

Analiza fenotipske i genetske varijabilnosti proizvodnih svojstava mliječnih goveda uslijed toplinskog stresa

Vučković, Goran

Doctoral thesis / Disertacija

2022

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj:

**Josip Juraj Strossmayer University of Osijek, Faculty of Agrobiotechnical Sciences Osijek /
Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet agrobiotehničkih znanosti Osijek**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:151:468891>

Rights / Prava: [In copyright](#) / [Zaštićeno autorskim pravom.](#)

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



Sveučilište Josipa Jurja
Strossmayera u Osijeku

**Fakultet
agrobiotehničkih
znanosti Osijek**

Repository / Repozitorij:

[Repository of the Faculty of Agrobiotechnical
Sciences Osijek - Repository of the Faculty of
Agrobiotechnical Sciences Osijek](#)



REPUBLIKA HRVATSKA
SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA
U OSIJEKU

FAKULTET AGROBIOTEHNIČKIH ZNANOSTI OSIJEK

Goran Vučković, dipl. ing.

**ANALIZA FENOTIPSKE I GENETSKE VARIJABILNOSTI
PROIZVODNIH SVOJSTAVA MLIJEČNIH GOVEDA USLIJED
TOPLINSKOG STRESA**

DOKTORSKA DISERTACIJA

Osijek, 2022.

REPUBLIKA HRVATSKA
SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA
U OSIJEKU

FAKULTET AGROBIOTEHNIČKIH ZNANOSTI OSIJEK

Goran Vučković, dipl. ing.

**ANALIZA FENOTIPSKE I GENETSKE VARIJABILNOSTI
PROIZVODNIH SVOJSTAVA MLJEČNIH GOVEDA USLIJED
TOPLINSKOG STRESA**

- Doktorska disertacija -

Osijek, 2022.

REPUBLIKA HRVATSKA
SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA
U OSIJEKU

FAKULTET AGROBIOTEHNIČKIH ZNANOSTI OSIJEK

Goran Vučković, dipl. ing.

**ANALIZA FENOTIPSKE I GENETSKE VARIJABILNOSTI
PROIZVODNIH SVOJSTAVA MLIJEČNIH GOVEDA USLIJED
TOPLINSKOG STRESA**

- Doktorska disertacija -

Mentor: prof. dr. sc. Vesna Gantner

Povjerenstvo za ocjenu:

- 1. dr. sc. Pero Mijić, redoviti profesor Fakulteta agrobiotehničkih znanosti Osijek, predsjednik**
- 2. dr. sc. Klemen Potočnik, izvanredni profesor Biotehničkog fakulteta Sveučilišta u Ljubljani, član**
- 3. dr. sc. Vladan Bogdanović, redoviti profesor Poljoprivrednog fakulteta Univerziteta u Beogradu, član**

Osijek, 2022.

REPUBLIKA HRVATSKA
SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA
U OSIJEKU

FAKULTET AGROBIOTEHNIČKIH ZNANOSTI OSIJEK

Goran Vučković, dipl. ing.

**ANALIZA FENOTIPSKE I GENETSKE VARIJABILNOSTI
PROIZVODNIH SVOJSTAVA MLIJEČNIH GOVEDA USLIJED
TOPLINSKOG STRESA**

- Doktorska disertacija -

Mentor: prof. dr. sc. Vesna Gantner

**Javna obrana doktorske disertacije održana je 06. lipnja 2022. godine pred
Povjerenstvom za obranu:**

- 1. dr. sc. Pero Mijić, redoviti profesor Fakulteta agrobiotehničkih znanosti Osijek,
predsjednik**
- 2. dr. sc. Klemen Potočnik, izvanredni profesor Biotehničkog fakulteta Sveučilišta u
Ljubljani, član**
- 3. dr. sc. Vladan Bogdanović, redoviti profesor Poljoprivrednog fakulteta
Univerziteta u Beogradu, član**

Osijek, 2022.

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište Josipa Jurja Strossmayera u Osijeku

Doktorska disertacija

Fakultet agrobiotehničkih znanosti Osijek

Poslijediplomski sveučilišni (doktorski) studij: Poljoprivredne znanosti

Smjer: Stočarstvo

UDK:

Znanstveno područje: Biotehničke znanosti

Znanstveno polje: Poljoprivreda

Grana: Stočarstvo

Analiza fenotipske i genetske varijabilnosti proizvodnih svojstava mliječnih goveda uslijed toplinskog stresa

Goran Vučković, dipl.ing.

Disertacija je izrađena na Fakultetu agrobiotehničkih znanosti Osijek Sveučilišta Josipa Jurja Strossmayera u Osijeku

Mentor: Prof. dr. sc. Vesna Gantner

Sažetak Sve brže i izraženije klimatske promjene u cijelom svijetu rezultiraju sve nepogodnijim uvjetima za stočarsku proizvodnju. U intenzivnoj proizvodnji moraju biti osigurani optimalni mikroklimatski uvjeti. Uvjeti toplinskog stresa dovode do smanjenja konzumacije suhe tvari, mliječnosti, promjene u sastavu mlijeka, porast broja somatskih stanica i pojavnosti mastitisa, narušavaju reprodukciju te dovode do značajnih financijskih gubitaka. Metode smanjivanja utjecaja toplinskog stresa podrazumijevaju optimizaciju hranidbe te primjenu različitih sustava hlađenja (kratkoročne), selekciju mliječnih goveda na otpornost na toplinski stres (dugoročna). Obzirom na nužnost razvoja i implementacije okolišno i ekonomski održivih proizvodnih sustava, glavni cilj istraživanja bio je utvrđivanje fenotipske i genetske varijabilnosti proizvodnih karakteristika mliječnih goveda uslijed toplinskog stresa te, razvoj metodologije genetske evaluacije mliječnih goveda na svojstvo rezistentnosti na toplinski stres. Za statističku analizu korištena je baza podataka kontrole mliječnosti (01/2005. - 12/2013) s približno 3 milijuna rekorda (HAPIH). Za statističku analizu korišten je statistički paket SAS te program VCE-6. Temeljem istraživanja utvrđen je negativan utjecaj povećanja parametara mikroklimat na dnevnu proizvodnost, dok je analiza genetskih parametara indicirala visoke genetske korelacije između dnevne proizvodnje mlijeka u normalnim i uvjetima toplinskog stresa, kao i visoke korelacije između UV-ima u normalnim uvjetima i uvjetima toplinskog stresa. Utvrđeno indicira da će visoko produktivne krave održati jednaku razinu proizvodnje i u uvjetima toplinskog stresa. U cilju pojednostavljenja selekcije mliječnih grla na rezistentnost na toplinski stres, dnevna proizvodnja mlijeka je analizirana kao bivarijantna varijabla (u normalnim i u uvjetima toplinskog stresa), što znači da se za svako grlo procjenjuju dvije uzgojne vrijednosti (UV) (pri selekciji se uvažava UV sukladna uvjetima na farmi).

Broj stranica: 110

Broj slika: 7

Broj tablica: 17

Broj literaturnih navoda: 105

Jezik izvornika: hrvatski (znanstveni radovi engleski)

Ključne riječi: mliječna goveda, toplinski stres, genetska evaluacija, uzgojna vrijednost

Datum obrane: travanj 2022.

Povjerenstvo za obranu:

1. **prof. dr. sc. Pero Mijić** – predsjednik
2. **prof. dr. sc. Klemen Potočnik** – član
3. **prof. dr. sc. Vladan Bogdanović** – član

Disertacija je pohranjena u:

Nacionalna i sveučilišna knjižnica u Zagrebu, Sveučilište Josipa Jurja Strossmayera u Osijeku, Sveučilište u Zagrebu, Sveučilište u Rijeci, Sveučilište u Splitu

BASIC DOCUMENTATION CARD

University of Josip Juraj Strossmayer in Osijek

PhD thesis

Faculty of Agrobiotechnical Sciences Osijek

Postgraduate university study: Agricultural sciences

Course: Animal Breeding

UDK:

Scientific Area: Biotechnical Sciences

Scientific Field: Agriculture

Branch: Animal Breeding

Analysis of phenotypic and genetic variability of production traits of dairy cattle due to heat stress

Goran Vučković, mag. ing.

Thesis performed at Faculty of Agrobiotechnical Sciences Osijek, University of Josip Juraj Strossmayer in Osijek

Supervisor: Prof. dr. sc. Vesna Gantner

Short abstract Increasingly faster and more pronounced climate change worldwide results in increasingly unfavourable conditions for livestock production. Optimal microclimatic conditions must be ensured in intensive production. Heat stress conditions induce a decrease in dry matter consumption, milk yield, changes in milk composition, an increase in the number of somatic cells and the incidence of mastitis, reproductive disorders, and significant financial losses. Methods of reducing the impact of heat stress include optimization of nutrition and the application of different cooling systems (short-term), and selection of dairy cattle for resistance to heat stress (long-term). Given the need to develop and implement environmentally and economically sustainable production systems, the main goal of the study was to determine the phenotypic and genetic variability of production traits of dairy cattle due to heat stress and to develop a methodology for genetic evaluation of dairy cattle for heat stress resistance. For statistical analysis, the milk recording database (01/2005 - 12/2013) with almost 3 million records (HAPIH) was used. The SAS statistical package and the VCE-6 program were used for analysis. Based on the research, the negative effect of increasing microclimate parameters on daily productivity was determined, while the analysis of genetic parameters indicated high genetic correlations between daily milk production under normal and heat stress conditions, as well as high correlations between BVs under normal and heat stress conditions. This indicate that highly productive cows will maintain the same level of production under conditions of heat stress. To simplify the selection of dairy cattle for resistance to heat stress, daily milk production was analyzed as a bivariate variable (under normal and under heat stress) which means that two breeding values (BV) are estimated for each animal (for the selection, BVs following the conditions on the farm should be considered).

Number of pages: 110

Number of figures: 7

Number of tables: 17

Number of references: 105

Original in: Croatian (scientific papers in English)

Key words: dairy cattle, heat stress, genetic evaluation, breeding value

Date of the thesis defense: April, 2022.

Reviewers:

1. **PhD Pero Mijić, professor** – chairman
2. **PhD Klemen Potočnik, professor** – member
3. **PhD Vladan Bogdanović, professor** – member

Thesis deposited in:

National and University Library, University of Josip Juraj Strossmayer in Osijek, University of Zagreb; University of Rijeka; University of Split

KAZALO

1. UVOD	1
2. DOSADAŠNJA ISTRAŽIVANJA	2
3. CILJ ISTRAŽIVANJA I HIPOTEZA	14
4. MATERIJAL I METODE RADA	15
5. REZULTATI ISTRAŽIVANJA S RASPRAVOM	20
4. ZAKLJUČCI.....	37
5. LITERATURA	41
SAŽETAK.....	105
SUMMARY	107

1. UVOD

Svakodnevno svjedočimo sve bržim izraženijim klimatskih promjenama u cijelom svijetu. Navedene će promjene rezultirati sve nepogodnijim klimatskim uvjetima za poljoprivrednu, a osobito stočarsku proizvodnju (IPCC, 2007.). Poljoprivreda, a osobito stočarski sektor, došao je u fokus uslijed značajnog utjecaja na okoliš. Globalno gledajući, stočarski sektor doprinosi ukupnoj emisiji stakleničkih plinova antropogenog porijekla, no s druge strane, može i značajno doprinijeti ublažavanju posljedica klimatskih promjena. Intenzitet emisije stakleničkih plinova, uvelike ovisi o vrsti životinja pa tako goveda najviše doprinose ukupnoj emisiji stočarskog sektora s približno 65% ukupne sektorske emisije. Stočarski sektor, izuzev što doprinosi ukupnoj emisiji stakleničkih plinova antropogenog porijekla, s druge strane, trpi i značajne gubitke uzrokovane klimatskim promjenama. U intenzivnoj proizvodnji mlijeka u stajskom uzgoju, kada mliječne krave većinom borave u farmskim objektima, u svrhu realizacije genetskog proizvodnog potencijala grla, trebali bi biti osigurani optimalni mikroklimatski uvjeti.

U mliječnom govedarstvu, najznačajniji utjecaj na mikroklimu u objektima imaju ambijentalna temperatura te relativna vlaga zraka pri čemu kombinacija visoke ambijentalne temperature i visoke relativne vlažnosti zraka ima najizraženiji efekt. U uvjetima visoke temperature te visoke relativne vlage u objektu krave su u toplinskom stresu što inducira smanjenje konzumacije suhe tvari te smanjenje proizvodnje mlijeka. Osim toga, uslijed toplinskog stresa mijenja se i sastav mlijeka, te dolazi do porasta broja somatskih stanica i pojavnosti mastitisa. Toplinski stres također ima negativni utjecaj i na reproduktivne performance mliječnih krava. Nadalje, u mnogim državama diljem svijeta uvjeti toplinskog stresa induciraju značajne financijske gubitke u proizvodnji mlijeka, pa tako primjerice u SAD-u financijski gubitak iznosi između \$897 i \$1,500 milijuna/godini.

Najčešća mjera toplinskog stresa je temperaturno-humidni indeks (THI) koji predstavlja kombinaciju ambijentalne temperature i relativne vlažnosti (Kibler, 1964.). Postoje brojne metode smanjivanja utjecaja toplinskog stresa na mliječne krave i to kratkoročne te dugoročne. Kratkoročne metode podrazumijevaju optimizaciju hranidbe te primjenu različitih sustava hlađenja u objektima na farmi, dok dugoročne metode znače selekciju mliječnih goveda na otpornost na toplinski stres. Uvažavajući neupitnost klimatskih promjena i neizbježnost povećanja obujma ukupne stočarske te govedarske proizvodnje u Republici Hrvatskoj, proizlazi nužnost razvoja i implementacije okolišno i ekonomski održivih proizvodnih sustava.

2. DOSADAŠNJA ISTRAŽIVANJA

Klimatske promjene su postale naša realnost, te su izuzetno bitan globalni problem. Svakodnevno svjedočimo sve bržim te sve izraženijim klimatskih promjenama u cijelom svijetu. Nadalje, u proteklom se stoljeću, prosječna globalna temperatura povećala za 0,7°C najvećim dijelom uslijed emisije stakleničkih plinova antropogenog porijekla. Navedene će promjene rezultirati sve nepogodnijim klimatskim uvjetima za poljoprivrednu, a osobito stočarsku proizvodnju (IPCC, 2007.). Prema navodima eksperata Organizacije za hranu i poljoprivredu Ujedinjenih naroda (FAO, 2013b) kako bi se umanjile opasnosti klimatskih promjena, nužno je zadržavanje porasta globalne temperature ispod 2°C.

Poljoprivreda, a osobito stočarski sektor, došao je u fokus uslijed značajnog utjecaja na okoliš. Globalno gledajući, stočarski sektor doprinosi ukupnoj emisiji stakleničkih plinova antropogenog porijekla, no s druge strane, može i značajno doprinijeti ublažavanju posljedica klimatskih promjena. Intenzitet emisije stakleničkih plinova, uvelike ovisi o vrsti pa tako goveda najviše doprinose ukupnoj emisiji stočarskog sektora sa oko 65% ukupne sektorske emisije. Sukladno izvješćima FAO-a (2013a.) glavne izvore stakleničkih plinova duž lanca stočarske proizvodnje predstavljaju proizvodnja i prerada krmiva te enterička fermentacija preživača. Također je utvrđeno da proizvodni sustavi preživača niže produktivnosti generiraju više stakleničkih plinova po jedinici proizvoda komparabilno sa visoko proizvodnim sustavima (Gerber i sur., 2011.). Općenito se može reći kako je, intenzitet emisije u proizvodnji mlijeka najniži u industrijskim regijama svijeta (zapadna Europa te Sjeverna Amerika) gdje iznosi manje od 1.7 kg CO²-eq/kg mlijeka dok regije sa nisko proizvodnim mliječnim sustavima karakterizira značajno viša emisija u iznosu do 9 kg CO²-eq/kg mlijeka (FAO, 2013b).

Stočarski sektor, izuzev što doprinosi ukupnoj emisiji stakleničkih plinova antropogenog porijekla, s druge strane, trpi i značajne gubitke uzrokovane klimatskim promjenama. U intenzivnoj proizvodnji mlijeka, tipa stajskog uzgoja s boravkom krava u objektima, genetski potencijal stada može doći do izražaja samo ako su osigurani optimalni mikroklimatski uvjeti. Najznačajniji utjecaj na ambijent mliječnih krava u proizvodnim objektima ima temperatura i relativna vlaga zraka. Međuodnos ambijentalne temperature i vlage zraka iznimno je važan sa stajališta dobrobiti životinja, reprodukcije, proizvodnosti te u konačnici profitabilnosti mliječne farme. Bilo koja ekstremna kombinacija potencijalno je štetna po životinju. U objektima s niskom temperaturom te visokom relativnom vlažnosti zraka povećava se frekvencija pojavnosti infekcija dišnog sustava te vimena. Kombinacija

visoke temperature objekta i niske relativne vlažnosti dovodi do isušivanja mukoznih membrana što posljedično rezultira povećanom prijemljivosti na različite infekcije (Romaniuk i Overby, 2005.). Međutim, daleko najizraženiji utjecaj na mliječne krave ima kombinacija visoka ambijentalna temperatura i visoka relativna vlažnost zraka.

Prema Auernhammer-u (1995.) fiziološka temperatura tijela odraslih goveda kreće se između 38,0 i 39,0 °C, te od 37,5 do 38,8°C prema Jessen-u (2005.), prilikom čega su fiziološke vrijednosti zdravih, kao i bolesnih životinja izložene dnevnim oscilacijama od 0,5°C – 1°C, s minimalnim vrijednostima ujutro oko 6:00 sati i navečer oko 18:00 sati (Lyhs, 1971.; Auernhammer, 1995.; Calegari i Frazzi, 2002.; Baumgartner, 2009.; Vickers i sur., 2010.). Navedene ritmičke dnevne oscilacije temelje se na prilagodljivim zadanim vrijednostima (Lyhs, 1971.). Vremenska razdoblja dnevne minimalne i maksimalne vrijednosti su povezana s drugim utjecajima kao što su uvjeti okoliša, smještaj i godišnje doba (Georg i sur., 2009.; Vickers i sur., 2010.). Kako goveda zoološki pripadaju razredu sisavaca, ona imaju sposobnost stabilnog održavanja tjelesne topline od 36 do 39°C bez značajnog utjecaja temperature okoliša (Jessen, 2000.; 2005.).


