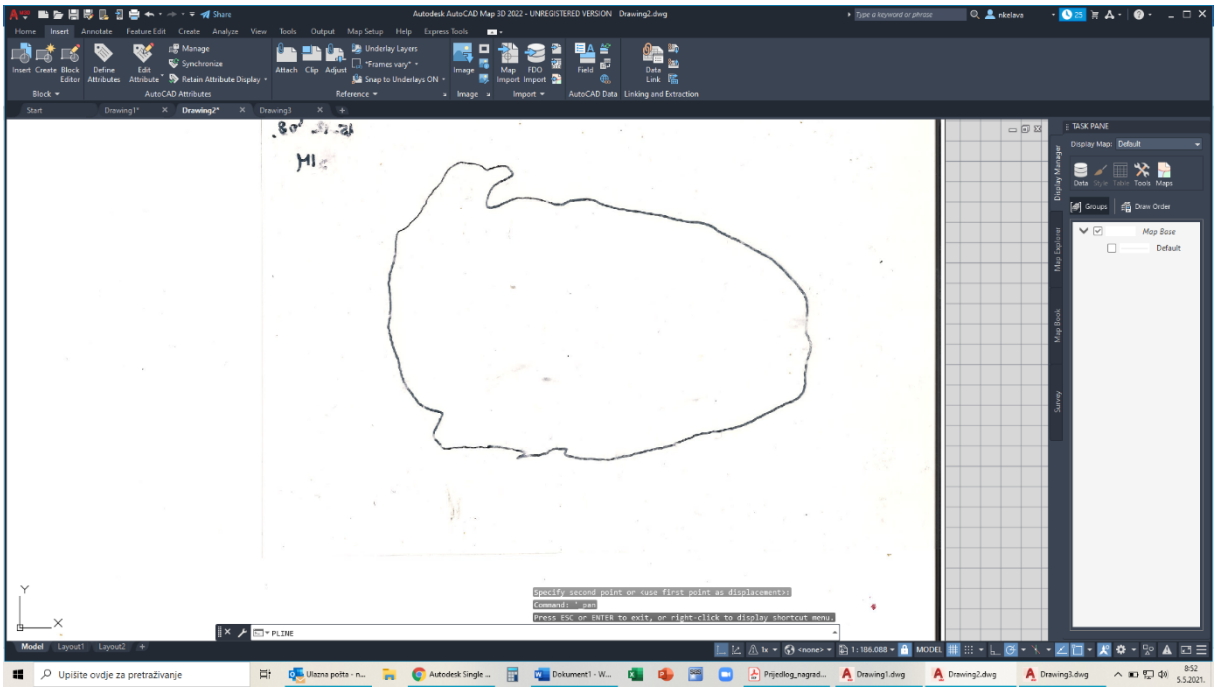

Slika 5.3.4.7. Naredba PLINE

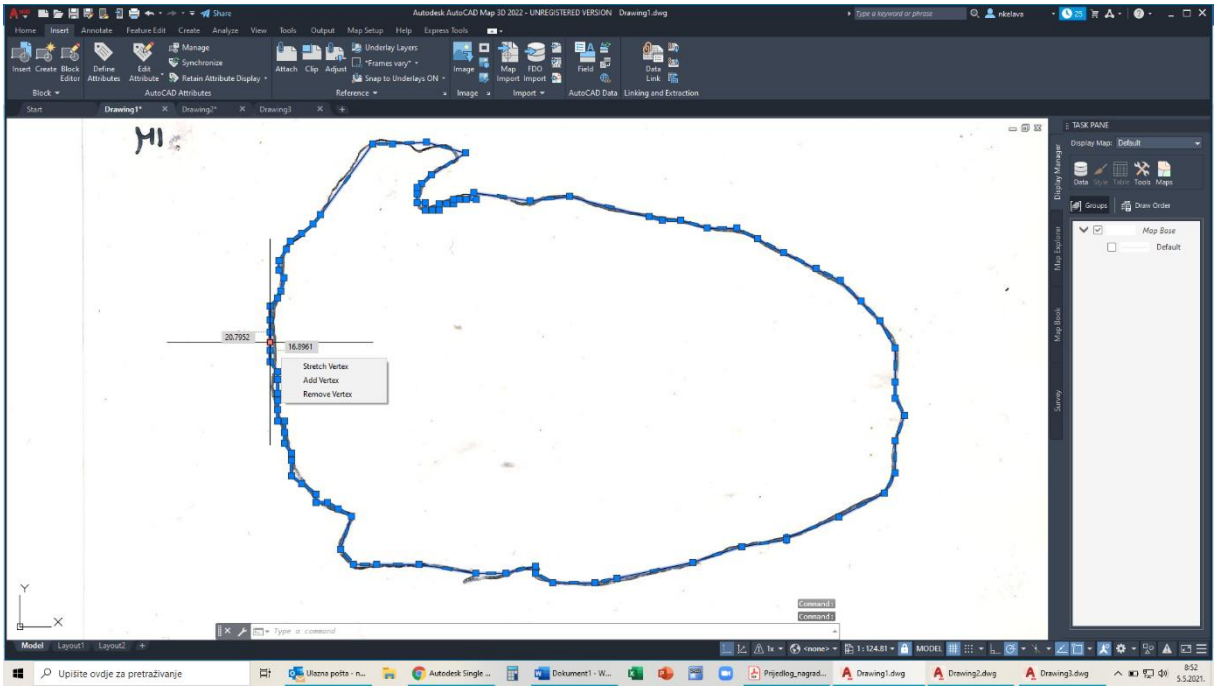

Slika 5.3.4.8. Iscrtavanje površine

6. Nakon dobivanja iscrtane površine pritisnut je desni klik miša, prilikom čega se otvorio padajući izbornik u kojem smo odabrali „Properties“. Navedenim odabirom otvorio se dijaloški okvir koji pruža različite informacije o crtežu. Odabirom padajućeg izbornika „Geometry“ očitali smo povšinu presjeka MLD-a u dijelu „Area“ (Slika 5.3.4.9.).