U uvjetima visoke temperature i visoke relativne vlage zraka u objektu krave su, vrlo često izložene toplinskom stresu. Stres se definira kao specifična-individualna reakcija jednog organizma na podražaje iz okoline koji dovode do narušavanja fiziološke ravnoteže (Kaufmann i Thun, 1998.; Möstl i Palme, 2002.; RÜTZ, 2010.; Carroll i Burdick Sanchez, 2013.). Ako se organizam nalazi u nepovoljnoj fiziološkoj ravnoteži, tada se narušava njegova sposobnost da se prilagodne svom okruženju (Broom i Johnson, 1993). Za izbjegavanje toplinskog stresa i svih njegovih negativnih učinaka bitno je održavanje temperature okoline, odnosno termoneutralne zone koja se za mliječne krave kreće od 4°C do 16°C (Heidenreich i sur., 2005.; Brade, 2013.; Tober i Loebsin, 2013.). Prema dosadašnjim istraživanjima (Albright i Arave, 1997.; Heidenreich i sur., 2005.; Dussert i Piron, 2012.; Brade, 2013.), postoje različite granice za termoneutralnu zonu kod mliječnih krava što vidljivo u Tablici 1.

Tablica 1.: Granice termoneutralne zone za mliječne krave prema različitim autorima

Termoneutralna zona za mliječne krave	Autori
+4°C do +16 °C	Heidenreich i sur., 2005.
+4°C do +20°C	Brade, 2013.
+2°C do +21°C	Albright i Arave, 1997.
+5°C do +20°C	Dussert i Piron, 2012.

Raspon temperature okoliša u kojem životinje mogu održavati svoju tjelesnu temperaturu konstantnom uz minimalnu brzinu metabolizma ili proizvodnju topline naziva se zona toplinske neutralnosti (B – B' na Slici 1.) ili termoneutralna zona (Bianca, 1968.; Blum, 2003.; Tvt-Merkblatt 100, 2010.; Tober i sur., 2011). Ona je ograničena s donjom kritičnom točkom prema dolje i gornjom kritičnom točkom prema gore. Položaj i širina ove zone ovisi o životinji, veličini tijela, dobi, intenzitetu hranidbe razini i vrsti proizvodnje, kao i o aklimatizaciji, primjerice izolacija dlakom ili masnih naslaga (Bianca, 1968.; Blum, 2003.; TVT-Merkblatt 100, 2010.; Tober i sur., 2011.). Unutar zone toplinske neutralnosti nalazi se zona udobnosti za krave, koja se naziva i zona toplinske indiferentnosti (A – A' na Slici 1.). To je zona temperature okoliša, unutar koje se tjelesna temperatura sa minimalnom termoregulacijskom aktivnosti može održavati na normalnoj razini, tako da organizam nije pod opterećenjem hladnoće niti topline. Prema Albright i Arave (1997.), to je definirano kao područje u kojem se ne javljaju očite potrebe za fiziološkim ili termoregulacijskim mehanizmima, a ukupna proizvodnja topline za dani unos energije je približno konstantna.


Zona hladnog stresa nalazi se ispod donje kritične temperature (B na Slici 1.), koja je oko 9°C za novorođenu telad, a -40°C za mliječne krave s proizvodnjom od 36 kg mlijeka/dan. Ovdje životinja mora tjelesnu temperaturu održati konstantnom, a to može postići ubrzanjem metabolizma i podrhtavanjem mišića. Donja granica smrtnosti nastupa kada temperatura tijela padne za 15 do 20 °C ispod fiziološke tjelesne temperature (Blum, 2003.). Toplinski stres za životinje počinje iznad termoneutralne zone (A') odnosno „zone udobnost“ prema shemi danoj na Slici 1. Ovdje goveda prvenstveno moraju nastojati odavati toplinu u okolinu kako bi održala konstantnu temperaturu tijela. Pri temperaturi okoliša od 25 do 30°C, goveda to mogu činiti putem proširenje perifernih žila, znojenjem i dahtanjem (Nichelmann, 1971.; Blum, 2003.). Ako tjelesna temperatura poraste iznad 42 - 45°C, tada dolazi do toplotnog udara opasnog po život jer je došlo i do smanjenja protoka krvi kroz kožu, putem koje goveda otpuštaju dio topline tijela. U konačnici, sve navedeno izaziva kolaps životinje i gubitka svijesti. Kod većine domaćih sisavaca nastupa toplinska smrt (Jessen, 2000.; Blum, 2003.).



Slika 1. Zone termoregulacije kod domaćih životinja (Bianca, 1968. i Blum, 2003.)


(A – A' = Granica područja toplinske indiferencije („zona udobnosti“); B – B' = područje minimalne proizvodnje topline; B = donja kritična temperatura; B' = gornja kritična temperatura; C – C' = Područje Homeotermije; D – D' = Područje preživljavanja sa: D = donja granična temperatura (niža – smrt od hladnoće); D' = gornja granična temperatura (viša – toplinska smrt)

Kako su goveda relativno otporna na hladnoću, ali osjetljiva na toplinu, kod njih je odavanje topline u okoliš od vrlo važno. Ovakvoj situaciji su naročito izložene mliječne krave s visokom proizvodnjom zbog ubrzanog metabolizma proizvode puno topline. Za dnevnu proizvodnju mlijeka do 50 kg na dan po životinji, potrebno je unijeti minimalno 300 MJ iskoristive energije. Više od jedne trećine apsorbirane energije pretvara se u toplinu i mora se otpustiti (Nichelmann, 1971.; Rößner i sur., 2005.; Brade, 2013.). Krava tjelesne mase od 550 kg i dnevne proizvodnje mlijeka od 30 kg, uz normalan energetske unos od 43.921 kcal/dan i stupanju iskorištenja od 20 - 30%, proizvede dnevno oko 30.000 - 35.000 kcal toplinske energije (Nichelmann, 1971.; Slika 2).




Slika 2. Proizvodnja topline kod mliječnih krava u ovisnosti o proizvodnji i tjelesnoj težini životinje (Nichelmann, 1971.) *EKM – mlijeko korigirano na energiju s 4% mliječne masti; MJ – Megajoule

Mnogi znanstvenici su proučavali odnos između odavanja topline mliječnih krava i proizvodnje mlijeka. Kada je u pitanju odavanje topline, razlikuje se suho ili osjetno odavanje topline, koje ovisi o temperaturnoj razlici između površine tijela i temperature okoline, te vlažno ili evaporativno odavanje topline, koje prvenstveno ovisi o relativnoj vlažnosti okoliša (Slika 2.) (Nichelmann, 1971.; Blum, 2003.); Jessen, 2005.; TVT-Merkblatt 100, 2010.). Odavanje suhe topline uključuje kondukciju, konvekciju i radijaciju (Slika 3). Kod kondukcije ili vodljivosti dolazi do izravnog prijenosa energije iz toplijih u hladnije slojeve, primjerice s ležeće životinje na hladniju površinu, ali i obrnuto (Jessen, 2000.; Blum, 2003.; Jessen, 2005.). To ovisi o efektivnoj veličini kontaktnog područja, temperaturi površine tijela i temperaturi okoline, te o toplinskoj vodljivosti i kapacitetu skladištenja kontaktnog područja sa strane okoliša (Tober i sur., 2011.; Loebsin i sur., 2012.).



Slika 3. Mogućnosti odavanja topline kod goveda (Brade, 2013.)

Tijekom konvekcije, medij poput zraka ili vode apsorbira toplinu i prenosi je. Međutim, ovaj način odavanja topline ovisi o temperaturnoj razlici između medija i površine tijela kao i o veličini efektivne površine tijela i može se podržati, primjerice s povećanjem brzine strujanja zraka ($> 0,2$ m/s) (Nichelmann, 1971.; Blum, 2003.; Jessen, 2005.; Tober i sur., 2011.; Loebstin i sur., 2012.). Kod trećeg načina emisije suhe topline, zračenja ili radijacije, odavanje topline se odvija putem dugih valova ($5 - 20 \mu$) infracrvene zrake (Lyhs, 1971.; Blum, 2003.; Jessen, 2005.; Röbner i sur., 2005.). Ona je pod utjecajem temperature površine dijelova koji zatvaraju prostor, površinskom temperaturom tijela krave kao i veličinom efektivnog područja zračenja (Tober i sur., 2011.; Loebstin i sur., 2012.). Ovaj način odavanja topline je neovisan o materijalu odnosno o dlaci životinje, stoga je odvojen od bilo kojeg transportnog medija i uvijek prisutan čak i ako nema temperaturne razlike između tijela (Röbner i sur., 2005.). S povećanjem temperature okoline, temperaturni gradijent između kože i okoline opada, što predstavlja granicu emisije suhe topline i od oko 20°C dovodi do emisije vlažne topline (Lyhs, 1971.; Nichelmann, 1971.; Slika 4).



Slika 4. Promjena u emisiji topline u ovisnosti o temperaturi staje (prema Strøm i Feenstra, 1980. i Sanker, 2012.).


Vlažno odavanje topline ili evaporacija se događa s jedne strane kroz *perspiratio insensibilis*, odnosno isparavanje vode preko kože, sluznica ili alveola pluća. To je fizički proces koji je neovisan o temperaturi okoline te ga životinja ne može mijenjati. Nadalje, odavanje topline ostvaruje si i isparavanjem vlage na koži (znojenje, cca. 60% emisije vlažne topline kod goveda) odnosno putem respiratornog trakta (prisilno disanje, dahtanje, cca. 40% emisije vlažne topline kod goveda) (Nichelmann, 1971.; Jessen, 2000.; Blum, 2003.; Berman, 2005.; Jessen, 2005.). Hlađenje isparavanjem relativno je neovisno o temperaturi zraka, ali parcijalni tlak vodene pare mora biti veći na koži ili sluznici, nego u okolnom zraku (Jessen, 2000.; Jessen, 2005.; Tober i sur., 2011.). Odavanje topline isparavanjem ili latentne topline prvenstveno je regulirano povećanjem tjelesne temperature jezgre, također na to još može utjecati i povećanje temperature kože (Jessen, 2005.). Kako navodi Jessen (2005.) isparavanje je uglavnom jako ograničeno zbog visokog sadržaja vodene pare u zraku, te je povezano s visokom temperaturom okoline (vlažno – toplo), pri čemu su granice upravljanja dosegnute već pri malim opterećenjima. Međutim, na brzinu isparavanja veliki utjecaj ima brzina strujanja zraka (Lyhs, 1971.; Berman, 2005.; Tablica 2.).

Tablica 2. Čimbenici koji utječu na prijenos topline između životinja i okoline (prema Blum, 2003.)

Način odvođenja topline	Životinja	Okolina
Radijacija (Isijavanje)	Srednja temperatura zračenja površine; Refleksija; Emisija	Srednja temperatura zračenja; Sunčevo zračenje; Refleksija
Konvekcija (Strujanje)	Temperatura površine; Površina za konvekciju; Vrsta površine	Temperatura zraka; Brzina strujanja zraka; Smjer vjetra
Kondukcija (Provodljivost)	Temperatura površine; Kontaktna površina	Temperatura tla; Toplinska provodljivost; Toplinski kapacitet
Evaporacija (Isparavanje)	Stupanj korištenja površine kože	Brzina strujanja zraka; Smjer vjetra


Toplinski stres inducira smanjenje konzumacije suhe tvari te smanjenje proizvodnje mlijeka (West i sur., 1999.). Osim toga, uslijed toplinskog stresa mijenja se i sastav mlijeka, te dolazi do porasta broja somatskih stanica i pojavnosti mastitisa (Bouraoui i sur., 2002.; Brügemann i sur., 2012.; Collier i sur., 2012.; Correa-Calderon i sur., 2004.; Nickerson i sur., 1987.; Ravagnolo i Misztal, 2000.; St-Pierre i sur., 2003.; West, 2003.; Gantner i sur., 2011., Gantner i sur., 2016.; Gantner i sur., 2017.a,b). Toplinski stres također ima negativni utjecaj i na reproduktivne performanse mliječnih krava. Nadalje, stanje toplinskog stresa također utječe na trajanje estrusa, sposobnost koncepcije, fiziologiju uterusa, endokrini status, rast folikula, lutealni mehanizam rani embrionalni te fetalni razvoj goveda (Nardone i sur., 1997.; Collier i sur., 1982.; Wise i sur., 1988.; Bohmanova i sur., 2007.; Ravagnolo i Misztal, 2002.). Najčešća mjera toplinskog stresa je temperaturno-humidni indeks (THI) koji predstavlja kombinaciju ambijentalne temperature i relativne vlažnosti zraka (Kibler, 1964.).

Vrijednost THI pri kojem dolazi do ekspresije toplinskog stresa (*threshold* vrijednost) varira ovisno o provedenim istraživanjima (Bernabucci i sur. (2010.) te Collier i sur. (2012.) - 68; Bouraoui i sur. (2002.) - 69; Du Preez i sur. (1990.a,b), Gantner i sur. (2011.) – 72, Gantner i sur. (2017.a,b)).



Slika 5. Utjecaj različitih vrijednosti THI i odgovarajuće razine stresa na goveda (Izvor: <http://www.bom.gov.au/watl/about-weather-and-climate/risk/risk-example-temperature.shtml>, doradili Mijić i sur. 2018.)

Na Slici 6. su prikazane vrijednosti temperaturno-humidnog indeksa (THI) s graničnim vrijednostima koje pokazuju da se toplinski stres kod životinja javlja već pri niskim temperaturama i niskoj relativnoj vlažnosti zraka (Collier i Zimbelman, 2007.; Zimbelman i Sur., 2009.; Collier i Sur., 2012.; Dussert i Piron, 2012.).



Slika 6. Vrijednosti temperaturno-humidnog indeksa (THI) sukladno ambijentalnoj temperaturi te relativnoj vlazi (Collier i sur., 2012.)

Prilikom primjene THI nastaje problem, koji se temelji na prijašnjim istraživanjima za stvaranje THI-a, u kojima su životinje bile izložene kontinuiranim klimatskim uvjetima. Međutim, u praktičnim uvjetima tijekom dana THI varira, budući da temperatura zraka i relativna vlažnost mogu rasti i smanjivati se (Collier i Zimbelman, 2007.). Stoga su Collier i Zimbelman (2007.) proveli istraživanje u praksi koja je vrijednost THI najprikladniji za procjenu toplinskog stresa, je li to maksimalni, minimalni ili dnevni prosjek. Autori su došli do saznanja, kako je dnevni prosjek THI-a od dva prethodna dana, imao najveći utjecaj na unos hrane i količinu mlijeka za jedan dan.

Kada se koristi THI, također treba napomenuti kako on ne uzima u obzir utjecaj dlake, brzinu strujanja zraka ili zračenja s obzirom na toplinsko opterećenje goveda (Berman, 2005.; Collier i Zimbelman, 2007.; Gaughan i sur. ., 2008.; Mačuhová i sur., 2008.; Zimbelman i sur., 2009.; Fiedler i sur., 2012.). Čimbenici upravljanja ili životinjski čimbenici, kao što su razlike u pasmini, također se ne uzimaju u obzir (Gaughan i sur., 2008.).

Učinci toplinskog stresa, između ostalog, ovise i o postojećim, a klimatskim čimbenicima prije svega o samom trajanju stresa (Klein, 1984.). Posljedice su višestruke, od nikakvog ili samo neznatnog učinka prilikom kratkog izlaganja toplinskom stresu, pa do smrti životinja pod ekstremnim toplinskim stresom (Brown-Brandl i sur., 2005.; Zimbelman, 2008.; Collier i sur., 2012.). Navedene posljedice prikazane su u Tablici 3. Kada su krave pod utjecajem toplinskog stresa, one prvo pokušavaju smanjiti vlastitu proizvodnju topline i to, na način smanjenja unosa hrane, budući da se najviše topline stvara u buragu prilikom fermentacije. Osim toga krave iz obroka biraju što više žitarica i proteina, jer oni prilikom probave proizvode manje topline od zelene krme (Brown-Brandl i sur., 2005.; Dussert i Piron, 2012.). Dolazi do smanjenja strukturne učinkovitosti obroka te postoji opasnost od pojave (subkliničke) acidoze buraga (Van Laer i sur., 2014.; Yoon, 2014.).

Tablica 3. Posljedice toplinskog stresa na mliječne krave ovisno o intenzitetu opterećenja (Collier i sur., 2012.)

THI	Razina Stresa	Simptomi
< 68	Bez toplinskog stresa	
68 – 71	Blagi toplinski stres	➤ posjećivanje zasjenjenih mjesta ➤ ubrzana frekvencija disanja (> 60 udisaja/min) ➤ širenje krvnih žila ➤ povišena tjelesna temperatura (> 38,5 °C) ➤ prvi utjecaj na proizvodnju mlijeka
72 – 79	Umjereni toplinski stres	➤ povećana proizvodnja sline ➤ ubrzana frekvencija disanja (> 75 udisaja/min) ➤ povećan broj otkucaja srca ➤ povišena tjelesna temperatura (> 39,0 °C) ➤ smanjenje unosa hrane ➤ povećana konzumacija vode ➤ smanjenje proizvodnje mlijeka ➤ smanjenje plodnosti
80 – 89	Jaki toplinski stres	➤ stvaranje nelagode zbog povećanja simptoma ➤ ubrzana frekvencija disanja (> 85 udisaja/min) ➤ tjelesna temperatura > 40°C
➤ 90	Opasnost	➤ pojava smrtnih slučajeva

Postoje brojne metode kako smanjiti utjecaj toplinskog stresa na mliječne krave. Obzirom na vrijeme potrebno za realizaciju te učinak primjene, metode se mogu klasificirati kao kratkoročne i dugoročne. Kratkoročne metode podrazumijevaju optimizaciju hranidbe te primjenu različitih sustava hlađenja u objektima na farmi, kao na Slici 7. (Kadzere i sur., 2002.; West, 2003.) dok dugoročne metode znače selekciju mliječnih goveda na otpornost na toplinski stres (Bohmanova, 2006.).



Slika 7. Ventilatori u staji za odvođenje topline putem strujanja zraka (foto: Vučković, G.)

Činjenici kako mjere smanjenja utjecaja toplinskog stresa, trebaju biti sastavni dio uspješnih proizvodnih sustava u mliječno-govedarskom sektoru, u prilog govori i studija Reiczigela i sur. (2009.) provedena na području Mađarske, autori studije predviđaju kako će uslijed klimatskih promjena narednih 30 godina porasti broja dana u godini sa izraženim toplinskim stresom za više od 300% odnosno s 5 na 17 dana.

Uvažavajući neupitnost klimatskih promjena i neizbježnost povećanja obujma ukupne stočarske te govedarske proizvodnje u Republici Hrvatskoj, na način povećanja produktivnosti i broja grla, kao imperativ se nameće razvoj i implementacija okolišno i ekonomski održivih proizvodnih sustava. Obzirom na navedeno, nužna je provedba analize fenotipske i genetske varijabilnosti proizvodnih karakteristika mliječnih goveda uslijed toplinskog stresa, zatim razvoj metodologije genetske evaluacije mliječnih goveda na svojstvo rezistentnosti na toplinski stres. Provedba navedenoga, omogućiti će uvođenje novih svojstava u uzgojne programe te kreiranje novih, rezistentnijih i efikasnijih generacija mliječnih goveda.

3. CILJ ISTRAŽIVANJA I HIPOTEZA

Glavni cilj istraživanja ove doktorske disertacije je utvrđivanje fenotipske i genetske varijabilnosti proizvodnih svojstava mliječnih goveda uslijed toplinskog stresa te, temeljem dobivenih rezultata, razvoj metodologije genetske evaluacije mliječnih goveda na svojstvo rezistentnosti na toplinski stres.

Sa svrhom realizacije navedenoga potrebno je realizirati sljedeće ciljeve:

1. Određivanje fenotipske varijabilnosti istraživanih grupa svojstava odnosno:
 - a. statistička analiza proizvodnih karakteristika (dnevna količina te sastav mlijeka) mliječnih krava pod uzgojno-seleksijskim radom,
 - b. statistička analiza mikroklimatskih parametara (ambijentalna temperatura i vlaga) u objektima.
2. Određivanje povezanosti između istraživanih grupa svojstava.
3. Razvoj i odabir optimalnih statističkih modela za procjenu značajnosti utjecaja mikroklimatskih parametara na varijabilnost proizvodnih karakteristika mliječnih krava.
4. Procjena komponenti varijance i kovarijance odabranih statističkih modela.
5. Procjena uzgojnih vrijednosti mliječnih krava za svojstvo rezistentnosti na toplinski stres.

Hipoteza je istraživanja da u populaciji mliječnih goveda u Republici Hrvatskoj postoji varijabilnost u rezistentnosti na toplinski stres koja omogućava genetsku evaluaciju grla pod kontrolom mliječnosti i selekciju životinja rezistentnijih na nepovoljne mikroklimatske parametre u farmskim objektima.

4. MATERIJAL I METODE RADA

Za statističku analizu korištena je baza podataka mliječnih goveda koja su uključena u provedbu kontrole proizvodnosti. Navedena baza podataka preuzeta je od Hrvatske agencije za poljoprivredu i hranu (HAPIH) koja je ovlaštena od strane ICAR-a za provedbu kontrole proizvodnosti u Republici Hrvatskoj.

Dnevna količina i sastav mlijeka

Prilikom statističke analize proizvodnih karakteristika (dnevna količina te sastav mlijeka) mliječnih krava pod uzgojno-seleksijskim radom korištena je baza podataka provedbe kontrole mliječnosti. U Republici Hrvatskoj kontrola mliječnosti provodi se sukladno AT4/BT4 metodi kontrole što znači kako se kontrola provodi svaka 4 tjedna od strane djelatnika HPA (AT4) ili ovlaštenog djelatnika farme (BT4). Obzirom da je u primjeni alternativna metoda kontrole mliječnosti, mjerenje na kontrolni dan podrazumijeva mjerenje količine mlijeka te uzorkovanje s ciljem analize sastava pri jutarnjoj ili večernjoj mužnji. Analiza uzoraka mlijeka obavlja se u Središnjem laboratoriju za kontrolu mlijeka (SLKM) Hrvatske agencije za poljoprivredu i hranu (HAPIH) smještenom u Križevačkoj Poljani. U navedenom laboratoriju se ispitivanja obavljaju sukladno akreditiranim laboratorijskim metodama, odnosno infracrvena spektrofotometrija – određivanje udjela mliječne masti, bjelančevina i laktoze, te fluoro-opto-elektronska metoda – brojanje somatskih stanica. Nadalje, u laboratoriju se koriste sljedeći uređaji: za određivanje sastava mlijeka Milcoscan FT6000, te za broj somatskih stanica Fossomatic FC5000.

Pri svakoj mužnji tijekom kontrole mliječnosti bilježi se vrijeme, kao i prethodne mužnje. To se radi iz razloga izračuna intervala između uzastopnih mužnji.

Dnevna količina mlijeka, dnevni sadržaj mliječne masti i bjelančevina izračunava se temeljem parcijalnih vrijednosti (jutarnja/večernja mužnja) pomoću linearne jednadžbe koja uvažava utjecaj intervala između mužnji. Utvrđeni dnevni sadržaj laktoze u mlijeku nije korigiran Dnevne količine komponenti mlijeka izračunavaju se temeljem sadržaja i izračunate dnevne količine mlijeka. Logična kontrola podataka vrši se temeljem standarda ICAR-a (2003.).

Sukladno kontrolnom danu kreirane su podgrupe mjeseca kontrole (M1 – siječanj, M2 – veljača, ..., M12 – prosinac), dok su sukladno datumu teljenja krave razvrstati u podgrupe mjeseca teljenja (C1 – siječanj, C2 – veljača, ..., C12 – prosinac).

Mikroklimatski parametri u farmskim objektima

Temperatura zraka i relativna vlaga u farmskim objektima mjere se na kontrolni dan prilikom provedbe kontrole mliječnosti. Vrijednosti temperaturno-humidnog indeksa (THI) izračunavaju se sukladno formuli (Kibler, 1964.):

$$THI = 1.8 \times Ta - (1 - RH) \times (Ta - 14.3) + 32$$

gdje je:

Ta – izmjerena temperatura zraka u objektu u °C,

RH – izmjerena relativna vlaga (%).

Temeljem ovih baza podataka kreirana je skupna baza u kojoj je provedena logična kontrola podataka te su definirane potrebne nove varijable.

Za analizu fenotipske varijabilnosti proizvodnih svojstava (dnevna količina te sastav mlijeka) i parametara mikroklimе (ambijentalna temperatura, relativna vlaga te temperaturno-humidni indeks) te korelacije između analiziranih skupina svojstava korišteni su podaci kontrole mliječnosti krava holstein i simentalne pasmine prikupljeni su tijekom redovne kontrole mliječnosti u razdoblju od siječnja 2005. do prosinca 2013. godine.

Zapisi na kontrolni dan koji su bili izvan zadanih kriterija vrijednosti, stadij laktacije (< 5 dana i > 500 dana), dob pri prvom teljenju (< 21 i > 36 mjeseci), nedostatkom informacije o redolijedu laktacije ili pasmine, zatim nedostajućim ili nelogičnim vrijednostima dnevne proizvodnosti (prema ICAR-u standardi, 2017.), te nedostajućim ili nelogičnim vrijednostima Ta i RH izbrisani su iz baze podataka. Nakon logičke kontrole baza podataka sastojala se od 1.636.192 zapisa na kontrolni dan 117.659 krava simentalne pasmine (sa 10.599 farmi) i 1.275.713 zapisa na kontrolni dan 90.159 krava holstein pasmine (sa 6.701 farmi). Sukladno redolsijedu laktacije, krave su podijeljene u četiri razreda kako slijedi: I., II., III. i IV. (životinje u četvrtoj i višoj laktaciji). Nadalje, ovisno o lokaciji farme, zapisi na kontrolni dan su podijeljeni u tri uzgojna područja: istočno, centralno i mediteransko. Nadalje, prema datumu kontrole mliječnosti, zapisi na kontrolni dan su podijeljeni u četiri sezone kontrole: proljeće, ljeto, jesen i zima.

Na istoj je bazi podataka, za procjenu utjecaja parametara mikroklimе (ambijentalna temperatura, T, relativna vlaga, RH i temperaturno-humidni indeks, THI) na varijabilnost proizvodnih svojstava (dnevna količina i sastav mlijeka) u mliječnim krava razvijeno je i testirano nekoliko statističkih modela. Na temelju parametara evaluacije (R^2_{adj} , RMSE modela) odabrana su dva statistička modela kao optimalna za daljnju statističku analizu.

Za evaluaciju predikcijskih mogućnosti primijenjenih statističkih modela korištene su sljedeće evaluacijske mjere:

Korigirani koeficijent determinacije, R^2_{adj} , koji mjeri udio varijabilnosti pojašnjene modelom:

$$R^2_{adj} = 1 - \frac{ME_E}{MS_T}$$

gdje je:

- MS_E – varijanca pogreške modela,
- MS_T – ukupna varijanca modela.

Standardna devijacija pogreške, RMSE, odnosno standardna devijacija razlike između stvarnih i vrijednosti procijenjenih modelom:

$$RMS_E = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y})^2}{n}}$$

gdje je:

- n – broj mjerenja,
- y_i – stvarna vrijednost,
- $\hat{y}$ – vrijednosti procijenjene modelom.

Odnos između dnevnih svojstava mliječnosti (količine i sadržaja) i parametara mikroklimat (T, RH i THI) analiziran je korištenjem PROC GLM u SAS-u (SAS Institute Inc., 2000.) prema sljedećem modelu 1:

$$y_{ijklmn} = \mu + b_1(d_i / 305) + b_2(d_i / 305)^2 + b_3 \ln(305 / d_i) + b_4 \ln^2(305 / d_i) + S_j + A_k + R_l + x_{ijklm} + e_{ijklm}$$

Varijabilnost dnevnih svojstava mliječnosti (količine i sadržaja) uslijed toplinskog stresa testirana je metodom najmanjih kvadrata za postavljene vrijednosti THI (68, 72) korištenjem PROC GLM u SAS-u prema sljedećem modelu 2:

$$y_{ijklmn} = \mu + b_1(d_i / 305) + b_2(d_i / 305)^2 + b_3 \ln(305 / d_i) + b_4 \ln^2(305 / d_i) + S_j + A_k + R_l + T_m + x_{ijklm} + e_{ijklm}$$

gdje je:

y_{ijklm} = procijenjena vrijednost dnevnog svojstva mliječnosti (količina i sadržaj);

μ = intercept;

b_1, b_2, b_3, b_4 = regresijski koeficijent;

d_i = stadij laktacije ($i = 5$ do 500 dana);

S_j = fixed utjecaj sezone kontrole mliječnosti j ($j = 1/2005$ do 12/2012);

A_k = fiksni utjecaj dobi pri prvom teljenju k ($k = 21$ do 36 mjeseci);

R_l = fiksni utjecaj regije uzgoja l ($l =$ istočna, središnja, i mediteranska Hrvatska);

x_{ijklm} = fiksni utjecaj mikroklimatskih parametara kao linearna regresija – model 1;

T_m = fiksni utjecaj THI razreda ($m = 0$ (normalni uvjeti – vrijednosti ispod zadanog praga) or $m = 1$ (uvjeti toplinskog stresa – vrijednosti jednake te iznad zadanog praga)) – model 2; e_{ijklm} = ostatak.

Značajnost razlika procijenjenih vrijednosti ovisno o razredu THI-a u modelu 2 ispitana je t-testom. Statistička analiza je provedena zasebno za svaku pasminu (holstein i simentalaska).

Na istoj je bazi podataka, provedena procjena komponenti varijance za proizvodnju mlijeka kao i procjena uzgojne vrijednosti za svojstva mliječnosti u uvjetima toplinskog stresa definiranog kao različite granične vrijednosti i za holstein pasminu krava THI (68, 70 i 72) te za simentalasku pasminu THI (72, 74 i 76).

Funkcija (f) THI-a kreirana je kako slijedi:

$$f(THI) = \begin{cases} 0, & \text{if } THI \leq THI_{threshold} \\ 1, & \text{if } THI > THI_{threshold} \end{cases}$$

gdje je THI_{prag} definiran na 68, 70, i 72 u holstein krava, te na 72, 74, i 76 u simentalaskih krava.

Za procjenu komponenti varijance za proizvodnju mlijeka kao i za procjenu uzgojnih vrijednosti za svojstva mliječnosti mliječnih krava holstein i simentalaske pasmine u uvjetima toplinskog stresa korišten je sljedeći bivarijantni model:

$$y_{ijklmnop} = \mu + b_1(d_i/305) + b_2(d_i/305)^2 + b_3 \ln(305/d_i) + b_4 \ln^2(305/d_i) + S_j + b_5 ac_k + b_6 ac_k^2 + R_l + P_{im} + Pe_n + Hy_o + a_p + e_{ijklmnop}$$

gdje je:

where $y_{ijklmnop}$ = procijenjena svojstva mliječnosti pri $THI = 0$ i $THI = 1$;

μ = intercept;

$b_1, b_2, b_3, b_4, b_5, b_6$ = regresijski koeficijenti;

d_i = stadij laktacije ($i = 5, \dots, 500$ dana);

S_j = fiksni utjecaj sezone teljenja j ($j = 1/2005, 2/2005, \dots, 4/2012$);

ac_k = fiksni utjecaj dobi pri teljenju kao kvadratna regresija;

R_l = fiksni utjecaj regije uzgojal ($l = 01, \dots, 16$);

P_{im} = fiksni utjecaj redoslijeda laktacije m ($m = 01, \dots, 07$; ugniježđen unutar laktacijske krivulje);

Pe_n – slučajni utjecaj permanentne okoline za životinju;

Hy_o – slučajni utjecaj interakcije između stada i godine;

a_p – slučajni aditivni genetski efekt za životinju;

$e_{ijklmnop}$ = slučajni ostatak.

Za pripremu podataka, logičnu kontrolu varijabli te statističku analizu korišten je statistički paket SAS (SAS Institute Inc., 2000). Prilikom procjene komponenti varijance i kovarijance odabranih statističkih modela, te procjene uzgojnih vrijednosti mliječnih krava za svojstvo rezistentnosti na toplinski stres korišten je program VCE-6, version 6.0.3-dev (KOVAČ i sur., 2012.). Za grafički obradu i prezentaciju rezultata korišten je SAS Enterprise Guide (SAS Institute Inc., 2000).

5. REZULTATI ISTRAŽIVANJA S RASPRAVOM

5.1. Analiza proizvodnih svojstva i mikroklimatskih parametara na farmama mliječnih krava

Kao preduvjeti za genetsku evaluaciju i selekciju mliječnih goveda na rezistentnost na toplinski stres, ciljevi ovog dijela istraživanja bili su:

1. Određivanje fenotipske varijabilnosti analiziranih skupina svojstava:
 - a. statistička analiza proizvodnih svojstava (dnevna količina i sastav mlijeka) mliječnih krava u selekciji,
 - b. statistička analiza parametara mikrokline (ambijentalna temperatura i vlaga) u stajama;
2. Određivanje korelacije između analiziranih skupina osobina.

Varijabilnost proizvodnih svojstava mliječnih krava odnosno dnevne količine mlijeka, dnevnog sadržaja masti, bjelančevina, laktoze i uree, te broja somatskih stanica prema pasmini i paritetu, posebno za svaku regiju (istočna, središnja i mediteranska Hrvatska) prikazana je u Tablicama 4, 5 i 6.

Tablica 4. Varijabilnost svojstava (srednja vrijednost; SD) dnevne proizvodnje u skladu s pasminom i paritetom u istočnoj Hrvatskoj

Svojstvo/ Paritet	Holstein				Simentalac			
	I.	II.	III.	IV.	I.	II.	III.	IV.
DMY	21,50±7,8	24,23±10,4	24,57±10,7	23,45±10,5	15,42±5,1	16,60±6,1	17,20±6,4	16,61±6,2
DFC	4,09±0,9	4,13±1,0	4,13±1,0	4,11±1,0	4,12±0,9	4,12±0,9	4,10±0,9	4,06±0,9
DPC	3,41±0,4	3,44±0,5	4,00±0,5	3,36±0,45	3,45±0,5	3,49±0,5	3,47±0,5	3,43±0,5
DLC	4,53±0,2	4,44±0,2	4,41±0,2	4,36±0,26	4,57±0,2	4,50±0,2	4,46±0,2	4,42±0,3
DUC	23,24±9,0	23,95±9,2	23,49±9,3	22,67±9,6	21,34±11,6	21,54±11,7	21,70±11,7	21,28±11,6
SCC	16,42±1,9	16,77±2,1	17,07±2,1	17,34±2,2	16,12±2,0	16,44±2,1	16,64±2,1	17,03±2,2

* DMY – dnevna mliječnost (kg); DFC – dnevni sadržaj masti (%); DPC – dnevni sadržaj proteina (%); DLC – dnevni sadržaj laktoze (%); DUC – dnevni sadržaj uree (mg/ml); SCC – log transformacija somatskih stanica

U istočnoj Hrvatskoj najveća prosječna dnevna mliječnost (DMY) utvrđena je kod pasmine holstein u trećoj laktaciji, dok je najniža (DMY) bila kod simentalke pasmine u prvoj laktaciji. Dnevni udio masti (DFC) bio je najmanji kod simentalke pasmine u četvrtoj laktaciji, dok je dnevni udio proteina (DPC) i dnevni sadržaj laktoze (DLC) bio najniži kod

holstein pasmine u četvrtoj laktaciji. Dnevni sadržaj uree (DUC) bio je najveći u drugoj laktaciji kod holstein pasmine. Konačno, najveći broj somatskih stanica utvrđen je u četvrtom paritetu kod obje pasmine, sa većom vrijednost kod holstein pasmine.

Tablica 5. Varijabilnost svojstava (srednja vrijednost; SD) dnevne proizvodnje u skladu s pasminom i paritetom u središnjoj Hrvatskoj

Svojstvo/ Paritet	Holstein				Simentalac			
	I.	II.	III.	IV.	I.	II.	III.	IV.
DMY	18,31±6,4	19,55±7,8	19,91±8,0	19,00±7,7	14,86±5,3	15,74±6,2	16,05±6,3	15,17±5,9
DFC	4,26±0,9	4,31±0,9	4,28±0,9	4,20±0,9	4,27±0,8	4,22±0,9	4,22±0,9	4,11±0,9
DPC	3,40±0,5	3,46±0,5	3,41±0,5	3,36±0,5	3,45±0,5	3,51±0,5	3,47±0,5	3,43±0,5
DLC	4,53±0,2	4,45±0,2	4,41±0,2	4,37±0,2	4,57±0,2	4,50±0,2	4,47±0,2	4,43±0,2
DUC	21,13±10,4	20,85±10,4	20,18±10,4	19,43±10,3	19,77±10,2	19,69±10,4	19,45±10,3	18,86±10,2
SCC	16,59±2,1	16,99±2,1	17,23±2,2	17,62±2,2	16,08±2,0	16,41±2,1	16,65±2,1	17,03±2,2

* DMY – dnevna mliječnost (kg); DFC – dnevni sadržaj masti (%); DPC – dnevni sadržaj proteina (%); DLC – dnevni sadržaj laktoze (%); DUC – dnevni sadržaj uree (mg/ml); SCC – log transformacija somatskih stanica

Kod mliječnih krava uzgajanih u središnjoj Hrvatskoj, najniža vrijednost dnevne količine mlijeka (DMY) utvrđena je kod simentalke pasmine u prvoj laktaciji, a najveća dnevna proizvodnja mlijeka bila je kod holstein pasmine u trećoj laktaciji. Dnevni udio masti (DFC) bio je najveći kod holstein pasmine u drugoj laktaciji, dok su dnevni udio proteina (DPC) i dnevni sadržaj laktoze (DLC) bili najniži u četvrtoj laktaciji kod holstein pasmine. Dnevni sadržaj uree (DUC) bio je najmanji u četvrtoj laktaciji, kod simentalke pasmine, dok je najviši kod holstein pasmine u prvoj laktaciji. Slično kao kod krava uzgajanih u istočnom području, najveći je broj somatskih stanica utvrđen je kod obje pasmine krava u četvrtoj laktaciji.