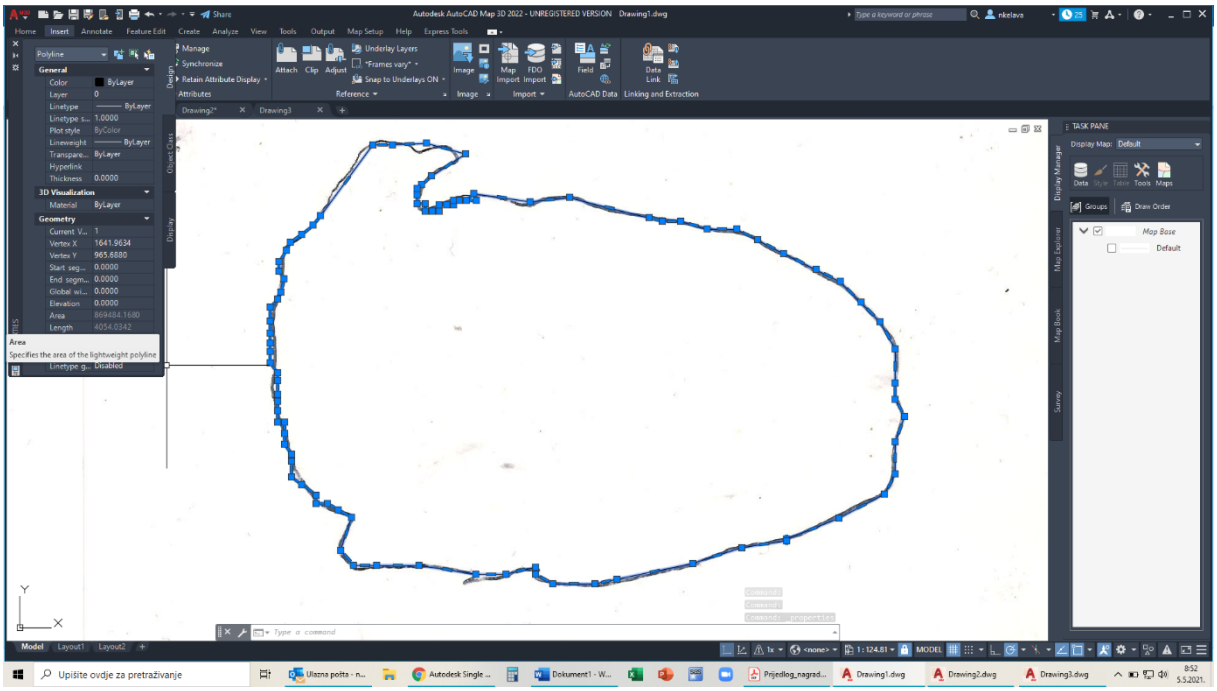

Slika 5.3.4.9. Očitavanje površine

5.3.5. Statistička analiza

Podaci su obrađeni primjenom statističkog paketa SAS V9.4. (2013). Najprije su u ASSIST-u izračunati parametri deskriptivne statistike: prosjek, minimalna i maksimalna površina te standardna devijacija. U svrhu utvrđivanja razlike između površina dugog leđnog mišića određenih različitim metodama primijenjena je procedura MIXED i REML (eng. *Restricted Maximum Likelihood*) metoda analiza komponenti varijance. Pri tome je površina MLD-a bila zavisna varijabla, metoda određivanja površine MLD-a je bila fiksni utjecaj, dok je interakcija ponovljenog mjerenja i uzorka bila slučajni utjecaj.

```
proc mixed data =sasuser.diplomski_kućar method=reml;
 class ponovljeno_mjerenje uzorak metoda;
 model površina=metoda;
 random ponovljeno_mjerenje*uzorak;
LSMEANS metoda/PDIFF;
        run;
```

```
proc mixed data=sasuser.diplomski_kućar_reml method=reml;
 class ponovljeno_mjerenje uzorak metoda kategorija;
 model površina=metoda(kategorija);
 random ponovljeno_mjerenje*uzorak;
LSMEANS metoda(kategorija)/PDIFF;
run;
```

Potom su izračunati Pearson-ovi koeficijenti korelacije u ASSIST rješenju SAS-a, a primjenom procedure REG određeni su regresijski koeficijenti, jednadžbe i pravci regresije korištenjem kao u sljedećem primjeru:

```
proc reg data=sasuser.diplomski_kućar_korelacija;
  model planimetar = autocad ;
  plot planimetar * autocad/pred ;
        run;
```

6. Rezultati i rasprava

6.1. Deskriptivna statistika površina MLD-a određenih različitim metodama i razlike u prosjecima najmanjih kvadrata

U tablicama 6.1.1. i 6.1.2. prikazana je deskriptivna statistika i usporedba površina MLD-a goveda određenih različitim metodama. Na ukupnom broj uzoraka utvrđene su značajne razlike ($p<0,05$) između površina MLD-a određenih različitim metoda. Značajno ($p<0,05$) manja površina MLD-a utvrđena je računalnim programom AutoCAD, dok se površine MLD-a određene preostalim metodama nisu značajno ($p>0,05$) razlikovale. Najveća površina MLD-a utvrđena je metodom mreže s točkama i iznosila je 84,03 cm^2, dok je najmanja površina MLD-a utvrđena u računalnom programu AutoCAD i iznosila je 82,69 cm^2. Polarnim planimetrom i metodom najveće dužine i širine utvrđene su gotovo jednake vrijednosti površine MLD-a i iznosile su 83,57 cm^2 odnosno 83,65 cm^2.

Metodama najveća širina i dužina i mreže s točkama utvrđene su veće standardne devijacije u odnosu na površine određivanje polarnim planimetrom i računalnim programom AutoCAD (Tablica 6.1.1.).

Određivanje površine MLD-a polarnim planimetrom je relativno brza metoda, no uzastopno ponavljanje mjerenja velikog broja uzoraka brzo postaje vizualno zamorno. Glavnim nedostatkom metode pored zamora očiju, može se smatrati i pomicanje kraka s iglom koji se pomjeri ukoliko nije dobro fiksiran te je stoga mjerenje ponoviti od početne točke (Ferreira i sur., 2012.).

Metoda mreže s točkama se subjektivno čini najbržom, ali i najmanje pouzdanom što potvrđuje i najveća vrijednost standardne devijacije. Potrebno je veće iskustvo kako bi se odredile koje točke će se uzeti u obzir kao granične odnosno one koje se nalaze na vanjskim rubovima iscrtane površine te također uslijed uzastopnog ponavljanja brojanja točaka na većem broju uzoraka pada koncentracija i može se lakše napraviti previdi i/ili prebrojavanje pojedinih točki. Posljedično ovom metodom su u odnosu na sve ostale i dobivene veće površine MLD-a, a razlika se može pripisati i većim kvadratima (1 cm^2) zbog kojeg određivanje rubnih točki može biti otežano (Yanez i sur., 2006.).

Metoda najveće dužine i širine ima također veću vrijednost standardne devijacije poglavito zbog razlika u iscrtanim površinama odnosno na onim folijama gdje postoje suženja ili udubljena najveća dužina i širina su nastale kao posljedica gubitka osnovnog oblika MLD-a prilikom rasijecanja. Osobito je ovo slučaj pri manjim tjelesnim masama kad MLD-a ima manje eliptičan oblik i poprima formu krnjeg trokuta (Yanez i sur., 2006.).

Primjena računalnog programa AutoCAD je vremenski zahtjevna u smislu pripreme jer je potrebno svaki uzorak skenirati i konvertirati u JPG format kako bi se mogao koristiti za određivanje površine. U opciji AutoCAD-a koja je korišten nije postojala mogućnost automatskog prepoznavanja iscrtane površine MLD-a nego je bilo potrebno ipak ručno učiniti ocrtavanje. U odnosu na planimetra prednost ove metode je mogućnost korekcije na prethodnu točku koliko se učini pomak od iscrtane površine te se ne mora kretati od početka. Ujedno, prednost je što nakon ocrtavanje površine program AutoCAD sam izračunava površinu sa većim brojem decimala u odnosu na korišteni polarni planimetra gdje često i očitavanje rezultata predstavlja problem. Korištenje digitalnog planimetra bilo bi znatno brže i preciznije.

Korištenje računalnog programa AutoCAD i digitalnog planimetra mogu se preporučiti za pouzdane i precizne metode, dok preostale dvije metode se subjektivno čine zamornim i iskustveno zahtjevnim, osobito metoda mreže s točkama.