Tablica 6. Varijabilnost svojstava (srednja vrijednost; SD) dnevne proizvodnje u skladu s pasminom i laktacijom u mediteranskom području

Svojstvo/ Paritet	Holstein				Simentalac			
	I.	II.	III.	IV.	I.	II.	III.	IV.
DMY	21,71±7,7	23,44±9,9	24,20±10,5	22,61±10,7	13,51±5,0	14,19±5,9	14,43±6,1	14,20±5,3
DFC	3,84±0,8	3,88±0,9	3,86±0,9	3,81±0,9	4,17±0,9	4,13±0,9	4,16±1,0	4,12±1,0
DPC	3,35±0,4	3,38±0,4	3,34±0,4	3,26±0,4	3,48±0,4	3,49±0,5	3,43±0,5	3,43±0,4
DLC	4,53±0,2	4,43±0,2	4,40±0,2	4,33±0,3	4,54±0,2	4,48±0,2	4,45±0,2	4,41±0,2
DUC	22,38±8,8	23,24±9,2	23,27±9,4	22,69±9,6	21,04±10,0	22,25±10,6	21,21±10,3	20,66±9,9
SCC	16,05±1,9	16,47±2,1	16,90±2,2	17,32±2,3	15,96±2,0	16,32±2,2	16,67±2,2	17,06±2,3

* DMY – dnevna mliječnost (kg); DFC – dnevni sadržaj masti (%); DPC – dnevni sadržaj proteina (%); DLC – dnevni sadržaj laktoze (%); DUC – dnevni sadržaj uree (mg/ml); SCC – log transformacija somatskih stanica

Slično kao u drugim područjima, u mediteranskom području, najviša dnevna proizvodnja mlijeka utvrđena je kod krava u trećoj laktaciji kod obje pasmine, s višom proizvodnjom kod holstein pasmine. Najveći dnevni udio masti (DFC) zabilježen je u prvoj laktaciji simentalke pasmine, dok je najviša utvrđena vrijednost dnevnog sadržaja proteina kod simentalke pasmine u drugoj laktaciji. Slično kao u drugim područjima, dnevni sadržaj uree bio je veći kod holstein u usporedbi sa simentalskom pasminom. Također, nešto više vrijednosti broja somatskih stanica utvrđene su kod holstein pasmine.

Varijabilnost mikroklimatskih parametara kao što su temperatura okoline, relativna vlažnost i temperaturno-humidni indeks (THI) u stajama za uzgoj predstavljena je u Tablici 7. prema pasmini krava.

Tablica 7. Varijabilnost (srednja vrijednost; SD) mikroklimatskih parametara prema pasmini, sezoni i području uzgoja

Parametar/ Sezona	Holstein				Simentalac			
	Proljeće	Ljeto	Jesen	Zima	Proljeće	Ljeto	Jesen	Zima
Istočno područje								
T	13,42±5,7	23,73±5,8	14,23±6,3	5,72±5,4	12,96±6,1	22,30±5,9	14,12±6,2	6,25±5,0
RH	66,44±12,8	64,18±13,3	67,06±13,9	69,58±14,7	67,90±11,1	67,28±11,4	70,05±10,8	71,31±11,3
THI	56,39±8,4	71,20±8,2	57,38±9,3	44,76±8,4	55,63±9,0	69,37±8,5	57,32±9,3	45,51±7,6
Središnje područje								
T	15,69±5,8	23,90±5,0	16,20±5,7	9,31±4,5	15,91±5,7	24,05±5,1	16,58±5,6	9,88±4,4
RH	68,12±10,7	69,08±10,9	71,62±10,3	72,84±9,9	69,18±10,3	69,87±10,5	72,52±9,8	73,86±9,5
THI	59,70±8,5	72,00±7,5	60,57±8,6	50,09±7,0	60,03±8,5	72,30±7,6	61,15±8,5	50,91±6,9
Mediteransko područje								
T	14,73±5,0	25,17±4,9	15,70±5,2	9,12±5,1	16,46±4,4	22,43±4,8	16,81±4,5	12,20±3,9
RH	68,75±9,5	70,58±11,1	70,06±8,9	70,73±10,0	70,18±10,6	69,37±11,5	72,26±9,7	71,43±9,9
THI	58,42±5,6	73,99±7,2	59,91±7,9	49,95±7,7	60,97±6,7	69,78±7,0	61,48±6,9	54,59±6,0

* T – ambijentalna temperatura (°C); RH – relativna vlažnost; THI – temperaturno humidni indeks

Maksimalna temperatura okoline (T) kao i najviši temperaturno-humidni indeks (THI) zabilježeni su u ljetnoj sezoni u mediteranskom području u stajama za uzgoj holstein krava, dok je minimalna temperatura zabilježena u zimskoj sezoni, također u stajama kod holstein pasmine, ali u istočnom području. Najviša vrijednost relativne vlažnosti (RH) utvrđena je u središnjem području u stajama za uzgoj simentalčkih krava tijekom zimske sezone.

Korelacije između proizvodnih svojstava mliječnih krava (dnevna količina mlijeka, dnevni udio masti, sadržaj proteina laktoze i uree te broj somatskih stanica) i mikroklimatski parametri (temperatura okoline, relativna vlažnost i temperaturno-humidni indeks (THI) u stajama sukladno pasmini i području uzgoja prikazani su u Tablici 5. Svi utvrđeni koeficijenti

korelacije bili su statistički visoko značajni ($p < 0,001$). Negativan učinak povećane temperature okoline na dnevnu količinu mlijeka (DMY) i dnevni udio masti, proteina i laktoze (DFC, DPC i DLC) utvrđen je kod obje pasmine u svim analiziranim područjima. Najizraženiji negativni učinak povišene temperature okoliša na dnevnu količinu mlijeka utvrđen je kod holstein pasmine u mediteranskom području, dok je kod simentalaske pasmine najveći pad dnevne proizvodnje mlijeka zabilježen u središnjem području. Negativan učinak visoke relativne vlage u stajama primijećen je kod holstein pasmine uzgajane u središnjem i mediteranskom području, kao i kod simentalaske pasmine uzgajanoj u središnjem području. Porast temperaturno-humidnog indeksa rezultirao je smanjenjem dnevne količine mlijeka i velikom varijabilnosti dnevnih sastava u obje pasmine u svim analiziranim područjima.

Tablica 8. Korelacija između proizvodnih svojstava i mikroklimatskih parametara prema pasmini i području uzgoja

Svojstvo	Holstein						Simentalac					
	DMY	DFC	DPC	DLC	DUC	SCC	DMY	DFC	DPC	DLC	DUC	SCC
Istočno područje												
T	-0,032	-0,105	-0,134	-0,019	0,197	0,013	-0,011	-0,123	-0,124	0,0126	0,204	-0,021
RH	0,044	0,040	0,013	-0,017	0,017	-0,222	-0,014	0,010	0,016	-0,024	-0,042	0,034
THI	-0,033	-0,106	-0,133	-0,016	0,195	0,013	-0,011	-0,134	-0,125	0,014	0,205	0,022
Središnje područje												
T	-0,012	-0,127	-0,116	-0,016	0,225	-0,004	0,0034	-0,133	-0,129	0,018	0,226	-0,025
RH	-0,039	0,039	0,038	-0,017	-0,013	0,020	-0,019	0,022	0,026	-0,025	-0,032	0,021
THI	-0,012	-0,136	-0,115	-0,016	0,223	-0,004	0,003	-0,133	-0,128	0,018	0,225	0,025
Mediteransko područje												
T	-0,094	-0,051	-0,073	0,005	0,116	0,003	0,0066	-0,085	-0,112	0,005	0,170	-0,014
RH	-0,065	-0,016	-0,018	0,002	-0,083	0,009	-0,017	-0,001	0,057	0,020	0,101	-0,008
THI	-0,094	-0,053	-0,072	0,007	0,112	0,001	0,066	-0,084	-0,106	0,007	0,177	0,015

* DMY – dnevna mliječnost (kg); DFC – dnevni sadržaj masti (%); DPC – dnevni sadržaj proteina (%); DLC – dnevni sadržaj laktoze (%); DUC – dnevni sadržaj uree (mg/ml); SCC – log transformirane somatske stanice; T – ambijentalna temperatura (°C); RH – relativna vlažnost; THI – temperaturno-humidni indeks; svi koeficijenti korelacije bili su statistički visoko značajni ($p < 0,001$)

Izvršene analize ukazuju na visoku varijabilnost proizvodnih svojstava s obzirom na pasminu krava, redoslijed laktacija kao i područje uzgoja. Također, pronađena je velika varijabilnost mikroklimatskih parametara ovisno o sezoni i području uzgoja. Utvrđene su statistički vrlo značajne ($p < 0,001$) korelacije između proizvodnih svojstava i mikroklimatskih parametara. Sve je to u konačnici utjecalo na negativan učinak mikroklimata kod obje pasmine na dnevnu proizvodnju mlijeka u svim uzgojnim područjima.

Kadzere i sur. (2002.) navode kako je intenzivna genetska selekcija na visoku proizvodnju mlijeka rezultirala promjenama u fiziologiji termoregulacije kod mliječnih

goveda. Veći okviri i veći gastrointestinalni trakt kod visokoproduktivnih životinja omogućava probavu veće količine hrane, pri čemu se stvara i više metaboličke topline, koja dalje utječe na životinju kroz smanjenu sposobnost regulacije temperature u toplinskom stresnom okruženju. Povećana mliječnost, unos hrane i zagrijavanje metabolizma postižu termo-neutralnost na nižim temperaturama. Treba imati na umu kako, visokoproduktivne mliječne krave gube sposobnost reguliranja tjelesne temperature na temperaturi zraka od 25 do 29 ° C. To potvrđuje i Berman (2005.) u svojem istraživanju gdje navodi kako povećanje dnevne proizvodnje s 35 na 45 kg mlijeka rezultira većom osjetljivosti na toplinski stres i smanjenja praga osjetljivosti na toplinski stres za 5°C. Gantner i sur. (2011.) su istaknuli kako čak i u razdobljima s nižim dnevnim temperaturama, ali pri visokoj relativnoj vlazi zraka, može doći do stanja toplinskog stresa. Du Preez i sur. (1990.a) su kod mliječnih krava uzgajanih u Južnoj Africi utvrdili pad mliječnosti pri THI većem od 72 (22 ° C pri 100% RH (RH-relativna vlažnost) 25 ° C pri 50% RH ili 28 ° C pri 20% RH). Casa i Ravelo (2003.) su utvrdili značajan pad proizvodnje mlijeka, u iznosu od 6-9% ovisno o području, tijekom toplijih mjeseci u Argentini. Bouraoui i sur. (2002.) izvijestili su o smanjenju od 0,41 kg mlijeka dnevno za svaki bodovni porast THI iznad 69. Prag vrijednosti THI ovisi o mnogim učincima, na primjer, fazi laktacije, razini proizvodnje mlijeka, pasmini, uzgajalištu, pojedinačnoj osjetljivosti na toplinski stres, i ostalim (Kadzere i sur. 2002., Bohmanova 2006., Collier et al. 2006., Hansen 2013., Gantner i sur. 2017.). Na primjer, Bouraoui i sur. (2002.) stavili prag na 65-69, Bernabucci i sur. (2010.) kao i Collier i Hall (2012.) na 68, Du Preez i sur. (1990a, b) na 72, dok su Bohmanova i sur. (2007.) postavili vrijednost praga ovisno o području uzgoja, 72 u Georgiji i 74 u Arizoni. West (2003.) je utvrdio smanjenje DMY od 0,85 kg za svaki porast temperature zraka od 1°C iznad termoneutralne zone krave. Spiers i sur. (2004.) izvijestili su kako se mliječnost krava smanjuje za 0,41 kg po danu za svaki jedinični THI porast iznad 69, pri čemu je u roku od jednog dana nakon početka toplinskog stresa smanjen unos hrane, dok se nakon dva dana nakon toplinskog stresa smanjila količina mlijeka. Gaafar i sur. (2011.) su utvrdili povećanje THI s 59,82 u zimskoj sezoni na 78,53 u ljetnoj sezoni, te je toplinski stres smanjio ukupnu (305 dana) i dnevnu količinu mlijeka za 39%, odnosno 31,40%. Kako navode Baumgard i Rhoads (2013.) pad proizvodnje mlijeka, usljed smanjenog unosa hrane, može biti i do 50%. Lambertz i sur. (2014.) ističu da do razlika u definiranju vrijednosti praga THI-a može doći zbog bolje prilagođenih krava THI-u, upravljanja farmom ili zbog boljih uvjeta smještaja.

5.2. Analiza proizvodnih svojstva i mikroklimatskih parametara na farmama mliječnih krava

Cilj ovog dijela istraživanja bio je razviti i odabrati optimalne statističke modele za ocjenu utjecaja parametara mikroklimat na varijabilnost proizvodnih svojstava mliječnih krava. Primjena optimalnog statističkog modela u rutinskoj genetičkoj evaluaciji i odabiru otpornijih životinja zasigurno će pridonijeti realizaciji profitabilne i održive mliječne farme.

Koeficijenti linearne regresije između analiziranih dnevnih svojstava mlijeka (dnevna količina, sadržaj masti, bjelančevina, laktoze i uree te broj somatskih stanica) i mikroklimatskih parametara (temperatura okoline, relativna vlažnost i temperaturno-humidni indeks THI) prikazani su prema pasmini u Tablici 6. Statistički značajno ($p < 0,05$) smanjenje dnevne količine mlijeka (DMY) i dnevnog sadržaja masti i proteina (DFC i DPC) uzrokovan porastom temperature okoline (T) i THI primijećen je kod obje pasmine. Dobiveni rezultati upućuju na činjenicu kako se, povećanjem relativne vlažnosti (RH), kod holstein krava povećala DMY, DFC i DPC, dok su se kod simentalke pasmine ta svojstva smanjila. Dnevni sadržaj laktoze (DLC) pokazao je vrlo nisku razinu varijabilnosti koja je nastala kao posljedica promjene mikroklimatskih uvjeta. Međutim, dnevni sadržaj uree (DUC) i broj somatskih stanica (SCC) kod obje analizirane pasmine, imao je povećane vrijednosti najvjerojatnije zbog većih dnevnih vrijednosti za T, RH i THI.

Tablica 9. Koeficijenti linearne regresije između dnevnih svojstava mlijeka i mikroklimatski parametri prema pasmini

Pasmina	Holstein			Simentalac		
Svojstvo	T	RH	THI	T	RH	THI
DMY	-0,0463	0,0023	-0,0315	-0,0483	-0,0068	-0,0320
DFC	-0,0004	0,0012	-0,0004	-0,0006	-0,0010	-0,0004
DPC	-0,0018	0,0003	-0,0011	-0,0011	-0,0001	-0,0007
DLC	-0,0005	0,0000	-0,0003	0,0001	0,0000	0,0001
DUC	0,0158	-0,0047	0,0102	0,0257	0,0050	0,0175
logSCC	0,0045	0,0019	0,0032	0,0003	0,0028	0,0002

* DMY – dnevna mliječnost (kg); DFC – dnevni sadržaj masti (%); DPC – dnevni sadržaj proteina (%); DLC – dnevni sadržaj laktoze (%); DUC – dnevni sadržaj uree (mg/ml); logSCC – log transformirane somatske stanice; T – ambijentalna temperatura (°C); RH – relativna vlažnost; THI – temperaturno-humidni indeks; svi koeficijenti korelacije bili su statistički visoko značajni ($p < 0,001$)

Statistički značajna ($p < 0,05$) razlika u svim analiziranim svojstvima dnevne mliječnosti, uz izuzetak SCC, zbog uvjeta toplinskog stresa pri THI = 68 utvrđena je kod obje pasmine (Tablica 10). Veća razlika između dnevne količine mlijeka proizvedene u

normalnim uvjetima i proizvodnje pri toplinskom stresu, utvrđena je kod holstein krava u količini od 314g manje mlijeka dnevno, dok je kod simentalских krava utvrđena manja razlika u količini od 296g mlijeka dnevno. Dnevne varijacije sadržaja masti / proteina / laktoze i SCC zbog toplinskog stresa bile su slične kod svih pasmina. Međutim, zbog toplinskog stresa dnevni sadržaj uree pokazao je značajan ($p < 0,05$) porast.

Tablica 10. Procijenjene srednje vrijednosti svojstava dnevne mliječnosti prema pasmini s obzirom na toplinski stres (HS-0 / HS-1) kada je prag THI = 68

<i>Pasmina</i>	<i>Holstein</i>		<i>Simentalac</i>	
Svojstvo	HS-0	HS-1	HS-0	HS-1
DMY	19,908 ^a	19,594 ^b	13,867 ^a	13,571 ^b
DFC	4,322 ^a	4,333 ^b	4,076 ^a	4,070 ^b
DPC	3,547 ^a	3,542 ^b	3,374 ^a	3,364 ^b
DLC	4,465 ^a	4,459 ^b	4,465 ^a	4,463 ^b
DUC	20,196 ^a	20,578 ^b	20,622 ^a	21,070 ^b
logSCC	15,947 ^a	15,955 ^a	16,306 ^a	16,300 ^a

* DMY – dnevna mliječnost (kg); DFC – dnevni sadržaj masti (%); DPC – dnevni sadržaj proteina (%); DLC – dnevni sadržaj laktoze (%); DUC – dnevni sadržaj uree (mg/ml); logSCC – log transformirane somatske stanice; procijenjene srednje vrijednosti unutar istog pasmine označene različitim slovima (a, b) razlikuju se statistički značajno ($p < 0,05$); HS-0: normalno stanje, HS-1: stanje toplinskog stresa

Rezultati analize varijance dnevne količine i sastava mlijeka s obzirom na uvjete toplinskog stresa (HS-0 / HS-1) pri THI = 72 prikazani su prema pasmini u Tablici 11. Slični trendovi kao i kod niže vrijednosti THI-a (68) utvrđeni su za sva analizirana svojstva kod obje pasmine, dok su utvrđene razlike bile veće u usporedbi s nižom THI vrijednosti.