Tablica 6.1.1. Deskriptivna statistika površina MLD-a goveda određenih različitim metodama

Metoda	broj uzoraka	prosjek	minimum	maksimum	standardna devijacija
		cm^2			
planimetar	150	83,57	31,47	130,14	21,41
najveća širina i dužina	150	83,65	27,37	134,72	22,71
mreža s točkama	150	84,03	30,00	137,83	22,87
AutoCAD	150	82,69	31,31	126,48	20,97

Tablica 6.1.2. Površine MLD-a određene različitim metodama (LSMEAN± standardna greška)

Metoda	Površina MLD-a (cm^2)		
	Svi uzorci (n=150)	Bikovi (n=131)	Telad (n=19)
planimetar	$83,89\pm1,05^{a}$	$90,44\pm0,68^{a}$	$38,45\pm1,78^{a}$
najveća širina i dužina	$83,70\pm1,05^{a}$	$90,76\pm0,68^{a}$	$35,79\pm1,78^{b}$
mreža s točkama	$84,06\pm1,05^{a}$	$91,15\pm0,68^{Aa}$	$35,96\pm1,78^{b}$
AutoCAD	$82,82\pm1,05^{b}$	$89,22\pm0,68^{Bb}$	39,33±1,78a

$^{A,B,\ a,b}$ Vrijednosti unutar stupca označene različitim slovima značajno se razlikuju (a,b = $p<0,05$; A,B =0,0001); LSMEAN – *least square mean*

U tablici 6.1.3. prikazana je deskriptivna statistika površina MLD-a bikova određenih različitim metoda. Računalnim programom AutoCAD utvrđena je značajno manja površina u odnosu na površine određene planimetrom i metodom najveće dužine i širine ($p<0,05$) odnosno površine određene metodom mreže s točkama ($p<0,0001$) (tablica 6.1.2.). Najveća površina MLD-a bikova određena je metodom mreže s točkama. Površine MLD-a bikova određene polarnim planimetrom i metodom najveće širine i dužine su bile gotovo jednake i iznosile su 90,05 odnosno 90,59 cm^2. Standardne devijacije površina MLD-a određenih polarnim planimetrom i računalnim programom AutoCAD bile su manje u odnosu na preostale dvije metode.

Tablica 6.1.3. Deskriptivna statistika površina MLD-a bikova određenih različitim metodama

Metoda	broj uzoraka	prosjek	minimum	maksimum	standardna devijacija
		cm^2			
planimetar	131	90,05	59,20	130,14	13,72
najveća širina i dužina	131	90,59	59,05	134,72	14,34
mreža s točkama	131	91,00	57,33	137,83	14,53
AutoCAD	131	89,02	59,22	126,48	13,60

U tablici 6.1.4. prikazana je deskriptivna statistika površina MLD-a teladi određenih različitim metoda. Značajno ($p<0,05$) manje površine MLD-a teladi utvrđene su metodom najveće dužine i širine i metodom mreže s točkama (35,79 i 35,95 cm^2) u odnosu na površine MLD-a određene polarnim planimetrom i računalnim programom AutoCAD (38,85 i 39,33 cm^2). Najmanja standardna devijacija pri određivanju površina MLD-a teladi utvrđena je za metodu mreže s točkama, dok su za preostale metode bile slične.

Tablica 6.1.4. Deskriptivna statistika površina MLD-a teladi određenih različitim metodama

Metoda	broj uzoraka	prosjek	minimum	maksimum	standardna devijacija
		cm^2			
planimetar	19	38,85	31,47	46,66	4,25
najveća širina i dužina	19	35,79	27,37	40,84	4,14
mreža s točkama	19	35,95	30,00	42,00	3,43
AutoCAD	19	39,33	31,31	46,63	4,10

6.2. Koeficijenti korelacije između površina MLD-a određenih različitim metodama

U tablici 6.2.1. prikazani su Pearson-ovi koeficijenti korelacije između površina MLD-a goveda određenih različitim metodama. Između površina MLD-a određenih različitim metodama utvrđena je vrlo visoka značajna pozitivna korelacija ($r >0,9$; $p<0,0001$). Tako je najveća vrijednost Pearson-ovog koeficijenta korelacije utvrđena između površina MLD-a određeni polarnim planimetrom i računalnim programom AutoCAD ($r=0,978$), slijedio je koeficijent korelacije između metoda mreže s točkama i računalnog programa AutoCAD ($r=0,969$), potom gotovo jednaki koeficijenti korelacije između površina MLD-a određenim polarnim planimetrom i metode mreže s točkama te metodom najveće dužine i širine i AutoCAD-om ($r=0,947$ i $r=0,949$). Najniža vrijednost Pearson-ovog koeficijenta korelacije između površina MDL-a utvrđena je između metoda najveće dužine i širine i mreže s točkama ($r=0,923$).

Istraživanjem koje su proveli Akbaş i sur. (2018.) također je utvrđena vrlo visoka značajna pozitivna korelacija ($r >0,9$; $p<0,0001$) što je u suglasju s navedenim rezultatima. U navedenom istraživanju uspoređivano je mjerenje površine presjeka MLD-a ovaca i koza pomoću planimetra i AutoCAD-a.

Tablica 6.2.1. Pearson-ovi koeficijenti korelacije između površina MLD-a određenih različitim metodama

Metoda	planimetar	najveća širina i dužina	mreža s točkama	AutoCAD
planimetar	---	0,954 < 0,0001	0,947 < 0,0001	0,978 < 0,0001
najveća širina i dužina		---	0,923 < 0,0001	0,949 < 0,0001
mreža s točkama			---	0,969 < 0,0001

U tablici 6.2.2. prikazani su Pearson-ovi koeficijenti korelacije između površina MLD-a bikova određenih različitim metodama. I u slučaju površina MLD-a bikova utvrđeni su visoki do vrlo visoki pozitivni i značajni ($p<0,0001$) koeficijenti korelacije između različitih metoda. Najveći stupanj korelacije utvrđen je između površina MLD-a bikova određenih polarnim planimetrom i računalnim programom AutoCAD ($r=0,939$; $p<0,0001$). Slijedio je koeficijent korelacije između metoda mreže s točkama i AutoCAD-a ($r=0,917$; $p<0,0001$). Visoka značajna korelacija utvrđena je i između površina MLD-a određenim polarnim planimetrom i metoda najveće dužine i širine te mreže s točkama ($r=0,871$ i $r=0,851$; $p<0,0001$) kao i metode najveće dužine i širine s AutoCAD-om ($r=0,857$; $p<0,0001$). Metoda najveće dužine i širine s metodom mreže s točkama imala je srednje visoku pozitivnu korelaciju ($r=0,784$; $p<0,0001$).

U istraživanju koje su proveli Ferreira i sur. (2012.) također su utvrđeni vrlo visoki pozitivni i značajni ($p<0,0001$) koeficijenti korelacije između različitih metoda prilikom mjerenja MLD-a ovaca. Najveći stupanj korelacije utvrđen je između površina MLD-a ovaca mjerenih metodom mreže s točkama i digitalnom metodom ($r = 0.98$; $p<0.0001$). Slijedio je koeficijent korelacije između planimetra i digitalne metode($r=0,97$; $p<0,0001$).

Tablica 6.2.2. Pearson-ovi koeficijenti korelacije između površina MLD-a bikova određenih različitim metodama

Metoda	planimetar	najveća širina i dužina	mreža s točkama	AutoCAD
planimetar	---	0,871 < 0,0001	0,851 < 0,0001	0,939 < 0,0001
najveća širina i dužina		---	0,784 < 0,0001	0,857 < 0,0001
mreža s točkama			---	0,917 < 0,0001

U tablici 6.2.3. su prikazani Pearson-ovi koeficijenti korelacije između površina MLD-a teladi određeni različitim metodama. I u slučaju površina MLD-a teladi utvrđeni su visoki do vrlo visoki pozitivni i značajni ($p<0,0001$) koeficijenti korelacije između različitih metoda. Najveći stupanj korelacije utvrđen je između površina MLD-a teladi određenih polarnim planimetrom i AutoCAD-om ($r=0,946$; $p<0,0001$). Površine MLD-a teladi određene polarnim planimetrom i metodom najveće dužine i širine imale su najniže, ali i dalje visoke značajne korelacije ($r=0,852$; $p<0,0001$).