Tablica 11. Procijenjene srednje vrijednosti svojstava dnevne mliječnosti prema pasmini s obzirom na toplinski stres (HS-0 / HS-1) kada je prag THI = 72

<i>Pasmina</i>	<i>Holstein</i>		<i>Simentalac</i>	
Svojstvo	HS-0	HS-1	HS-0	HS-1
DMY	19,908 ^a	19,424 ^b	13,841 ^a	13,543 ^b
DFC	4,321 ^a	4,344 ^b	4,076 ^a	4,065 ^b
DPC	3,548 ^a	3,538 ^b	3,373 ^a	3,363 ^b
DLC	4,465 ^a	4,457 ^b	4,465 ^a	4,462 ^b
DUC	20,231 ^a	20,541 ^b	20,641 ^a	21,258 ^b
logSCC	15,946 ^a	15,967 ^a	16,305 ^a	16,301 ^a

* DMY – dnevna mliječnost (kg); DFC – dnevni sadržaj masti (%); DPC – dnevni sadržaj proteina (%); DLC – dnevni sadržaj laktoze (%); DUC – dnevni sadržaj uree (mg/ml); logSCC – log transformirane somatske stanice; procijenjene srednje vrijednosti unutar istog pasmine označene različitim slovima (a, b) razlikuju se statistički značajno ($p < 0,05$); HS-0: normalno stanje, HS-1: stanje toplinskog stresa

Rezultati u Tablici 11. pokazuju kako dnevna količina mlijeka kod holstein pasmine pada približno 0,5 kg dnevno usljed povećanog toplinskog stresa. Međutim, kod simentalških krava, pri istim vrijednostima THI (indeks 72), pad proizvodnje je nešto manje i iznosi 0,3 kg mlijeka dnevno. Negativan učinak povećanja temperature i temperaturno humidnog-indeksa na dnevnu količinu mlijeka utvrđen je kod obje pasmine i sva promatrana stanja toplinskog stresa. Porast temperature okoline za jedan stupanj, kod obje pasmine, dovodi do smanjenja za približno 50 g mlijeka dnevno (malo veći pad utvrđen je kod simentalških krava (-0,0483 naspram -0,0463). Negativan učinak visoke relativne vlage u stajama izraženiji je bio kod simentalških u odnosu na holstein krave. Sukladno tome, prema mnogim istraživanjima, visokoproduktivne mliječne krave gube svoju sposobnost regulacije tjelesne temperature na temperaturi zraka od 25 do 29°C. Tako Berman (2005.) navodi kako je povećanje dnevne proizvodnje s 35 na 45 kg rezultiralo većom osjetljivošću na toplinski stres i smanjenja praga temperature za srednji toplinski stres za 5°C. Međutim, stanje toplinskog stresa može se pojaviti čak i u razdobljima s nižim temperaturama kada probleme može uzrokovati visoka relativna vlažnost zraka (Gantner i sur., 2011.). Negativan učinak visoke vlažnosti na proizvodnju mlijeka također je potvrđen i u istraživanjima Bianc-a (1965.). Autorica je utvrdila kako je pri 29°C i 40% RH dnevna količina mlijeka kod holstein, jersey i brown swiss krava bila na 97, 93 i 98% u odnosu na normalu proizvodnju, ali kada se RH povećala na 90%, proizvodnja mlijeka pala je na 69, 75 i 83% normalne razine. Du Preez i sur. (1990.a) su utvrdili pad proizvodnje mlijeka kod krava uzgajanih na jugu Afrike pri THI većem od 72, što znači pri 22°C na 100% RH, 25°C pri 50% RH ili 28°C pri 20% RH je THI uvijek veći od 72. Značajno smanjenje proizvodnje mlijeka, u iznosu od 6% odnosno (9%), ovisno o regiji, tijekom toplijih mjeseci u Argentini također su utvrdili Casa i Ravelo (2003.). Slično rezultatima ovog istraživanja, Bouraoui i sur. (2002.) izvijestili su o smanjenju od 0,41kg mlijeka dnevno za svaki bodovni porast THI-a iznad 69. Sukladno brojnim istraživanjima (Kadzere et al., 2002.; Bohmanova, 2006.; Collier i sur., 2006.; Hansen, 2013.; Gantner i sur., 2017.), granična vrijednost THI ovisi o mnogim učincima, na primjer, fazi laktacije, rednom broju laktacije, razini proizvodnje mlijeka, pasmini, području uzgoja, individualnoj osjetljivost na toplinski stres, itd. Tako su primjerice, Bouraoui i sur. (2002) stavili prag THI-a na 65-69. Slično su napravili i Bernabucci i sur. (2010) kao i Collier i Hall (2012) gdje je početak toplotnog stresa bio pri THI-u od 68. Međutim, Du Preez i sur. (1990a, b) postavili su nešto veće vrijednosti THI-a (72) od prethodno navedenih autora, kao i Bohmanova i sur. (2007), ovisno o definiranom području 72 u Georgiji i 74 u Arizoni. Lambertz i sur. (2014) su istaknuli

da razlike u definiranim vrijednostima praga mogu nastati zbog bolje prilagođenosti krava, upravljanja farmom ili smještajem.

5.3. Genetski parametri i uzgojne vrijednosti za dnevnu proizvodnju mlijeka krava holsteina pasmine u uvjetima toplinskog stresa

Kako bi se omogućila primjena dugoročne metode mitigacije koja je jednostavna za uporabu u praksi, ovaj dio istraživanja imao je za cilj procijeniti komponente varijance kao i uzgojnu vrijednost za dnevnu proizvodnju mlijeka krava holstein pasmine u uvjetima toplinskog stresa definirane kao različite vrijednosti praga THI (68, 70, i 72). Dnevna proizvodnja mlijeka analizirana je kao bivarijantna varijabla u normalnim uvjetima (ispod zadanog praga THI vrijednosti) i u uvjetima toplinskog stresa (iznad zadanog praga THI vrijednosti). Procijenjene komponente varijance dnevne proizvodnje mlijeka za vrijednosti praga (THI_{prag} 68, 70 ili 72) prikazane su u Tablici 12.

Tablica 12. Procijenjene varijance i kovarijanca za dnevnu proizvodnju mlijeka holstein pasmine s obzirom na postavljene vrijednosti praga (THI_{prag} je 68, 70 ili 72)

Utjecaj	Varijanca (THI-0)	Varijanca (THI-1)	Kovarijanca
	THI prag je 68 (DMY 48.28 vs 45.33)		
Penv	11.6407 ± 0.08523 kg ²	11.1895 ± 0.11864 kg ²	9.7591 ± 0.08779 kg ²
Hyear	8.27282 ± 0.15181 kg ²	9.71132 ± 0.19553 kg ²	8.11141 ± 0.15721 kg ²
Animal	9.80707 ± 0.13229 kg ²	9.20131 ± 0.15652 kg ²	8.96254 ± 0.12544 kg ²
Residual	18.5586 ± 0.030809 kg ²	15.2324 ± 0.058844 kg ²	-
	THI prag je 70 (DMY 48.27 vs 44.79)		
Penv	11.5145 ± 0.08552 kg ²	11.3893 ± 0.13122 kg ²	9.7225 ± 0.08825 kg ²
Hyear	8.31285 ± 0.15667 kg ²	9.75394 ± 0.20254 kg ²	8.14021 ± 0.16185 kg ²
Animal	9.76130 ± 0.13339 kg ²	9.07161 ± 0.16561 kg ²	8.91184 ± 0.12865 kg ²
Residual	18.6856 ± 0.031649 kg ²	14.5760 ± 0.064901 kg ²	-
	THI prag je 72 (DMY 48.23 vs 44.31)		
Penv	11.3858 ± 0.07841 kg ²	11.8413 ± 0.15383 kg ²	9.7582 ± 0.09426 kg ²
Hyear	8.34451 ± 0.15330 kg ²	9.96719 ± 0.21632 kg ²	8.19485 ± 0.16508 kg ²
Animal	9.71994 ± 0.13159 kg ²	9.91724 ± 0.17880 kg ²	8.83270 ± 0.13134 kg ²
Residual	18.7763 ± 0.032042 kg ²	13.5879 ± 0.077664 kg ²	-

*Penv – trajna okolina; Hyear – interakcija stado-godina, animal – individualni utjecaj krave, residual – ostatak

Varijanca za trajnu okolinu pri $THI = 0$ bila je u rasponu od 11.386 kg² do 11.641 kg², dok se za $THI = 1$ kretala od 11.190 kg² do 11.841 kg², ovisno o postavljenoj vrijednosti THI praga. Dobiveni rezultati pokazuju da je pri višim THI vrijednostima učinak trajne okoline bio istaknutiji. Varijanca interakcije stado-godina također se povećala kako je povećana vrijednost THI_{prag} , s većim vrijednostima varijance utvrđenim u uvjetima toplinskog stresa ($THI = 1$). Suprotno tome, procijenjena varijanica za individualnu životinju smanjivala se s porastom od THI_{prag} vrijednosti, s nižim vrijednostima varijance utvrđenim u uvjetima toplinskog stresa. Slično tome, Aguilar i sur. (2009.) utvrdili su da procijenjena aditivna genetska varijanica za mlijeko, postotak masti i proteina uvelike ovisi o vrijednosti THI praga, stadiju laktacije, paritetu i statističkom modelu koji se koristi za ocjenu. Aguilar i sur. (2009) utvrdili su da funkcija ukupne aditivne genetske varijance i THI -a ima tipičan kvadratni oblik, što je odgovaralo rezultatima Ravagnola i Misztal (2000.). Štoviše, genetska varijanica za rezistentnost na toplinski stres značajno je povećana na kraju laktacije i u sljedećim laktacijama. Utjecaj stadija laktacije na aditivnu genetsku varijancu ima najviše vrijednosti na kraju laktacije (DIM u 300) što su također prepoznali Brugemann i sur. (2011.). Isti autori utvrdili su smanjenje aditivne genetske varijance i varijance trajne okoline za dnevnu količinu proteina u uvjetima povećanja vrijednosti THI od 21 do 72.

Procijenjeni omjeri varijance i korelacije za dnevnu proizvodnju mlijeka za krave holstein pasmine s obzirom na postavljene vrijednosti praga (THI_{prag} je 68, 70 ili 72) prikazani su u Tablici 13. Varijabilnost dnevne proizvodnje mlijeka zbog trajne okoline kretala se od 23,61 do 26,72%, ovisno o karakteristikama okoline. Učinak trajne okoline bio je najizraženiji u stajama s THI vrijednostima većim od 72. Varijabilnost dnevne proizvodnje mlijeka zbog interakcije stado-godina kretala se između 17,14% - 22,5% s najvećim udjelom varijabilnosti utvrđenim u okolini, koju karakterizira toplinski stres i pri najvišoj vrijednosti THI praga. Nasljednost (heritabilitet) za dnevnu proizvodnju mlijeka u normalnim uvjetima ($THI = 0$) kretala se između 20,16% - 20,31 %. Utvrđene vrijednosti heritabiliteta u uvjetima toplinskog stresa ($THI = 1$) bile su slične i kretale su se između 20,12 i 20,30%. Dobiveni rezultati ukazuju na vrlo važnu ulogu upravljanja stadom za ublažavanje toplinskog stresa na farmama mliječnih krava.

Procijenjene genetske korelacije bile su visoke i iznosile su, ovisno o vrijednosti praga THI -a, od 94,35% na najnižem THI -u (68) do 94,87% na najvišoj analiziranoj vrijednosti THI -a (72). Visoke vrijednosti procijenjene genetske korelacije između dnevne proizvodnje mlijeka u normalnim uvjetima i dnevne proizvodnje mlijeka u uvjetima s

toplinskim stresom pokazuju kako će visokoproizvodne krave u normalnim uvjetima održati jednaku razinu proizvodnje i u uvjetima toplinskog stresa. Sanchez i sur. (2009.) definirali su usporedne konstantne vrijednosti heritabiliteta za dnevnu proizvodnju mlijeka kao funkciju od THI (u rasponu od 60 do 90). Aguilar i sur. (2009.) utvrdili su da heritabilitet dnevne količine mlijeka ovisi o stadiju laktacije, rednom broju laktacije i vrijednosti THI-a, uključujući najviše vrijednosti pri kraju laktacije i u trećoj laktaciji uz neznatan porast pri višim vrijednostima THI-a. Ravagnolo i Misztal (2000) utvrdili su lagani porast heritabiliteta za postotak proteina, kao i smanjenje heritabiliteta za sadržaj masti s povećanjem THI-a sa 72 na 85. Suprotno tome, Brugemann i sur. (2011.) zaključili su da je vrijednost heritabiliteta za sadržaj bjelancevina bila najveća pri nižim THI vrijednostima (kod THI u rasponu 21-72) i na kraju laktacije. Isti autori naznačili su da je utjecaj stadija laktacije na vrijednosti heritabiliteta uočljiviji od učinka THI-a. Aguilar i sur. (2009.) utvrdili su da genetske korelacije između laktacija i tolerancije na toplinski stres variraju u intervalu 0,56 do 0,79 što ukazuje na varijacije u toleranciji toplinskog stresa zbog utjecaja laktacije.

Tablica 13. Procijenjeni omjeri i korelacije za dnevnu proizvodnju mlijeka krava holstein pasmine s obzirom na postavljene vrijednosti praga (THI_{prag} je 68, 70 ili 72)

Učinak	Omjer (THI-0)	Omjer (THI-1)	Korelacija
THI prag je 68			
Penv	0.24111 ± 0.1866E-02	0.24682 ± 0.2668E-02	0.85509 ± 0.3966E-02
Hyear	0.17135 ± 0.2744E-02	0.21421 ± 0.3544E-02	0.90496 ± 0.3784E-02
Animal	0.20313 ± 0.2565E-02	0.20296 ± 0.3276E-02	0.94349 ± 0.4040E-02
Residual	0.38440 ± 0.1453E-02	0.33600 ± 0.2001E-02	-
THI prag je 70			
Penv	0.23852 ± 0.1807E-02	0.25428 ± 0.2957E-02	0.84900 ± 0.4218E-02
Hyear	0.17220 ± 0.2816E-02	0.21777 ± 0.3715E-02	0.90401 ± 0.3827E-02
Animal	0.20220 ± 0.2624E-02	0.20253 ± 0.3525E-02	0.94705 ± 0.4411E-02
Residual	0.38707 ± 0.1508E-02	0.32542 ± 0.2163E-02	-
THI prag je 72			
Penv	0.23609 ± 0.1736E-02	0.26722 ± 0.3485E-02	0.84040 ± 0.4581E-02
Hyear	0.17303 ± 0.2755E-02	0.22492 ± 0.4003E-02	0.89858 ± 0.4381E-02
Animal	0.20155 ± 0.2547E-02	0.20123 ± 0.3853E-02	0.94874 ± 0.5090E-02
Residual	0.38934 ± 0.1503E-02	0.30663 ± 0.2326E-02	-

*Penv – trajna okolina; Hyear – interakcija stado-godina, animal – individualni utjecaj krave, residual – ostatak

Osnovna statistika procijenjenih uzgojnih vrijednosti (UV) za dnevnu proizvodnju mlijeka krava holstein pasmine u normalnim uvjetima i uvjetima toplinski stresnog okruženja s obzirom na postavljene vrijednosti praga (THI_{prag} je 68, 70 ili 72) prikazani su u Tablici 14. Srednje vrijednosti UV, unatoč uvjetima u okolišu, iznosile su otprilike 100,6. Uz to, srednja vrijednost UV za dnevnu proizvodnju mlijeka u normalnim uvjetima bila najveća pri srednjoj vrijednosti THI-a (70), dok je u toplinski stresnim uvjetima UV imao najveću vrijednost THI (72). Korelacija UV u normalnim uvjetima i uvjetima toplinskog stresa bila je visoka i iznosila je između 98,64-98,91% pokazujući visoku povezanost između produktivnosti krava u normalnim uvjetima i uvjetima toplinskog stresa.

Tablica 14. Varijabilnost procijenjenih uzgojnih vrijednosti (UV) za dnevnu proizvodnju mlijeka krava holstein pasmine s obzirom na postavljene vrijednosti praga (THI_{prag} je 68, 70 ili 72)

THI	UV (THI – 0)					UV (THI – 1)					r
	mean	SD	CV	MIN	MAX	mean	SD	CV	MIN	MAX	
68	100,675	14,30	14,21	52,028	147,961	100,672	14,30	14,20	52,030	147,957	0,98642
70	100,679	14,30	14,21	52,028	147,961	100,620	14,30	14,22	52,029	147,955	0,98819
72	100,670	14,31	14,21	52,028	147,960	100,693	14,29	14,19	52,028	147,958	0,98908

*r – korelacija između UV-a u normalnom (THI – 0) i okruženju toplinskog stresa (THI – 1); svi koeficijenti korelacije bili su statistički visoko značajni ($p < 0,001$)

Aguilar i sur. (2009.) u proučavanju genetskih komponenti toplinskog stresa za mliječna goveda zaključili su kako vrijednost genetske varijance tolerantnosti na toplinski stres za dnevnu mliječnost ovisi o primijenjenom modelu (slučajna regresija nasuprot modela ponovljivosti). Za analizu komponenata varijance odgovora na toplinski stres Ravagnolo i sur. (2000.) primijenili su takozvani model isprekidane crte koji se karakterizira pragom termo neutralnosti i krivuljom smanjenja proizvodnje nakon utvrđenog praga. Štoviše, u nekim studijama (Brügemann i sur., 2011.; Menendez-Buxadera i sur., 2012. .; Carabaño i sur., 2014.) utvrdili su da je varijabilnost dnevne proizvodnje mlijeka u uvjetima toplinskog stresa definirana kao funkcija polinoma koja omogućuje fleksibilniji pristup nego model isprekidane crte. Prema Gaughanhu i sur. (2012.) jedna od glavnih prepreka u primjeni bilo kojeg modela procjene je način kombinacije mikroklimatskih varijabli.

Carabaño i sur. (2014.) naglasili su važnost definiranja pravilnog razdoblja između dnevnih kontrola mliječnosti i datuma kada su se dogodila mjerenja mikroklimatskih parametara. Također, izuzetno je važno definirati odgovarajuće kriterije za odabir za svaki

model za procjenu. U modelu isprekidane crte, kao kriterij može biti odabran prag termo tolerancije i krivulja odgovora životinje. Carabaño i sur. (2014.) utvrdili su da se u primjeru polinoma višeg reda koji je korišten za definiranje odgovora životinja na toplinski stres, kao kriterij može koristiti nagib određene krivulje polinoma pod umjerenim ili jakim toplinskim stresom. Sánchez i sur. (2009) su naglasili da će primjena modela u praksi pokazati da životinje s većim prilagodbenim mogućnostima imaju niži pad proizvodnje kao i kasniju reakciju na okolišni stres. Osim toga, Carabaño i sur. (2014.) naveli su varijabilnost genetskog odgovora i ponovna rerangiranja životinja s obzirom na različite temperature koje upućuju na interakcije između genotipa i mikroklimatskih parametara.

S ciljem pojednostavljenja provedbe selekcije mliječnih grla na rezistentnost na toplinski stres u praksi, u ovom je istraživanju dnevna proizvodnja mlijeka analizirana kao bivarijantna varijabla i to u normalnim uvjetima (ispod THI_{prag} vrijednosti), i u uvjetima toplinskog stresa (iznad THI_{prag} vrijednosti). Procijenjene visoke genetske korelacije između dnevne proizvodnje mlijeka u normalnim uvjetima i uvjetima toplinskog stresa, upućuju na zaključak kako će krave holstein pasmine s visokom produktivnošću održati jednaku razinu proizvodnje čak i u uvjetima toplinskog stresa. S obzirom na dobivene rezultate, može se pretpostaviti dobra aklimatizacija krava holstein pasmine na uvjete farmskog okoliša.

5.4. Genetski parametri i uzgojne vrijednosti za dnevnu proizvodnju mlijeka krava simentalne pasmine u uvjetima toplinskog stresa

Ovaj dio istraživanja imao je za cilj procijeniti komponente varijance kao i uzgojnu vrijednost za dnevnu proizvodnju mlijeka krava simentalne pasmine u uvjetima toplinskog stresa definirane kao različite vrijednosti praga THI (72, 74, i 76). Dnevna proizvodnja mlijeka analizirana je kao bivarijantna varijabla u normalnim uvjetima (ispod zadanog praga THI vrijednosti) i u uvjetima toplinskog stresa (iznad zadanog praga THI vrijednosti).

Procijenjene komponente varijance dnevne proizvodnje mlijeka krava simentalne pasmine za vrijednosti praga (THI_{prag} 72, 74 ili 76) prikazane su u Tablici 15. Varijanca za trajni okoliš kada je $THI = 0$ bila je u rasponu od 3.627 kg² do 3.579 kg², dok se za $THI = 1$ kretala od 3.577 kg² do 3.670 kg², ovisno o postavljenoj vrijednosti THI praga, ukazujući na to je pri višim THI vrijednostima učinak trajnog okoliša bio istaknutiji.

Tablica 15. Procijenjene varijance i kovarijanca za dnevnu proizvodnju mlijeka krava simentalke pasmine s obzirom na postavljene vrijednosti praga (THI_{prag} je 72, 74 ili 76)

Utjecaj	Varijanca ($THI=0$)	Varijanca ($THI=1$)	Kovarijanca
	THI prag je 72		
Penv	$3.62684 \pm 0.023704 \text{ kg}^2$	$3.57655 \pm 0.054748 \text{ kg}^2$	$3.18274 \pm 0.029340 \text{ kg}^2$
Hyear	$4.39042 \pm 0.057105 \text{ kg}^2$	$5.35418 \pm 0.080783 \text{ kg}^2$	$4.22085 \pm 0.061951 \text{ kg}^2$
Animal	$5.25454 \pm 0.056325 \text{ kg}^2$	$5.25809 \pm 0.078944 \text{ kg}^2$	$5.07305 \pm 0.058007 \text{ kg}^2$
Residual	$8.94054 \pm 0.012533 \text{ kg}^2$	$7.54261 \pm 0.038398 \text{ kg}^2$	-
THI prag je 74			
Penv	$3.59892 \pm 0.024255 \text{ kg}^2$	$3.61619 \pm 0.065184 \text{ kg}^2$	$3.18366 \pm 0.032497 \text{ kg}^2$
Hyear	$4.39700 \pm 0.055753 \text{ kg}^2$	$5.50066 \pm 0.089483 \text{ kg}^2$	$4.25371 \pm 0.063407 \text{ kg}^2$
Animal	$5.23564 \pm 0.053151 \text{ kg}^2$	$5.25395 \pm 0.087959 \text{ kg}^2$	$5.09532 \pm 0.058297 \text{ kg}^2$
Residual	$8.96415 \pm 0.013173 \text{ kg}^2$	$7.40636 \pm 0.045108 \text{ kg}^2$	-
THI prag je 76			
Penv	$3.57874 \pm 0.022982 \text{ kg}^2$	$3.69503 \pm 0.082649 \text{ kg}^2$	$3.17386 \pm 0.036770 \text{ kg}^2$
Hyear	$4.40475 \pm 0.053216 \text{ kg}^2$	$5.58089 \pm 0.097791 \text{ kg}^2$	$4.25124 \pm 0.065262 \text{ kg}^2$
Animal	$5.22721 \pm 0.052722 \text{ kg}^2$	$5.17235 \pm 0.099102 \text{ kg}^2$	$5.10041 \pm 0.064147 \text{ kg}^2$
Residual	$8.97953 \pm 0.013315 \text{ kg}^2$	$7.28479 \pm 0.052614 \text{ kg}^2$	-

*Penv – trajna okolina; Hyear – interakcija stado-godina, animal – individualni utjecaj krave, residual – ostatak

Uočen je sličan trend povećanja varijance u normalnom stanju s obzirom na vrijednosti praga THI_{prag} zbog varijabilnosti uslijed interakcije stado-godina i rezidualne varijance. U uvjetima toplinskog stresa ($THI = 1$), s obzirom na postavljenu vrijednost praga THI_{preg} , uočeno je smanjenje rezidualne varijance, dok se povećala varijanca interakcije stado-godina. Procijenjena varijanca za individualni utjecaj životinje bila je nešto veća u uvjetima toplinskog stresa kao i pri višim vrijednostima postavljenog THI praga s izuzetkom kada je THI -a jednak 76.

Aguilar i sur. (2009.) utvrdili su da procijenjena aditivna genetska varijanca za mlijeko, količinu masti i proteina uvelike ovisi o vrijednosti THI praga, stadiju i redosljedu laktacije, te statističkom modelu koji se koristi za ocjenu. Slično kao u studiji Ravagnola i Misztal (2000.), Aguilar i sur. (2009.) utvrdili su da funkcija ukupne aditivne genetske varijance i THI ima tipičan kvadratni oblik. Štoviše, genetska varijanca za rezistentnost na toplinski stres značajno je povećana na kraju laktacije i u višim laktacijama. Utjecaj stadija laktacije na aditivnu genetsku varijancu ima najviše vrijednosti na kraju laktacije ($DIM =$

300) što su također prepoznali Brugemann i sur. (2011.). Isti autori utvrdili su smanjenje aditivne genetske varijance i varijance trajnog okoliša za količinu proteina u kontrolnom danu u uvjetima povećanja vrijednosti THI (od 21 do 72).

Procijenjeni omjeri varijance i korelacije za dnevnu proizvodnju mlijeka krava simentalke pasmine s obzirom na postavljene vrijednosti praga (THI_{prag} je 72, 74 ili 76) prikazani su u Tablici 16. Varijabilnost dnevne proizvodnje mlijeka zbog trajnog okoliša kretala se od 16,13 do 17,00%, ovisno o uvjetima okoliša. Učinak trajnog okoliša bio je najizraženiji u stajama s $THI > 76$. Varijabilnost dnevne proizvodnje mlijeka zbog interakcije stado-godina kretala se između 19,77% - 25,68% s najvećim udjelom varijabilnosti utvrđenim u okolišu koji karakterizira toplinski stres i pri najvišoj vrijednosti THI praga. Heritabilitet za dnevnu proizvodnju mlijeka u normalnim uvjetima ($THI = 0$) bio je približno 23,50% dok su vrijednosti nasljednosti u uvjetima toplinskog stresa ($THI = 1$) bile više i kretale su se u rasponu 23.78-24.20%

Tablica 16. Procijenjeni omjeri varijance i korelacija za dnevnu proizvodnju mlijeka krava simentalke pasmine s obzirom na postavljene vrijednosti praga (THI_{prag} je 72, 74 ili 76)

Učinak	Omjer (THI-0)	Omjer (THI-1)	Korelacija
THI prag je 72			
Penv	0.16328 ± 0.1117E-02	0.16458 ± 0.2509E-02	0.88370 ± 0.6348E-02
Hyear	0.19766 ± 0.2286E-02	0.24638 ± 0.3164E-02	0.87056 ± 0.3506E-02
Animal	0.23656 ± 0.2312E-02	0.24196 ± 0.3384E-02	0.96513 ± 0.3312E-02
Residual	0.40250 ± 0.1189E-02	0.34708 ± 0.2144E-02	-
THI prag je 74			
Penv	0.16215 ± 0.1138E-02	0.16605 ± 0.2996E-02	0.88250 ± 0.7366E-02
Hyear	0.19810 ± 0.2205E-02	0.25259 ± 0.3433E-02	0.86493 ± 0.3936E-02
Animal	0.23589 ± 0.2190E-02	0.24126 ± 0.3719E-02	0.97150 ± 0.3927E-02
Residual	0.40387 ± 0.1209E-02	0.34010 ± 0.2495E-02	-
THI prag je 76			
Penv	0.16128 ± 0.1073E-02	0.17002 ± 0.3690E-02	0.87280 ± 0.9648E-02
Hyear	0.19850 ± 0.2114E-02	0.25679 ± 0.3768E-02	0.85744 ± 0.4453E-02
Animal	0.23556 ± 0.2162E-02	0.23799 ± 0.4268E-02	0.98090 ± 0.5076E-02
Residual	0.40466 ± 0.1188E-02	0.33519 ± 0.2930E-02	-

*Penv – trajna okolina; Hyear – interakcija stado-godina, animal – individualni utjecaj krave, residual – ostatak

Procijenjene genetske korelacije bile su visoke i te su iznosile, ovisno o vrijednosti praga THI-a, od 96,51% na najnižem THI-u (72) do 98,09% na najvišoj analiziranoj vrijednosti THI-a (76). Visoke vrijednosti procijenjene genetske korelacije između dnevne proizvodnje mlijeka u normalnim uvjetima i dnevne proizvodnje mlijeka u uvjetima s toplinskim stresom pokazuju da će krave s visokim performansama u normalnim uvjetima održati jednake razine proizvodnje i u uvjetima toplinskog stresa.

Osnovna statistika procijenjenih uzgojnih vrijednosti (UV) za dnevnu proizvodnju mlijeka krava simentalke pasmine normalnim uvjetima i uvjetima toplinski stresnog okruženja definirana vrijednostima THI praga ($THI_{threshold}$ 72, 74 ili 76) predstavljena je u Tablici 17. Srednje vrijednosti uzgojnih vrijednosti, unatoč uvjetima u okolišu, iznosile su otprilike 100,5. Uz to, srednja vrijednost UV za dnevnu proizvodnju mlijeka u normalnim uvjetima bila najveća pri najnižoj vrijednosti THI, dok je u toplinski stresnim uvjetima UV imala najveću vrijednost pri najvećoj vrijednosti THI. Korelacija UV u normalnim uvjetima i uvjetima toplinskog stresa bila je visoka i razlikovala se između 99,48-99,76% pokazujući veliku vezu između produktivnosti krava u normalnim uvjetima i uvjetima toplinskog stresa.

Tablica 17. Varijabilnost procijenjenih uzgojnih vrijednosti (UV) za dnevnu proizvodnju mlijeka krava simentalke pasmine s obzirom na postavljene vrijednosti praga (THI_{prag} je 72, 74 ili 76)

THI	UV (THI – 0)					UV (THI – 1)					r
	mean	SD	CV	MIN	MAX	mean	SD	CV	MIN	MAX	
72	100.486	13.325	13.26	52.127	147.981	100.423	13.326	13.27	52.106	147.980	0.99477
74	100.482	13.325	13.26	52.122	147.981	100.446	13.323	13.26	52.107	147.980	0.99591
76	100.481	13.324	13.26	52.126	147.981	100.451	13.323	13.26	52.116	147.980	0.99762

*r – korelacija između UV-a u normalnom (THI – 0) i okruženju toplinskog stresa (THI – 1); svi koeficijenti korelacije bili su statistički visoko značajni ($p < 0,001$)

Sanchez i sur. (2009) definirali su usporedne konstantne vrijednosti nasljednosti za dnevnu proizvodnju mlijeka kao funkciju od THI (u rasponu od 60 do 90). Aguilar i sur. (2009) utvrdili su da nasljednost dnevne mliječnosti ovisi o stadiju laktacije, vrijednosti pariteta i THI-a, uključujući najviše vrijednosti pri kraju laktacije i u trećem paritetu, uz neznatan porast pri višim vrijednostima THI-a. Ravagnolo i Misztal (2000.) definirali su lagani porast nasljednosti za prinos proteina, kao i smanjenje nasljednosti za prinos masti s povećanjem THI-a sa 72 na 85. Suprotno tome, Brugemann i sur. (2011.) zaključili su da je vrijednosti nasljednosti za prinos proteina bila najveća pri nižim THI vrijednostima (kod

THI u rasponu 21-72) i na kraju laktacije. Isti autori naznačili su da je utjecaj stadija laktacije na vrijednosti nasljednosti uočljiviji od učinka THI-a. Aguilar i sur. (2009.) izvijestili su znanstvenu i stručnu javnost kako genetske korelacije između laktacija i tolerancije toplinskog stresa variraju od 0,56 do 0,79 što ukazuje na varijacije u toleranciji toplinskog stresa zbog laktacija

Aguilar i sur. (2009) utvrdili su da vrijednost genetske varijance za rezistentnost na toplinski stres ovisi o primijenjenom modelu (slučajna regresija nasuprot modela ponovljivosti). U nekim istraživanjima (Brügemann i sur., 2011; Menendez-Buxadera i sur., 2012.; Carabaño i sur., 2014) utvrđeno je da je varijabilnost dnevne proizvodnje mlijeka u uvjetima toplinskog stresa može biti definirana kao funkcija polinoma koja omogućuje fleksibilniji pristup komparabilno sa modelom isprekidane crte. Gaughan i sur. (2012.) navode da je jedan od najvećih problema u primjeni bilo kojeg modela način uvažavanja mikroklimatskih parametara te razmak između testnih dana i datuma izmjere mikroklimat (Carabaño i sur., 2014). Sánchez i sur. (2009) predviđaju primjenu modela u praksi koji će pokazati životinje s većim mogućnostima prilagodbe (imaju niži pad proizvodnje kao i kasniju reakciju na okolišni stres). Kako bi se pojednostavnio praktični odabir životinja s rezistentnijih na toplinski stres, u navedenom istraživanju dnevna mliječnost je analizirana kao bivarijantna varijabla, u normalnim uvjetima (ispod postavljene vrijednosti THI_{prag}), i u smislu toplinskog stresa (iznad postavljene vrijednosti THI_{prag}). Procijenjene vrlo visoke genetske korelacije između dnevne proizvodnje mlijeka u normalnim uvjetima i uvjetima toplinskog stresa, te vrlo visoke korelacije između uzgojnih vrijednosti u normalnim i toplinski stresnim uvjetima ukazuju da će visoko produktivne krave u normalnim uvjetima održavati sličnu razinu proizvodnje čak i u uvjetima toplinskog stresa. To sve govori o dobroj prilagodbi krava simentalke pasmine na farmske uvjete.

4. ZAKLJUČCI

Temeljem provedene statističke analize i utvrđivanja fenotipske i genetske varijabilnosti proizvodnih karakteristika mliječnih goveda (holstein i simentalke pasmine) u uvjetima toplinskog stresa u proizvodnim objektima, te razvoja i primjene metodologije genetske evaluacije mliječnih goveda na svojstvo rezistentnosti na toplinski stres, može se zaključiti sljedeće:

- varijabilnost u dnevnim svojstvima mliječnosti uslijed utjecaja pasmine krava (holstein, simentalke), redosljeda laktacije kao i uzgojnog područja (istočna, središnja i mediteranska Hrvatska),
- varijabilnost parametara mikrokline u stajama (ambijentalna temperatura, relativna vlaga i temperaturno-humidni indeks) uslijed utjecaja sezone (proljeće, ljeto, jesen i zima) i uzgojnog područja (istočna, središnja i mediteranska Hrvatska),
- negativan utjecaj povećanja parametara mikrokline (ambijentalna temperatura, relativna vlaga te temperaturno-humidni indeks) na dnevnu proizvodnju mlijeka kod svih krava bez obzira na pasminu (holstein i simentalke) i uzgojno područje (istočna, središnja i mediteranska Hrvatska),
- utvrđeni utjecaji trebaju se uzeti u obzir u statističkom modelu za procjenu genetskih parametara i uzgojnih vrijednosti mliječnih goveda za rezistentnost na toplinski stres,
- primjena odabranih optimalnih statističkih modela za procjenu pokazala je statistički visoko značajan ($p < 0,05$) utjecaj parametara mikrokline (temperatura, T, relativna vlažnost, RH, i temperaturno-humidni indeks, THI) na varijabilnost analiziranih proizvodnih svojstava u mliječnih krava (dnevna mliječnost, dnevni sadržaj masti, proteina, laktoze i uree te broj somatskih stanica),
- odabranim statističkim modelom utvrđeno je statistički značajno ($p < 0,05$) smanjenje dnevne mliječnosti i dnevnog sadržaja masti i proteina uzrokovano povećanjem T i THI u obje pasmine;
- dnevni sadržaj uree i broj somatskih stanica povećali su se u smislu povećanog dnevnog T, RH i THI u obje analizirane pasmine,
- dnevni sadržaj laktoze pokazao je vrlo nisku varijabilnost zbog varijacija u mikroklimatskim uvjetima,

-
- analiza varijabilnosti dnevnih svojstava mlijeka s obzirom na uvjete toplinskog stresa (normalni ili stresni: HS-0 / HS-1) na različitim pragovima vrijednosti THI (68 i 72) pokazala je statistički značajnu ($p < 0,05$) razliku u svim analiziranim svojstvima s izuzetkom logSCC,
 - veća razlika između dnevne količine mlijeka krava u normalnim uvjetima u odnosu na stanje toplinskog stresa utvrđena je kod krava holstein pasmine, kao i kod više testirane vrijednosti praga THI (72 u odnosu na 68),
 - varijabilnost u dnevnom sadržaju mliječne masti, proteina i laktoze te logSCC zbog toplinskog stresa bila je slična kod obje pasmine dok je dnevni sadržaj uree pokazao značajno povećanje ($p < 0,05$) kod svih krava u okruženju toplinskog stresa s većim porastom kod simentalke pasmine i kod izraženijeg toplinskog stresa (viša vrijednost praga THI, THI = 72),
 - odabrani statistički model može poslužiti kao osnova za daljnja istraživanja s ciljem procjene genetskih parametara, kao i uzgojne vrijednosti otpornosti na toplinu,
 - analiza genetskih parametara pokazuje da je pri višim vrijednostima THI-a učinak stalnog okruženja bio izraženiji, te je sličan trend povećanja varijance u normalnom stanju s obzirom na vrijednosti praga THI_{prag} utvrđen i u varijance uslijed interakcije stado-godina i rezidualne varijance i to u obje analizirane pasmine krava,
 - u uvjetima toplinskog stresa (THI = 1), s obzirom na postavljenu vrijednost praga THI_{prag}, uočeno je smanjenje rezidualne varijance, dok se povećala varijanca interakcije stado-godina u obje analizirane pasmine krava,
 - procijenjena varijanca za individualni utjecaj životinje bila je nešto veća u uvjetima toplinskog stresa kao i pri višim vrijednostima postavljenog THI praga s izuzetkom kada je THI-a jednak 76,
 - procijenjeni omjeri varijance i korelacije za dnevnu proizvodnju mlijeka holstein i simentalke pasmine krava u odnosu na definiranu vrijednost praga (THI_{prag} 68, 70 ili 72 / 72, 74, 76) ukazuju na vrlo važnu ulogu upravljanja stadom u ublažavanju toplinskog stresa na mliječnim farmama,
 - vrijednosti heritabiliteta za dnevnu proizvodnju mlijeka krava holstein pasmine u normalnim uvjetima u staji (THI = 0) iznosile su između 20,16 % - 20,31%, dok su u uvjetima toplinskog stresa (THI = 1) bile slični i varirali između 20,12 i 20,30 %,