Tablica 6.2.3. Pearson-ovi koeficijenti korelacije između površina MLD-a telad određenih različitim metodama

Metoda	planimetar	najveća širina i dužina	mreža s točkama	AutoCAD
planimetar	---	0,852 < 0,0001	0,871 < 0,0001	0,946 < 0,0001
najveća širina i dužina		---	0,872 < 0,0001	0,910 < 0,0001
mreža s točkama			---	0,918 < 0,0001

6.3. Regresija između površina MLD-a određenih različitim metodama

6.3.1. Povezanost površina MLD-a određenih različitim metodama u odnosu na površine MLD-a određene polarnim planimetrom

Na slici 6.3.1.1. prikazan je koeficijent regresije, regresijska krivulja i regresijska jednadžba između površina MLD-a određenih polarnim planimetrom (X) i metodom mreže s točkama (Y). Koeficijent regresije između površina MLD-a (cm^2) određenih ovim metodama iznosio je r^2= 0,89 ($p<0,0001$), a regresijska jednadžba je Y= -0,4675+1,0111*X. Može se primijetiti veća grupiranost manjih površina MLD-a odnosno površina MLD-a teladi, dok među površinama MLD-a bikova postoji veća prostorna udaljenost (dispergiranost). No, većina uzoraka nalazi se unutar gornje i donje 95% razine povjerenja.

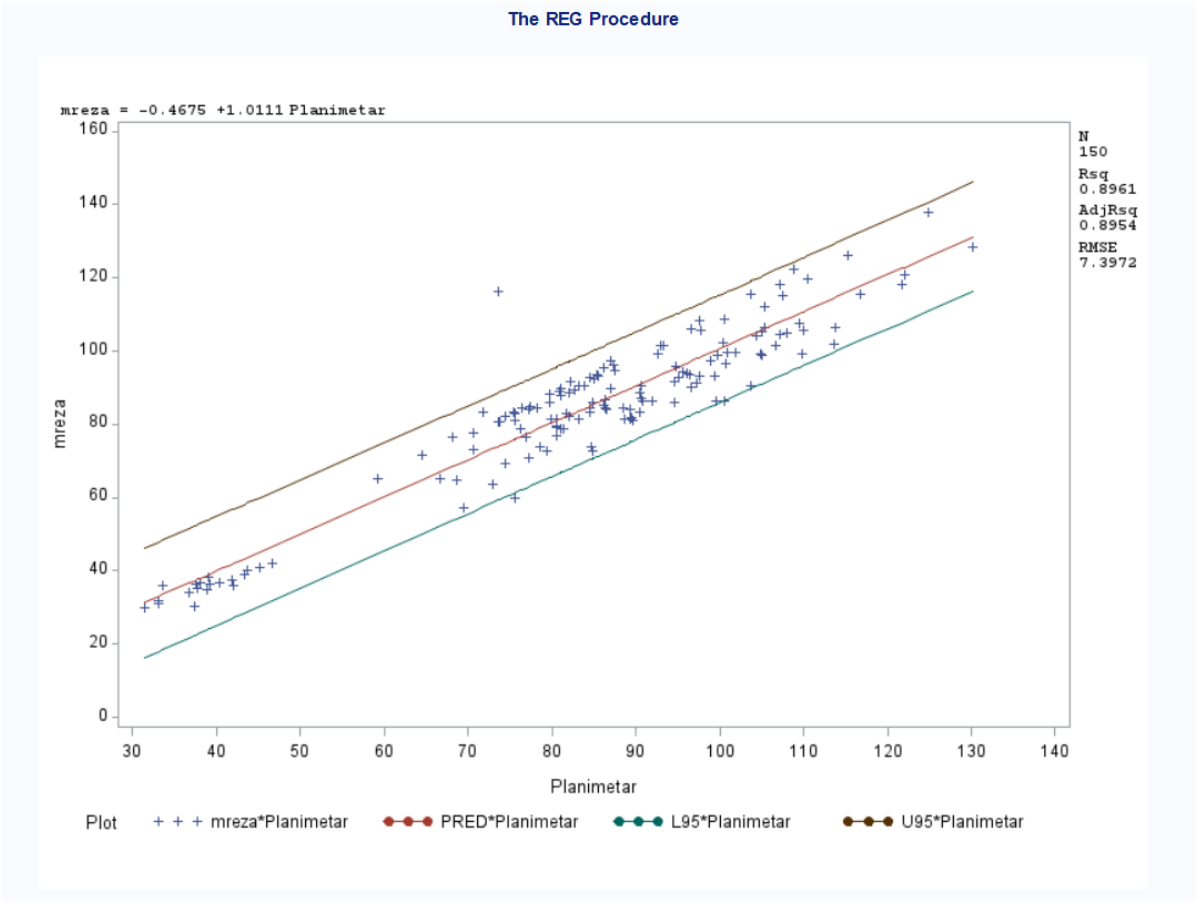

Slika 6.3.1.1. Parametri regresije površina MLD-a (cm^2) određenih polarnim planimetrom i metodom mreže s točkama

Na slici 6.3.1.2. prikazani su parametri regresije površina MLD-a određenih polarnim planimetrom i metodom najveće dužine i širine. Koeficijent regresije između površina MLD-a određenih ovim metodama iznosi 0,90, a jednadžba regresije glasi Y= -0,901+1,0118*X. Podaci pokazuju vrlo sličnu prostornu raspodjelu kao i u prethodnom slučaju.

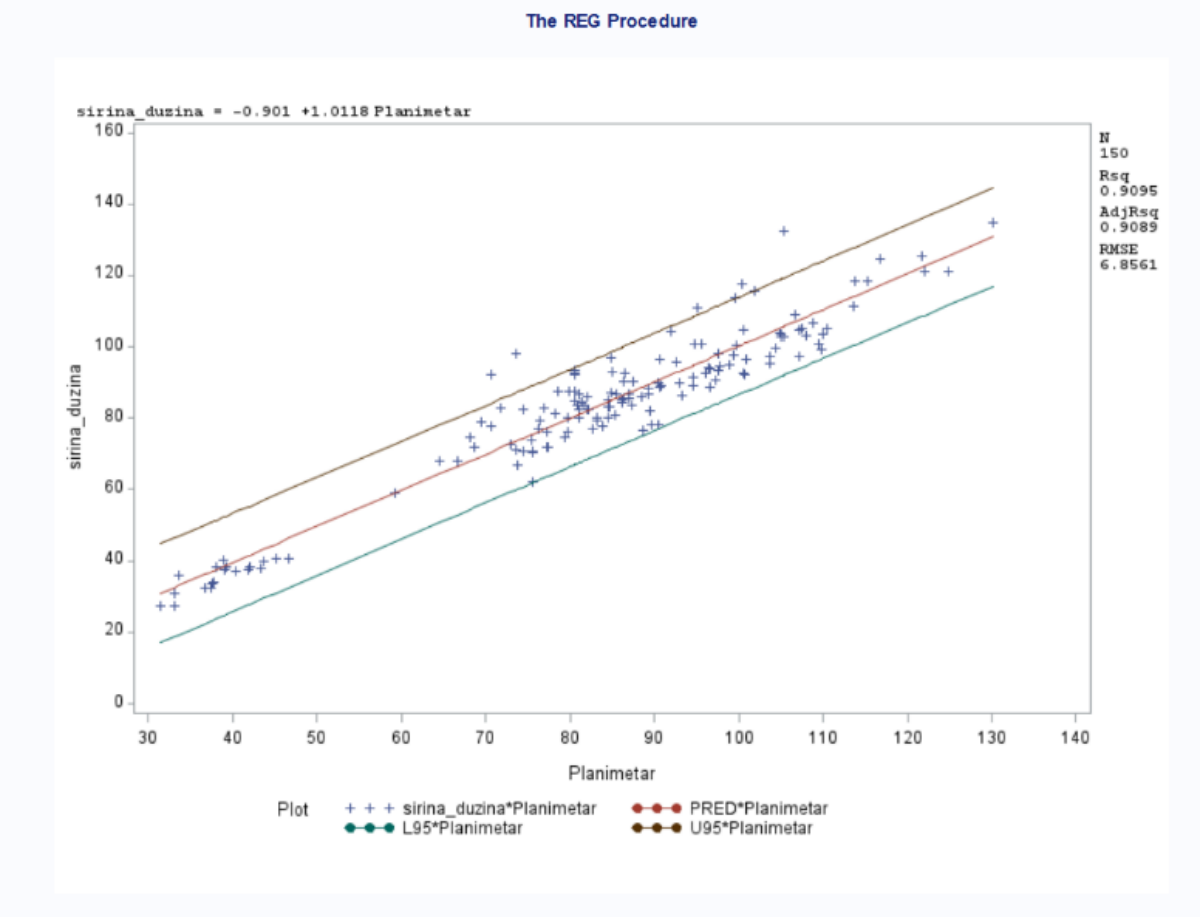

Slika 6.3.1.2. Parametri regresije površina MLD-a (cm^2) određenih polarnim planimetrom i metodom najveće dužine i širine

Na slici 6.3.1.3. prikazani su parametri regresije površina MLD-a određenih polarnim planimetrom i računalnim programom AutoCAD. Između površina MLD-a određenih ovim dvjema metodama utvrđen je najveći koeficijent regresije i iznosi 0,9565, dok jednadžba regresije glasi Y= 2,2615+0,9654*X. Ukoliko se izuzme 5 vrijednosti koje predstavljaju *outlier*-e (prelaze gornju i donju granicu 95% povjerenja), površine MLD-a pokazuju najmanju prostornu dispergiranost u odnosu na prethodne povezanosti između metoda.

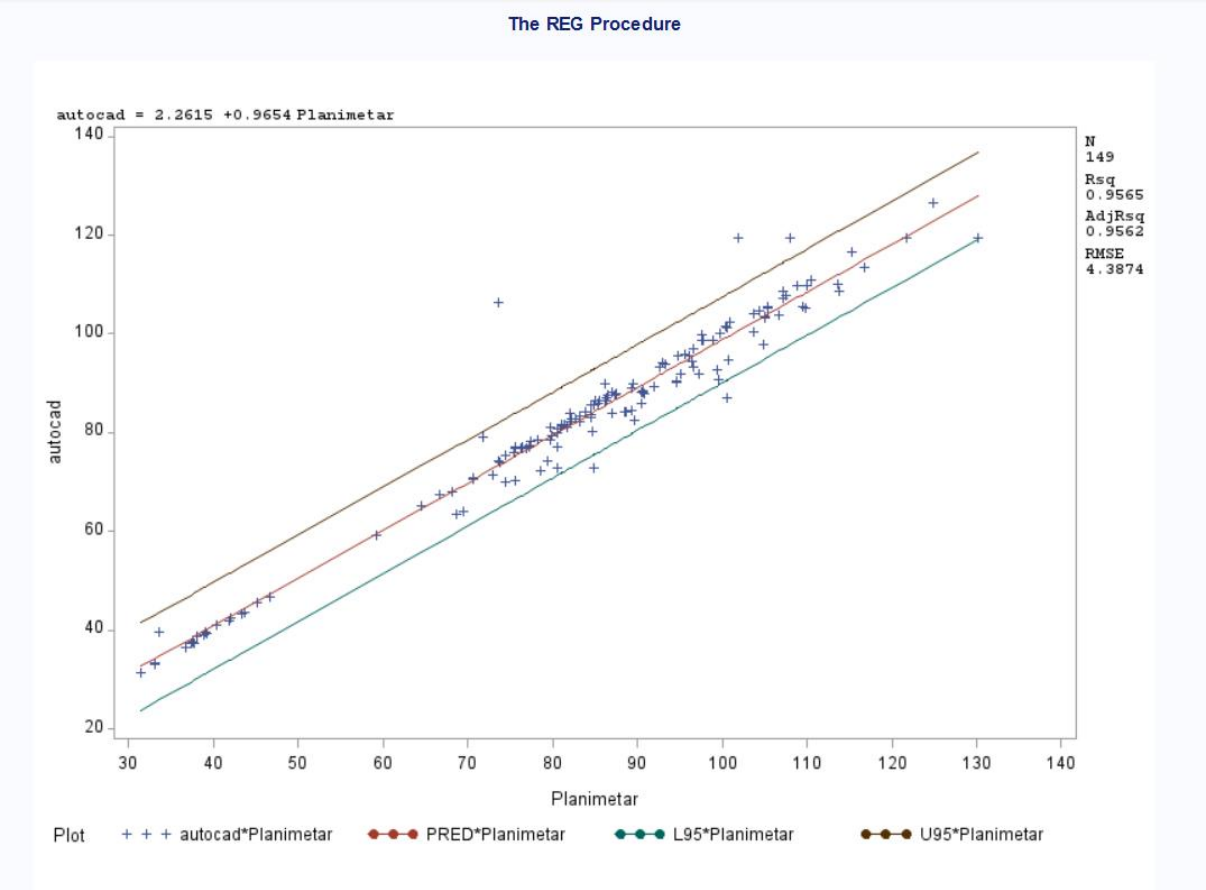

Slika 6.3.1.3. Parametri regresije površina MLD-a (cm^2) određenih polarnim planimetrom i AutoCAD-om

6.3.2. Povezanost površina MLD-a određenih različitim metodama u odnosu na površine MLD-a određene računalnim programom AutoCAD

Na slici 6.3.2.1. prikazani su parametri regresije površina MLD-a određenih metodom mreže s točkama i računalnim programom AutoCAD. Koeficijent regresije površina MLD-a između ove dvije metode iznosi 0,9407, dok jednadžba regresije glasi Y=-3,1855+1,0518*X. Površine pokazuju prostornu agregiranost i unutar su očekivane gornje i donje 95% granice povjerenja.