-
- vrijednost heritabiliteta za dnevnu proizvodnju mlijeka krava simentalke pasmine u normalnim uvjetima u staji (THI = 0) bila je oko 23,50%, dok je u uvjetima toplinskog stresa (THI = 1) bila veća i kretala se između 23,78-24,20%.
 - procijenjene genetske korelacije u holstein pasmine bile su visoke, te su ovisno o vrijednosti praga THI, iznosile od 94,35 % pri najnižem THI (68), do 94,87 % na najvišem THI (72),
 - procijenjene genetske korelacije u simentalke pasmine bile su visoke te su, ovisno o vrijednosti praga THI iznosile od 96,13% pri najnižem THI (72) do 98,09% na najvišem THI (76).
 - visoke vrijednosti procijenjenih genetske korelacije između dnevne proizvodnje mlijeka u normalnim uvjetima i dnevne proizvodnje mlijeka u uvjetima toplinskog stresa indiciraju da će krave s visokom proizvodnjom u normalnim uvjetima održati jednake razine proizvodnje i u uvjetima toplinskog stresa,
 - srednja vrijednost uzgojne vrijednost (UV) krava holstein pasmine unatoč uvjetima okoliša, iznosila otprilike 100,6 s najvišom procijenjenom vrijednosti u normalnim uvjetima pri THI (70), te u uvjetima toplinskog stresa pri THI (72),
 - u simentalke pasmine srednja vrijednost UV-a za dnevnu proizvodnju mlijeka iznosila je oko 100,5, te je u normalnim uvjetima bila je najveća pri najnižoj vrijednosti THI, dok je u uvjetima toplinskog stresa najveća UV bila pri na najvišoj vrijednosti THI,
 - korelacije između UV krava holstein pasmine u normalnim uvjetima i uvjetima toplinskog stresa bile su visoke i iznosile između 98,64-98,91 % indicirajući jaku povezanost između produktivnosti krava u normalnoj i okolini karakteriziranom toplinskim stresom,
 - korelacije između UV-a krava simentalke pasmine u normalnim uvjetima i uvjetima toplinskog stresa bile su visoke i kretale su se između 99,48-99,76% što ukazuje na snažnu vezu između produktivnosti krava u normalnom okruženju i okruženju toplinskog stresa.
 - procijenjene visoke genetske korelacije između dnevne proizvodnje mlijeka u normalnim uvjetima i uvjetima toplinskog stresa, kao i visoke korelacije između UV-ima u normalnim uvjetima i uvjetima toplinskog stresa, indiciraju da će mliječne krave s visokom produktivnošću u normalnom stanju održati jednaku

- razinu proizvodnje čak i u uvjetima toplinskog stresa. Stoga se može pretpostaviti dobra aklimatizacija mliječnih krava na uvjete okoliša na farmama u Hrvatskoj,
- kako bi se pojednostavila provedba selekcije mliječnih grla na rezistentnost na toplinski stres u proizvodnim uvjetima, u ovom je istraživanju dnevna proizvodnja mlijeka analizirana kao bivarijantna varijabla i to u normalnim uvjetima (ispod THI_{prag} vrijednosti), i u uvjetima toplinskog stresa (iznad THI_{prag} vrijednosti),
 - bivarijantna analiza znači da se za svako grlo procjenjuje UV u normalnim uvjetima te u uvjetima toplinskog stresa odnosno da uzgajivači prilikom selekcije uvažavaju onu uzgojnu vrijednost sukladno okolišnim uvjetima u farmskim objektima.

5. LITERATURA

1. Aguilar, I., Misztal, I., Tsuruta, S. (2009): Genetic components of heat stress for dairy cattle with multiple lactations. *Journal of Dairy Science* 92, 5702-5711. <https://doi.org/10.3168/jds.2008-1928>
2. Albright J.L. und Arave C.W. (1997): *The behavior of cattle*; CAB INTERNATIONAL Wallingford, UK, ISBN 0851991963; S. 154 – 157.
3. Almeida G.L.P., Pandorfi H., Guiselini C. (2011): Uso do Sistema de resfriamento adiabático evaporativo no conforto térmico de vacas da raça Girolando. *Revista Brasileira de Engenharia Agrícola e Ambiental* 15:754-760.
4. Auernhammer R. (1995): Untersuchungen über die Eignung verschiedener Körperstellen zur automatisierten Messung der Körpertemperatur beim Rind; Dissertation, Ludwig-Maximilians Universität München, Veterinärmedizinische Fakultät.
5. Balfoussia E., Skenderi K., Tsironi M., Anagnostopoulos A.K., Parthimos N., Vougas K., Papassotiriou I., Tsangaris G.T., Chrousos G.P. (2014): A proteomic study of plasma protein changes under extreme physical stress. *Journal of Proteomics*, 98 (2014) 1-14.
6. Battisti D.S., Naylor R.L. (2009): Historical warnings of future food insecurity with unprecedented seasonal heat. *Science*, 323, 240-244.
7. Baumgard L.H., Rhoads R.P. (2013). Effects of heat stress on postabsorptive metabolism and energetics. *Annual Review of Animal Biosciences*, 1: 311-337.
8. Baumgartner W. (2009): Allgemeiner klinischer Untersuchungsgang; In: Baumgartner W. (Hrsg.): *Klinische Propädeutik der Haus- und Heimtiere*; Parey Verlag, Stuttgart; S. 43 – 195.
9. Berman A. (2005): Estimates of heat stress relief needs for Holstein dairy cows; *Journal of Animal Science* 83; S. 1377 – 1384.
10. Bernabucci U., Lacetera N., Baumgard L.H., Rhoads R.P., Ronchi B., Nardone A. (2010): Metabolic and hormonal acclimation to heat stress in domestic ruminants. *Animal*, 4, 1167-1183. <https://doi.org/10.1017/S175173111000090X>
11. Bianca W. (1968): Thermoregulation; In: Hafez E.S.E. (Hrsg.): *Adaption of Domestic Animals*; Lea und Febiger, Philadelphia; S. 97 – 118.
12. Biffani, S., Bernabucci, U., Vitali, A., Lacetera, N., Nardone, A. (2016): Short communication: effect of heat stress on the non-return rate of Italian Holstein cows. *Journal of Dairy Science* 99, 5837-5843. <https://doi.org/10.3168/jds.2015-10491>
13. Blum J.W. (2003): *Bioklimatologie der Haustiere*; Vorlesungsskript Tierhaltung, Univ. Bern, 4. Semester.
14. Bohmanova, J. (2006): *Studies on genetics of heat stress in US Holsteins*. PhD thesis. Athens: University of Georgia.

15. Bohmanova, J., I., Misztal, S., Tsuruta, H.D., Norman, T.J., Lawlor (2005): National genetic evaluation of milk yield for heat tolerance of United States Holsteins. *Interbull Bull*, 33: 160-162.
16. Bohmanova, J., J., Jamrozik, F., Miglior, I., Misztal, P.G., Sullivan (2007): Legendre polynomials versus linear splines in the Canadian test-day model. *Interbull Bull*, 37: 42-48.
17. Bohmanova, J., Misztal I., Cole J.B. (2007): Temperature-humidity indices as indicators of milk production losses due to heat stress. *Journal of Dairy Science*, 90, 1947-1956. <https://doi.org/10.3168/jds.2006-513>
18. Bouraoui R., Lahmar M., Majdoub A., Djemali M., Belyea R. (2002): The relationship of temperature humidity-index with milk production of dairy cows in a Mediterranean climate. *Animal Research*, 51, 479-491. <https://doi.org/10.1051/animres:2002036>
19. Brade W. (2013): Milcherzeugung unter den Bedingungen des Klimawandels – Möglichkeiten zur Vermeidung oder Minderung des Hitzestresses; *Berichte über Landwirtschaft*, Band 91, Ausgabe 3.
20. Bradford, H.L., Fragomeni, B.O., Bertrand, J.K., Lourenco D.A.L., Misztal, I. (2016): Genetic evaluations for growth heat tolerance in Angus cattle. *Journal of Animal Science* 94, 4143-4150. <https://doi.org/10.2527/jas.2016-0707>
21. Broom D.M. und Johnson K.G. (1993): Stress; In: Broom D.M., Johnson K.G. (Hrsg.): *Stress and Animal Welfare*; Kluwer Academic Publishers, Dordrecht, The Netherlands; S. 57 –72.
22. Brown-Brandl T.M., Eigenberg R.A., Nienaber J.A. und Hahn G.L. (2005): Dynamic Response Indicators of Heat Stress in Shaded and Non-shaded Feedlot Cattle, Part 1: Analyses of Indicators; *Biosystems Engineering* 90 (4), S. 451 – 456.
23. Brügemann, K., Gernand, E., von Borstel, U. U., König, S. (2011): Genetic analyses of protein yield in dairy cows applying random regression models with time-dependent and temperature x humidity-dependent covariates. *Journal of Dairy Science* 94, 4129-4139. <https://doi.org/10.3168/jds.2010-4063>
24. Calegari F. und Frazzi E. (2002): Circadian trend of vaginal temperature of Friesian cows during summer season; *Bornimer Agrartechnische Berichte*, Heft 29; S. 143 – 148.
25. Carabaño, M.J., Bachagha, K., Ramón, M., Díaz, C. (2014): Modeling heat stress effect on Holstein cows under hot and dry conditions: Selection tools. *Journal of Dairy Science* 97, 7889-7904. <https://doi.org/10.3168/jds.2014-8023>
26. Carroll J.A. und Burdick Sanchez N.C. (2013): The Physiology of Stress and Effects on Immune Health in Ruminants; In: *Proceedings of the 28th Annual Southwest Nutrition and Management Conference*, Arizona; S. 35 – 44.
27. Casa A.C., Ravelo A.C. (2003): Assessing temperature and humidity conditions for dairy cattle in Cordoba, Argentina. *International Journal of Biometeorology*, 48, 6–9.

-
28. Casa, A.C., Ravelo, A.C. (2003): Assessing temperature and humidity conditions for dairy cattle in Cordoba, Argentina. *International Journal of Biometeorology* 48, 6-9.
<https://doi.org/10.1007/s00484-003-0179-x>
 29. Collier R.J. und Zimbelman R.B. (2007): Heat Stress Effects on Cattle: What We Know and What We Don't Know; In: *Proceedings of the 22nd Annual Southwest Nutrition and Management Conference*, Arizona; S. 76 – 83.
 30. Collier R.J., Dahl G.E., Van Baale M.J. (2006): Major advances associated with environmental effects on dairy cattle. *Journal of Dairy Science*, 89, 1244-1253.
 31. Collier R.J., Hall L.W. (2012): Quantifying heat stress and its impact on metabolism and performance. Tucson, Arizona: Department of Animal Sciences, University of Arizona.
 32. Collier, R.J., Dahl, G.E., van Baale, M.J. (2006): Major advances associated with environmental effects on dairy cattle. *Journal of Dairy Science* 89, 1244-1253.
[https://doi.org/10.3168/jds.s0022-0302\(06\)72193-2](https://doi.org/10.3168/jds.s0022-0302(06)72193-2)
 33. Collier, R.J., Hall, L.W. (2012): Quantifying heat stress and its impact on metabolism and performance. Tucson, Arizona: Department of Animal Sciences, University of Arizona.
 34. Correa-Calderon A., Armstrong D., Ray D., De Nise S., Enns M., Howison C. (2004): Thermoregulatory responses of Holstein and Brown Swiss heat-stressed dairy cows to two different cooling systems. *International Journal of Biometeorology*, 48, 142-148.
<https://doi.org/10.1007/s00484-003-0194-y>
 35. Das R., Sailo L., Verma N., Bharti P., Saikia J., Imtiwati, Kumar R. (2016): Impact of heat stress on health and performance of dairy animals: A review. *Veterinary World*, 9(3): 260-268.
 36. Druet, T., F., Jaffrézic, D., Boichard, V., Ducrocq (2003): Modeling lactation curves and estimation of genetic parameters for first lactation test-day records of French Holstein cows. *J. Dairy Sci.*, 86(7): 2480-2490.
 37. Du Preez J.H., Giesecke W.H., Hattingh P.J. (1990a): Heat stress in dairy cattle and other livestock under Southern African conditions. I. Temperaturehumidity index mean values during the four main seasons. *Onderstepoort Journal of Veterinary Research*, 57, 77-86.
 38. Du Preez J.H., Hatting P.J., Giesecke W.H., Eisenberg B.E. (1990b): Heat stress in dairy cattle and other livestock under Southern African conditions. III. Monthly temperature-humidity index mean values and their significance in the performance of dairy cattle. *Onderstepoort Journal of Veterinary Research*, 57, 243-248.
 39. Dunn R.J.H., Mead N.E., Willett K.M., Parker D.E. (2014): Analysis of heat stress in UK dairy cattle and impact on milk yields. *Environmental Research Letters* 9, 064006.
 40. Dussert L. und Piron A. (2012): Live yeast could help reduce the impact of heat stress on dairy production;
<https://en.engormix.com/dairy-cattle/articles/live-yeast-dairy-production/35335.htm>

41. Fiedler M., Hoffmann G., Loebstin C., Berg W., Von Bonrutzki K., Ammon C. und Amon T. (2012): Luftgeschwindigkeit und Hitzebelastung im Milchviehstall – Auswirkungen auf das Tierwohl; *Landtechnik* 67 (6); S. 421 – 424.
42. Freitas, M., Misztal, I., Bohmanova, J., Torres, R. (2006): Regional differences in heat stress in U.S. Holsteins. *Proc 8th World Congr. Genet. Appl. Livest. Prod., Commun.* 01- 11, Instituto Prociencia, Belo Horizonte, Brazil.
43. Gaafar H.M.A., Gendy M.E., Bassiouni M.I., Shamiah S.M., Halawa A.A., Hamd M.A. (2011): Effect of heat stress on performance of dairy Friesian cow's milk production and composition. *Researcher*, 3(5): 85-93.
44. Gantner V., Bobić T., Gantner R., Gregić M., Kuterovac K., Novaković J., Potočnik K. (2017): Differences in response to heat stress due to production level and breed of dairy cows. *International Journal of Biometeorology* 61, 9, 1675- 1685. <https://doi.org/10.1007/s00484-017-1348-7>
45. Gantner V., Mijić P., Kuterovac K., Solić D., Gantner R. (2011). Temperature-humidity index values and their significance on the daily production of dairy cattle. *Mljekarstvo*, 61(1), 56- 63.
46. Gaughan J.B., Mader T.L., Holt S.M. und Lisle A. (2008): A new heat load index for feedlot cattle; *Journal of Animal Science* 86; S. 226 – 234.
47. Gaughan, J.B., Mader, T.L., Gebremedhim, K.G. (2012): Rethinking heat index tools for livestock. In: Collier, R.J., and J.L. Collier. *Environmental physiology of livestock*. Chichester, West Sussex, UK: Wiley-Blackwell. <https://doi.org/10.1002/9781119949091.ch14>
48. Gauly M., Bollwein H., Breves G., Brügemann K., Dänicke S., Das, Demeler J.G., Hansen H., Isselstein J., König S., Lohölter M., Martinsohn M., Meyer U., Potthoff M., Sanker C., Schröder B., Wrage N., Meibaum B., Von Samson-Himmelstjerna G., Stinshoff H., Wrenzycki C. (2013): Future consequences and challenges for dairy cow production systems arising from climate change in Central Europe-A review. *Animal*, 7, 843-859.
49. Georg H., Ude G., Schwalm A. und Wenderel B. (2009): Untersuchung von Injektaten zur elektronischen Tierkennzeichnung mit Temperatursensoren und Überprüfung geeigneter Injektionsorte bei Bullenkälbern; *Landbauforschung – vTI Agriculture and Forestry Research* 4 (59): S. 287 – 294.
50. Hammami H., Bormann J., M'hamdi N., Montaldo H.H., Gengler N. (2013): Evaluation of heat stress effects on production traits and somatic cell score of Holsteins in a temperate environment. *Journal of Dairy Science*, 96, 1844– 1855. <https://doi.org/10.3168/jds.2012-5947>
51. Hansen P.J. (2013): Genetic control of heat stress in dairy cattle. In: *Proceedings 49th Florida Dairy Production Conference*, Gainesville, April 10, 2013. Intergovernmental Panel on Climate Change – IPCC (2007): *Climate change 2007: The physical science basis. Contribution of*

- Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge: Cambridge University Press.
52. Heidenreich T., Büscher W. und Cielejewski H. (2005): Vermeidung von Wärmebelastung für Milchkühe; In: DLG-Merkblatt 336; Hrsg.: Deutsche Landwirtschafts-Gesellschaft e.V., Frankfurt a. Main.
53. Hubbard, K.G., Stooksbury, D.E., Hahn, G.L., Mader, T.L. (1999): A climatologic perspective on feedlot cattle performance and mortality related to the temperaturehumidity index. *Journal of Production Agriculture* 12, 650-653. <https://doi.org/10.2134/jpa1999.0650>
54. Ipcc. Climate Change (2007): Mitigation. Contribution of Working Group III to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change. B. Metz, O.R. Davidson, P.R. Bosch, R. Dave, Meyer, L.A. eds. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA.
55. Jentsch W., Derno M. und Weiher O. (2001): Wärmeabgabe der Milchkühe in Abhängigkeit von der Leistung – eine Studie; *Archiv Tierzucht* 44; S. 599 – 610.
56. Jessen C. (2000): Wärmebilanz und Thermoregulation; In: von Engelhardt W., Breves G. (Hrsg.): *Physiologie der Haustiere*, Enke Verlag, Stuttgart; S. 446 – 460.
57. Jessen C. (2005): Temperatur, Adaption und Regulation; In: Penzlin H. (Hrsg.): *Lehrbuch der Tierphysiologie*, Elsevier Verlag, München; S. 445 – 474.
58. Kadzere C.T., Murphy M.R., Silanikove N., Maltz E. (2002): Heat stress in lactating dairy cows: a review. *Livestock Production Science*, 77, 59-91.
59. Kadzere, C.T., Murphy, M.R., Silanikove, N., Maltz, E. (2002): Heat stress in lactating dairy cows: a review. *Livestock Production Science* 77, 59-91. [https://doi.org/10.1016/S0301-6226\(01\)00330-X](https://doi.org/10.1016/S0301-6226(01)00330-X)
60. Kaufmann C. und Thun R. (1998): Einfluß von akutem Streß auf die Sekretion von Cortisol und Progesteron beim Rind; *Tierärztliche Umschau* 53 (7); S. 403 – 409.
61. Kibler H.H. (1964): Environmental physiology and shelter engineering. LXVII. Thermal effects of various temperature-humidity combinations on Holstein cattle as measured by eight physiological responses. *Research Bulletin*, University of Missouri, College of Agriculture, Agricultural Experiment Station, 862.
62. Klein, H.G.F. (1984): Auswirkungen einer Temperaturbelastung während der Dauer der ersten Laktation auf Leistung und Thermoregulation bei Kühen der Rasse Deutsche Schwarzbunte; Dissertation Technische Universität Berlin.
63. Kovač, M., Groeneveld, E., Garcia-Cortez, A. (2012): VCE-6, version 6.0.3-dev.
64. Lambertz, C., Sanker, C., Gauly, M. (2014): Climatic effects on milk production traits and somatic cell score in lactating Holstein-Friesian cows in different housing systems. *American Dairy Science Association. Journal of Dairy Science* 97 (1), 319-329.