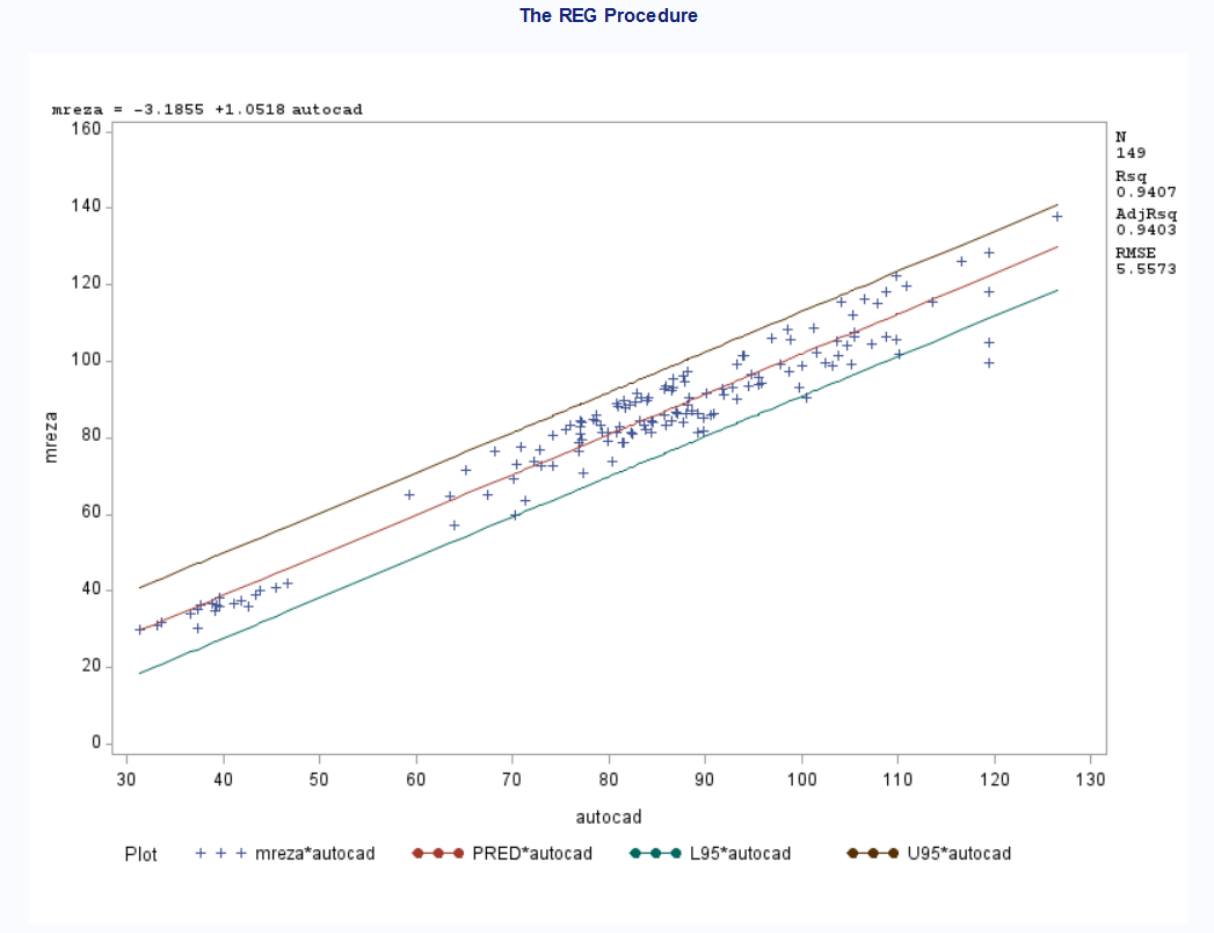

Slika 6.3.2.1. Parametri regresije površina MLD-a (cm^2) određenih prilagođenom metodom mreže s točkama i AutoCAD-om

Na slici 6.3.2.1. prikazani su parametri regresije površina MLD-a određenih metodom najveće dužine i širine i računalnim programom AutoCAD. Koeficijent regresije površina MLD-a između ove dvije metode iznosi 0,900, dok regresijska jednadžba glasi Y=-1,0638+1,0215*X. Prostorni raspored površina je vrlo sličan kao i u slučaju povezanosti površina određenih planimetrom i AutoCAD-om.

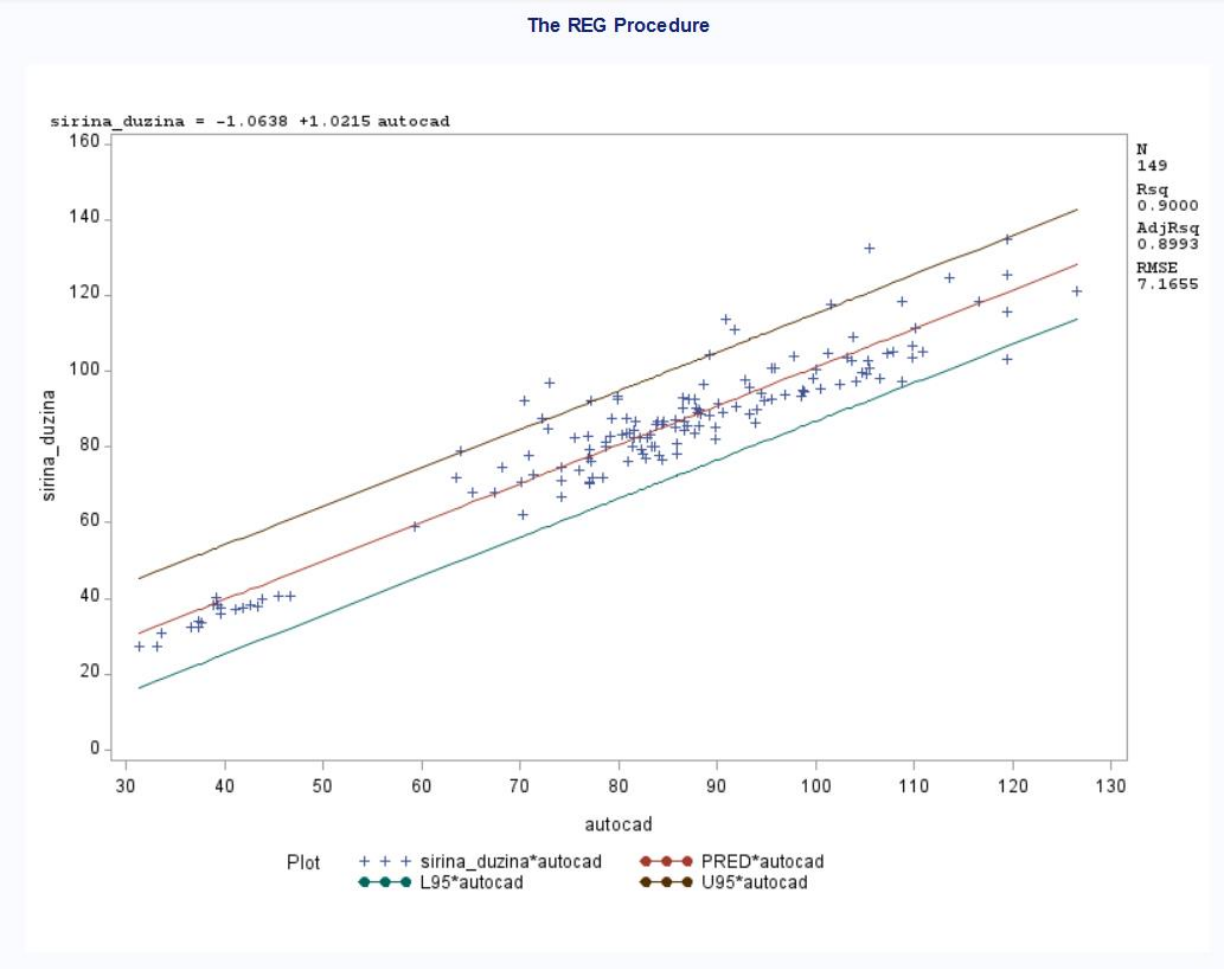

Slika 6.3.2.2. Parametri regresije površina MLD-a (cm^2) određenih metodom najveće širine i dužine i AutoCAD-om

Značajne razlike u površinama MLD-a ovaca određene različitim metodama navodi i Ferreira i sur. (2012.). Slično kao i u predmetnom istraživanju značajno manje površine MLD-a utvrđene su metodom mreže s točkama, no u predmetnom istraživanju utvrđene su veće površine MLD-a planimetrom u odnosu na druge metode. Kao i u predmetnom istraživanju Ferreira i sur. (2012.) navode visoke koeficijente korelacije i regresijske koeficijente između različitih metoda te su digitalna metoda i metoda mreže s točkama imale najveće koeficijente korelacije. Također, Yanez i sur. (2006.) su utvrdili značajne razlike u površinama MLD-a jaradi određenih različitim metodama. Suprotno ovom istraživanju, Yanez i sur. (2006.) su najveće površine MLD-a utvrdili metodom mreže, a najmanju površinu planimetrom. Veću preciznost digitalne metode u odnosu na površine određene planimetrom utvrdili su Karolyi i sur. (2007.). Vrlo visoke pozitivne i značajne koeficijente korelacije između površina MLD-a određenih planimetrom i AutoCAD-om navodi i Akbaş i sur. (2018.).

7. Zaključak

Prema rezultatima istraživanja možemo zaključiti sljedeće:

- površine MLD-a goveda određene različitim metoda značajno ($p<0,05$) su se razlikovale
- prilagođenom metode mreže s točkama utvrđena je značajno ($p<0,05$) veća površina MLD-a u odnosu na ostale metode, dok je u računalnom programu AutoCAD određena najmanja ($p<0,05$) površina MLD-a
- metode mjerenja površina MLD-a prilagođenom mrežom s točkama i metoda s dvije točke subjektivnije su u odnosu na ostale metode
- između metoda su utvrđeni vrlo visoki pozitivni i značajni koeficijenti korelacije i regresije

8. Popis literature

1. Akbaş, A. A., Mehmet, S. A. R. I., Elmaz, Ö., & SAATCI, M. (2018). Comparison of two methods using measurement of the surface area of M. Longissimus dorsi (MLD). Lalahan Hayvancılık Araştırma Enstitüsü Dergisi, 58(2), 77-80.
2. Bergen, R., Crews, Jr., D. H., Miller, S. P., McKinnon, J. J. (2003). Predicting lean meat yield in beef cattle using ultrasonic muscle depth and width measurements. Can. J. Anim. Sci. 83: 429–434.
3. Berry, B . W . 1993. Tenderness of beef loin steaks as influenced by marbling level, removal of subcutâneous fat, and cooking method. Journal of Animal Science, 71: 2412- 2419.
4. Boggs D.L., Merkel R.A., Doumit M.E. (1998): Livestock and Carcasses An Integrated Approach to Evaluation, Grading, and Selection. 5th ed. Kendall/Hunt Publishing Co. Dubuque, IA.
5. Byrne, C. E., Troy, D. J., & Buckley, D. J. (2000). Postmortem changes in muscle electrical properties of bovine M. longissimus dorsi and their relationship to meat quality attributes and pH fall. Meat Science, 54(1), 23-34.
6. Civille , G. & Liska , I. (1975) Modifications and applications to foods of the General
7. Cobos, Á., & Díaz, O. (2015). Chemical composition of meat and meat products. Handbook of food chemistry, 1-32.
   Consumer sensory acceptance and value for beef steaks of similar tenderness, but
8. Domaćinović, M., Antunović, Z., Džomba, E., Opačak, A., Baban, M., & Mužic, S. (2015). Specijalna hranidba domaćih životinja. Poljoprivredni fakultet u Osijeku, Osijek, 10-78.
9. DZZS (2015.-2019.) Poljoprivredna proizvodnja (broj goveda): https://www.dzs.hr/ - pristupljeno 26.7.2021.
10. DZZS (2019.) Osnovne karakteristike potrošnje kućanstva u 2019.(potrošnja govođeg mesa): https://www.dzs.hr/ - pristupljeno 22.9.2021.
11. EUROSTAT (2020.) Broj grla goveda u proizvodnji mesa: https://ec.europa.eu/eurostat/databrowser/view/apro_mt_pann/default/table?lang=en – pristupljeno 24.7.2021.
12. EUROSTAT (2020.) Proizvodnja govođeg mesa u tis. tona na prostoru EU: https://ec.europa.eu/eurostat/databrowser/view/apro_mt_pann/default/table?lang=en – pristupljeno 24.7.2021.
13. EUROSTAT(2020.) Broj goveda u Hrvatskoj: https://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=apro_mt_lscatl&lang=en – pristupljeno 24.7.2021.
14. EUROSTAT(2020.) Proizvodnja govođeg mesa u Hrvatskoj: https://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=apro_mt_pann&lang=en – pristupljeno 24.7.2021.
15. FAOSTAT (1965., 1997., 2019.) Broj grla goveda u proizvodnji mesa: http://www.fao.org/faostat/en/#data/QCL - pristupljeno 24.7.2021.

16. FAOSTAT (1965., 1997., 2019.) Proizvodnja goveđeg mesa u tonama: http://www.fao.org/faostat/en/#data/QCL - pristupljeno 24.7.2021.
17. Faustman, C. and Cassens, R. G. (1990) The biochemical basis for discolouration in fresh meat: a review. Journal of Muscle Foods 1, 21 l-243.
18. Feiner, G. (2006). Meat products handbook: Practical science and technology. Elsevier.Agricultural Research Council (ARC).
19. Ferizbegović, J., Šakić, V., Katica, V., & Crnkić, Ć. (2009). Osnove uzgoja tovnih goveda. Sarajevo, Promocult, 1-118.
20. Ferreira O.G.L, Rossi F.D., Coelho R.A.T., Fucilini V.F., Benedetti M. (2012). Measurement of rib-eye area by the method of digital images. Revista Brasileira de Zootecnia 41(3): 811-814.
Food Flavor and Safety (eds A.M. Spanier , H. Okai & M. Tamura), pp. 78– 97. ACS
Foods sensory texture profile technique . Journal of Texture Studies , 6 (1), 19 – 31 .
21. Hammond, J. (1955). Quality meat production. Journal of the Yorkshire Agricultural Society.
22. Hirzel, R . 1939. Factors Affecting Qua lity in Mutton and Beef with Special Reference to the Proportions of Muscle, Fat and Bone. J. Veterinary Sci. 12:379.
23. Hofmann K. (1994). What is quality? Definition, measurement and evaluation of meat
24. Honikel, K. O., & Kim, C. J. (1985). Über die ursachen der entstehung von PSE-Schweinefleisch. Fleischwirtschaft, 65(9), 1125-1131.
25. Hood, D. E. (1980) Factors affecting the rate of metmyoglobin accumulation in pre-packaged beef. Meat Science 4, 247-265.
26. Hrvatska agencija za poljoprivredu i hranu (2021). Godišnje izvješće Govedarstvo.
27. Ilančić, D. (1975). Kvaliteta mesa od goveda i ocjena na liniji klanja. Jugoinspekt
28. Ivanković, A., & Mijić, P. (2020). Govedarstvo. Agronomski fakultet Sveučilišta u Zagrebu, Zagreb.
29. Jakopović, I., Dadić, M., & Šubaša, M. (2005). Čimbenici koji određuju izbor sustava proizvodnje goveđeg mesa. Stočarstvo: Časopis za unapređenje stočarstva, 59(6), 451-463.
30. Karolyi, D. (2004). Sposobnost vezanja vode u mesu. Meso: prvi hrvatski časopis o mesu, 6(6), 26-30.
31. Karolyi, D., Džidić, A., Salajpal, K., Đikić, M., Jurić, I. (2007). Comparison of two methods for longissimus muscle area measurements. Evaluation of carcass and meat quality in cattle and sheep / Lazzaroni, Carla ; Gigli, Sergio ; Gabina, Dunixi (ur.). Wageningen, The Netherlands: Wageningen Academic Publishers, 2007. str. 175-177
32. Kelava, N., Konjačić, M., Ivanković, A., & Ramljak, J. (2007). Ultrazvuk u funkciji razvoja proizvodnje goveđeg mesa. Stočarstvo: Časopis za unapređenje stočarstva, 61(3), 231-243.
33. Killinger, K. M., Calkins, C. R., Umberger, W. ., Feuz, D. M., Eskridge, K. M. 2004.
34. Klont, R. E., Barnier, V., Brocks L., van Cruijningen, C., van Dijk, A., Eikelenboom, G., HovingBolink, A. H. and Oliver, A. (1998). Colour, colour stability and ageing rate of different veal muscles in relation to pteslaughter blood haemoglobin content. ID-DLO report 98.011, IDDLO, Lelystad.

35. Komolka, K., Albrecht, E., Gotoh, T., & Maak, S. (2017). Abundance of beige and brown adipocyte markers in different adipose depots of cattle at 26 months of age. Advances in Animal Biosciences, 8(s1), s38-s41.
36. Lawrence, T.L.J. & Fowler, V.R., 2002. Tissues: Growth and structure relative to product value for human consumption, In: Growth of Farm Animals, 2nd Edition, CABI Publishing, UK.
37. Lawrie , R.A. & Ledward , D.A. (2006) Chemical and biochemical constituents of meat. In: Meat Science (eds R.A. Lawrie & D.A. Ledward), 7th edn, Chapter 4. Woodhead Publishing , Cambridge, England .
38. Lipavić, G. (2019). Sustav klasiranja goveđih trupova i polovica u Republici Hrvatskoj (Doctoral dissertation, Josip Juraj Strossmayer University of Osijek. Faculty of Agrobiotechical Sciences Osijek. Department for special zootechnique.).
39. Liua, J., Sghaier Chrikib , Marie-Pierre Ellies-Ourya,c , Isabelle Legrandd , Grzegorz Pogorzelskie , Jerzy Wierzbickif , Linda Farmerg , Declan Troyh , Rod Polkinghornei , Jean-François Hocquettea (2020). European conformation and fat scores of bovine carcasses are not good indicators of marbling. Meat Science, 70: 108233, https://doi.org/10.1016/j.meatsci.2020.108233
40. Mackintosh, D.L. (1937). A System of Linear Measurements for Estimating Area of the Ribeye." Report to Review Committee of the Conference on Cooperative Meat Investigations. Volume 1.
41. McGilchrist, P., Alston, C.L., Gardner, G.E., Thomson, K.L., Pethick, D.W. (2012). Beef carcasses with larger eye muscle areas, lower ossification scores and improved nutrition have a lower incidence of dark cutting. Meat Sci. 92: 474–480.
42. Ministarstvo poljoprivrede: KOLK (2020.) Razvrstavanje goveđih trupova u 2020. godini
43. Mojto, J., Zaujec, K., & Gondeková, M. (2009). Effect of age at slaughter on quality of carcass and meat in cows. Slovak Journal of Animal Science, 42(1), 34-37.
44. Narodne novine (2008). Pravilnik o zaštiti životinja pri klanju ili usmrćivanju (Pravilnik preuzima odredbe Direktive br. 93/119/EEZ o zaštiti životinja pri klanju ili usmrćivanju), NN 39/2008
45. Narodne novine (2018). Pravilnik o razvrstavanju i označivanju goveđih trupova i mesa koje potječe od goveda starih manje od 12 mjeseci, NN 71/2018
46. Naumann, H.D. (1952). A Recommended Procedure for Measuring and Grading Beef for Carcass Evaluation. Proc. Reciprocal Meat Conf 5:108.
47. Nishimura, T. , Hattori, A. , Takahashi, K. 1999. Structural changes in intramuscular connective tissue during the fattening of Japanese black cattle: Effect of marbling on beef tenderization. Journal of Animal Science, 77: 93-104.
48. O'Connor M.E. (2011). Method for Grid Assessment of Beef Carcass Ribeye Area. Standards, Analysis and Technology Branch, USDA, Washington.
49. Pethick, D. W., Harper, G. S., & Oddy, V. H. (2004). Growth, development and nutritional manipulation of marbling in cattle: a review. Australian Journal of Experimental Agriculture, 44(7), 705-715.
50. Pliquett, F., Lap, V., Sinz, V., & Reuter, U. (1990). The effect of the oxygen content of the air breathed in on the passive electrical properties of muscle tissue. Zeitschrift fur

experimentelle Chirurgie, Transplantation, und kunstliche Organe: Organ der Sektion Experimentelle Chirurgie der Gesellschaft fur Chirurgie der DDR, 23(2), 116-120.
quality. Meat Focus International. 3(2)

51. Senčić, Đ., Antunović, Z., Kralik, D., Mijić, P., Šperanda, M., Zmaić, K., ... & Novoselec, J. (2010). Proizvodnja mesa. Poljoprivredni fakultet Osijek.
52. Spanier , A. & Miller , J.A. (1993) Role of proteins and peptides in meat flavor . In: Symposium Series No. 528. American ChemicalSociety , Washington, District of Columbia .
53. Troxel, T. R., Gadberry, S., & Barham, B. (2009). Understanding beef carcass information.
54. Unruh, J. A., Waylan, A. T., Campbell, R. E. (1997). Use of video image analysis, ribeye grids, and linear ribeye measurements to predict and compare ribeye areas from carcass left and right sides. Cattlemen's Day 1997 – pristup 15.09.2021. https://newprairiepress.org/kaesrr/vol0/iss1/508
55. Uremović, Z., Uremović, M., Pavić, V., Mioč, B., Mužic, S., & Janječić, Z. (2002). Stočarstvo. Agronomski fakultet Sveučilišta u Zagrebu, 566.
56. USDA (2019.) Nutritivna vrijednost goveđeg mesa: https://fdc.nal.usda.gov/fdc-app.html#/food-details/746763/nutrients - pristupljeno 22.7.2021.
57. Viljoen, H.F., De Kock, H.L. & Webb, E.C., 2002. Consumer acceptability of dark, firm and dry (DFD) and normal pH beef stakes. Meat Sci. 61, 181-185.
58. Webb, E. C. (2003). Carcass fat quality and composition. In Consistency of quality: abstracts and proceedings of the 11th International Meat Symposium, Centurion, South Africa, 29-30 January, 2003 (pp. 48-55).
59. Williams, A. R. (2002). Ultrasound applications in beef cattle carcass research and management. Journal of Animal Science, 80(E-suppl_2), E183-E188.
60. Yanez, E.A. Ferreira, A.C.D., Medeiros, A.N., Pereira Filho, J.M., Teixeira, I.A.M.A., Resende, K.T. (2006). Methodologies for ribeye area determination in goats. Small Rum. Res. 66: 197–200. doi:10.1016/j.smallrumres.2005.09.004

ŽIVOTOPIS

Jelena Kućar rođena je 26.6.1997. godine u Varaždinu. Godine 2016. završila je opći smjer Druge gimnazije u Varaždinu. Iste godine upisuje preddiplomski studij „Ekološke poljoprivrede“ na Agronomskom Fakultetu u Zagrebu. Navedeni smjer uspješno završava 2019. godine kada upisuje diplomski studij „Proizvodnja i prerada mesa“ na istom fakultetu. Odlično se služi Office programskim paketom te fluidno komunicira i razumije engleski jezik. Aktivno sudjeluje u obiteljskom poslu uzgoja i prodaje božićnih drvaca.