-
65. Lambertz, C., Sanker, C., Gauly, M. (2014): Climatic effects on milk production traits and somatic cell score in lactating Holstein-Friesian cows in different housing systems. *Journal of Dairy Science* 97, 319-329. <https://doi.org/10.3168/jds.2013-7217>
66. Loebstin C., Tober O., Fiedler M., Schröter K. (2012): Hitzestress bei Milchrindern und Möglichkeiten der Minderung; Mitteilungen der Landesforschungsanstalt für Landwirtschaft und Fischerei Mecklenburg-Vorpommern, Heft 49, S. 64 – 72.
67. Lyhs L. (1971): Grundlagen der Thermoregulation und des Wärmehaushaltes; In: Lyhs L. (Hrsg.), *Der Wärmehaushalt landwirtschaftlicher Nutztiere*; Gustav Fischer Verlag, Jena; S. 13 – 36.
68. Mačuhová J., Enders S., Peis R., Guterman S., Freiburger M., Haidn B. (2008): Untersuchungen zur Optimierung des Stallklimas in Außenklimaställen für Milchvieh; Schriftenreihe der Bayerischen Landesanstalt für Landwirtschaft, ISSN 1611-4159.
69. Menéndez-Buxadera, A., Molina, A., Arrebola, F., Clemente, I., Serradilla J.M. (2012): Genetic variation of adaptation to heat stress in two Spanish dairy goat breeds. *Journal of Animal Breeding and Genetics* 129, 306-315. <https://doi.org/10.1111/j.1439-0388.2011.00984.x>
70. Mijić. P., Bobić. T., Vučković. G. (2018.): Mikroklima u objektima za krave u proizvodnji mlijeka; Sveučilišni priručnik; Sveučilište Josipa Jurja Strossmayera u Osijeku; Poljoprivredni fakultet u Osijeku
71. Min L., Zheng N., Zhao S., Cheng J., Yang Y., Zhang Y., Yang H., Wang J. (2016): Long-term heat stress induces the inflammatory response in dairy cows revealed by plasma proteome analysis. *Biochemical and Biophysical Research Communications*, 4; 471 (2): 296-302. NRC. (2007): *Nutrient Requirements of Small Ruminants, Sheep, Goats, Cervids, and New World Camelids*. National Academy Press, Washington, DC.
72. Misztal, I. (1999): Model to study genetic component of heat stress in dairy cattle using national data. *J. Dairy Sci.*, 82(Suppl. 1): 32. (Abstr.)
73. Misztal, I. (2006): Properties of random regression models using linear splines. *J. Anim. Breed Genet.*, 123(2): 74-80.
74. Moseley, C., O., Panferov, C., Döring, J., Dietrich, U., Haberlandt, V., Ebermann, D., Rechid, F., Beese, D., Jacob (2012): Empfehlung für eine niedersächsische Strategie zur Anpassung an die Folgen des Klimawandels. Niedersächsisches Ministerium für Umwelt, Energie und Klimaschutz, Regierungskommission Klimaschutz, Hannover, Germany. Accessed Aug. 15, 2012.
75. Möstl, E., Palme R. (2002): Hormones as indicators of stress; *Domestic Animal Endocrinology* 23; S. 67 – 74.
76. Nichelmann, M. (1971): Der Wärmehaushalt beim Rind; In: Lyhs L. (Hrsg.), *Der Wärmehaushalt landwirtschaftlicher Nutztiere*; Gustav Fischer Verlag, Jena; S. 37 – 103.
-

-
77. Ravagnolo, O., Misztal, I., Hoogenboom, G. (2000): Genetic component of heat stress in dairy cattle, development of heat index function. *Journal of Dairy Science*, 83, 2120-2125.
78. Ravagnolo, O., Misztal, I. (2000): Genetic component of heat stress in dairy cattle, parameter estimation. *Journal of Dairy Science* 83, 2126-2130. [https://doi.org/10.3168/jds.s0022-0302\(00\)75095-8](https://doi.org/10.3168/jds.s0022-0302(00)75095-8)
79. Reiczig J., Solymosi N., Könyves L., Maróti-Agóts A., Kern A., Bartyik J. (2009): Examination of heat stress caused milk production loss by the use of temperature-humidity indices. *Magy Allatorv*, 131: 137-144.
80. Rößner S., PACHE S., HÖRING O., GEIDEL S. und Bergfeld U. (2005): Ergebnisse zu methodischen Untersuchungen zur Bestimmung der Radiation von Milchkühen; DGfZ, Veröffentlichung zur Vortragstagung am 21./22. September 2005, Berlin.
81. Rütz A. (2010): Untersuchung verschiedener Parameter auf ihre Eignung zur Bewertung der Tiergerechtigkeit von Laufställen für Milchkühe im Rahmen eines On-farm welfare assessment; Dissertation Ludwig-Maximilians Universität München, Veterinärmedizinische Fakultät.
82. Sánchez, J. P., Misztal, I., Aguilar, I., Zumbach, B., Rekaya, R. (2009): Genetic determination of the onset of heat stress on daily milk production in the US Holstein cattle. *Journal of Dairy Science* 92, 4035-4045. <https://doi.org/10.3168/jds.2008-1626>
83. Sánchez, J.P., R., Rekaya, I., Misztal (2009): Reaction norm model subject to threshold response for genetic evaluation on heat tolerance. *Genet. Sel. Evol.*, 41:10.
84. Santos Daltro D., Fischer V., München Alfonso E.P., Calderaro Dalcin V., Tempel Stumpf M., Kolling G.J., Marcos Vinícius Gualberto Barbosa Da Silva, Mcmanus C. (2017): Infrared thermography as a method for evaluating the heat tolerance in dairy cows. *Revista Brasileira de Zootecnia / Brazilian Journal of Animal Science*, 46(5), 374- 383.
85. SAS Institute Inc. (2000). SAS User's Guide, version 8.2 ed. Cary, NC: SAS Institute Inc.
86. Schaeffer, L.R. (2004): Application of random regression models in animal breeding. *Livest. Prod. Sci.*, 86(1-3): 35-45.
87. Segnalini M., Bernabucci U., Vitali A., Nardone A., Lacetera N. (2013): Temperature humidity index scenarios in the Mediterranean basin. *International Journal of Biometeorology*, 57, 451–458. <https://doi.org/10.1007/s00484-012-0571-5>
88. Silvestre, A.M., F., Petim-Batista, J., Colaco (2005): Genetic parameter estimates of Portuguese dairy cows for milk, fat, and protein using a spline test-day model. *J. Dairy Sci.*, 88(3): 1225-1230.
89. Smith D.L., Smith T., Rude B.J., Ward S.H. (2013): Short communication: Comparison of the effects of heat stress on milk and component yields and somatic cell score in Holstein and Jersey cows. *Journal of Dairy Science*, 96, 3028–3033. <https://doi.org/10.3168/jds.2012-5737>
-

-
90. Spiers D.E., Spain J.N., Sampson J.D., Rhoads R.P. (2004): Use of physiological parameters to predict milk yield and feed intake in heat-stressed dairy cows. *Journal of Thermal Biology*, 29(7-8): 759-764.
 91. St-Pierre N.R., Cobanov B., Schnitkey G. (2003): Economic losses from heat stress by US livestock industries. *Journal of Dairy Science*, 86, 52–77. [https://doi.org/10.3168/jds.s0022-0302\(03\)74040-5](https://doi.org/10.3168/jds.s0022-0302(03)74040-5)
 92. Tober O., Loebin C., Sanftleben P. (2011): Untersuchungen telemetrisch erfassbaren Verhaltens sowie ausgewählter physiologischer und Stallklimaparameter bei Hochleistungskühen unter den Bedingungen moderner Außenklima-Laufstallhaltung zur Schaffung von Managementhilfen und Optimierungen der Tierumwelt; Forschungsbericht der Landesforschungsanstalt für Landwirtschaft und Fischerei Mecklenburg Vorpommern, 1/12.
 93. Tober, O., Loebin, C. (2013): Das Verhalten von laktierenden Milchkühen in einem Außenklima-Laufstall in Abhängigkeit von der Stalllufttemperatur; *Berliner und Münchener Tierärztliche Wochenschrift* 126 (9); S. 388 – 393.
 94. TVT-Merkblatt 100 (2010): Die Vermeidung von Hitzeschäden bei landwirtschaftlichen Nutztieren (Geflügel, Schweine, Rinder); Hrsg.: Tierärztliche Vereinigung für Tierschutz e.V., TVT, Bramsche.
 95. Upadhyay R.C., Ashutosh, Singh S.V. (2009): Impact of climate change on reproductive functions of cattle and buffalo. In: Aggarwal, P.K., editor. *Global Climate Change and Indian Agriculture*. ICAR, New Delhi. 107-110.
 96. Van Laer E., Moons C.P.H., Sonck B., Tuytens F.A.M. (2014): Importance of outdoor shelter for cattle in temperate climates; *Livestock Science* 159; S. 87 – 101.
 97. Vasconcelos J. L. M., Demetrio D. G. B. (2011): Manejo reprodutivo de vacas sob estresse calórico. *Revista Brasileira de Zootecnia* 40:396-401.
 98. Vickers L.A., Burfeind O., Von Keyserlingk M.A.G., Veira D.M., Weary D.M. und Heuwieser W. (2010): Technical note: Comparison of rectal and vaginal temperatures in lactating dairy cows; *Journal of Dairy Science* 93; S. 5246 – 5251.
 99. Vitali A., Sagnalini M., Bertocchi L., Bernabucci U., Nardone A., Lacetera N. (2009): Seasonal pattern of mortality and relationships between mortality and temperature humidity index in dairy cows. *Journal of Dairy Science*, 92, 3781-3790.
 100. West J.W. (2003): Effects of heat-stress on production in dairy cattle. *Journal of Dairy Science*, 86(6): 2131-2144. [https://doi.org/10.3168/jds.s0022-0302\(03\)73803-x](https://doi.org/10.3168/jds.s0022-0302(03)73803-x)
 101. West J.W., Hill G.M., Fernandez J.M., Mandevu P., Mullinix B.G. (1999): Effect of dietary fiber on intake, milk yield, and digestion by lactating dairy cows during cool or hot, humid weather. *Journal of Dairy Science*, 82, 2455- 2465. [https://doi.org/10.3168/jds.s0022-0302\(99\)75497-4](https://doi.org/10.3168/jds.s0022-0302(99)75497-4)

102. Wheelock J.B., Rhoads R.P., Van Baale M.J., Sanders S.R., Baumgard L.H. (2010): Effect of heat stress on energetic metabolism in lactating Holstein cows. *Journal of Dairy Science*, 93(2): 644-655.
103. Yoon I. (2014.): The impact of heat stress on milk fat depression; *International Dairy Topics*, Vol. 13 (5); S. 19 – 21.
104. Zimbelman R.B. (2008): Management Strategies to Reduce Effects of Thermal Stress on Lactating Dairy Cattle; Dissertation, University of Arizona, Department of Animal Science.
105. Zimbelman R.B., Rhoads R.P., Rhoads M.L., Duff G.C., Baumgard L.H., Collier R.J. (2009): A Re-Evaluation of the Impact of Temperature Humidity Index (THI) and Black Globe Humidity Index (BGHI) on Milk Production in High Producing Dairy Cows; Vortrag auf der Southwest Nutrition and Management Conference, Savoy, Illinois.

Izvorni znanstveni rad broj 1 u obliku i izvornom jeziku na kojem je objavljen u znanstvenom časopisu

Naslova rada: **ANALYSIS OF PRODUCTION TRAITS AND MICROCLIMATE PARAMETERS ON DAIRY CATTLE FARMS**

Autori: ***Goran Vučković, Tina Bobić, Pero Mijić, Mirna Gavran, Klemen Potočnik, Vladan Bogdanović, Vesna Gantner***

Tip rada: Izvorno znanstveni rad

Časopis: ***Biotechnology in Animal Husbandry***

Kategorija: A2

Impakt faktor: -

Kvartil: -

Primljen na recenziju: 04. studeni 2019.

Prihvaćen za objavljivanje: 28. studeni 2019.

Status: Objavljen

Volumen: 35

Svezak: 4

Stranice: 323 - 334

WOS broj: -

ANALYSIS OF PRODUCTION TRAITS AND MICROCLIMATE PARAMETERS ON DAIRY CATTLE FARMS

Goran Vučković¹, Tina Bobić², Pero Mijić², Mirna Gavran², Klemen Potočnik³, Vladan Bogdanović⁴, Vesna Gantner²

¹Rinderunion Baden-Württemberg, Herberlingen, Germany

²Department for Animal Production and Biotechnology, Faculty of Agrobiotechnology Osijek, University of Josip Juraj Strossmayer in Osijek, Osijek, Croatia

³Department of Animal Science, Biotechnical Faculty, University of Ljubljana, Ljubljana, Slovenia

⁴Faculty of Agriculture University of Belgrade, Belgrade, Serbia

Corresponding author: Vesna Gantner, vgantner@fazos.hr

Original scientific paper

Abstract: Aiming determination of the variability of production traits (daily milk yield and composition) and microclimate parameters (ambient temperature and humidity) in the barns; as well as the correlation between the analyzed groups of traits, 1,636,192 test-day records from Simmentals and 1,275,713 test-day records from Holsteins were analysed. Performed analysis indicate high variability of production traits due to cow's breed, parity as well as breeding region. Also, high variability of microclimate parameters in the barns due to season and breeding region was found. Furthermore, statistically highly significant ($p < 0.001$) correlations between the production traits and microclimate parameters were determined. Finally, the negative effect of inadequate microclimate on daily milk production was determined in both breeds in all breeding regions. Since genetic evaluation and selection of dairy cattle for heat resistance is only long-term method for heat stress managing, determined effect will be taken into account in the statistical model for estimation of genetic parameters and breeding values.

Key words: production traits, dairy cows, microclimate parameters

Introduction

As climate change has become a pervasive topic in global agricultural production, thus, heat stress in Europe is becoming a growing problem in livestock production especially in dairy cattle breeding (Gauly *et al.*, 2013). Every day we are witnessing faster and more pronounced climate change around the world. These changes will result in increasingly unfavourable climatic conditions for agricultural and especially livestock production (IPCC, 2007). For instance, Reiczigel *et al.* (2009) in Hungary, as well as Dunn *et al.* (2014) in UK indicated an increase of heat stress days per year. Almeida *et al.* (2011) stated that the optimal ambient

temperature for dairy production depends on the species, breed, feed intake, age, acclimatization, yield levels, coat and hair characteristics and also on animal tolerance to heat and cold. Also, accordingly to Santos Daltro et al. (2017), high-producing dairy cows are more sensitive to heat stress because, by increasing milk production, cows produce more metabolic heat. In accordance to Vasconcelos and Demetrio (2011), selection for milk production reduces the ability of the cow to withstand the stress caused by heat and consequently during the hotter months of the year, increases susceptibility to heat stress and decreases production and reproductive efficiency. Similarly, Hansen (2013) stated that the high production makes cows more susceptible to heat stress meaning that heat stress will become, and already is, a problem in intensive dairy breeding systems regardless the climate changes. Bohmanova (2006) and Collier et al. (2006) determined that production level significantly alter the animal response to heat stress making high production animals more sensitive to heat stress than low production ones. Heat stress adversely affects the milk production and its composition in dairy animals, especially animals of high genetic value (Bouraoui et al., 2002; West, 2003; Spiers et al., 2004; Upadhyay et al., 2009; Wheelock et al., 2010; Gantner et al. 2011, 2017). Besides, in heat stressed dairy animals, maintenance requirements of energy also increased by 30% (NRC, 2007). Furthermore, heat stress also effects health of dairy animals by imposing direct or indirect affects in normal physiology, metabolism, hormonal and immunity system (Das et al., 2016). Balfoussia et al. (2014) determined that the acclimatization to long-term stress results in proteomic changes indicated by expression of proteins related to inflammation, while Min et al. (2016) concluded that long-term moderate heat stress may lead to an inflammatory response in dairy cows with significantly increased plasma TNF- α and IL-6, which presents a pro-inflammatory factors. Finally, heat stress induces considerable profit loss (St-Pierre et al., 2003). Heat stress is considered to be a combination of temperature and humidity that exceed the comfort zone of a cow. The most common measure of heat stress in dairy cattle is temperature-humidity index (THI) that includes ambient temperature and relative humidity (Kibler, 1964). The THI threshold value at which heat stress affects milk production and feed intake vary, depending on study, from 68 to 72 (Du Preez et al., 1990a, b; Bouraoui et al., 2002; Bernabucci et al., 2010; Gantner et al., 2011; Collier and Hall, 2012), while Vitali et al. (2009) emphasised the increased risk of animals' death at THI = 80. There are numerous methods to reduce the effect of heat stress on dairy cows, that is short-term and long-term methods. Short-term methods include optimization of feeding and application of different cooling systems in farm buildings, while long-term methods mean selection of dairy cattle for resistance to heat stress. Taking into account the unquestionability of climate change, the necessity of adequate adaptation strategies in order to decrease negative effects of climate change on domestic animals was pointed out by Segnalini et al. (2013). As preconditions for genetic evaluation and selection of

dairy cattle for heat resistance the goals of this study were: 1. Determination of phenotypic variability of the analyzed groups of traits: a. statistical analysis of production traits (daily milk yield and composition) of dairy cows under selection, b. statistical analysis of microclimate parameters (ambient temperature and humidity) in the barns; and 2. Determination of the correlation between the analyzed groups of traits.

Material and Methods

For the analysis of the variability of production traits and microclimate parameters, test-day records of Holstein and dairy Simmental cows reared in Croatia were used. Test-day records were collected during the regular milk recording performed monthly in accordance to the alternative milk recording method (AT4 / BT4) in the period from January 2005 to December 2013. At each recording, measuring and sampling of milk were performed during the evening or morning milkings. Also, at each recording, ambient temperature and relative humidity in the barns were recorded. Based on measured microclimate parameters, temperature-humidity index (THI) was calculated using the following equation by *Kibler (1964)*:

$$THI = 1.8 \times Ta - (1 - RH) \times (Ta - 14.3) + 32$$

Where Ta presents the average temperature in degrees Celsius while RH is the relative humidity as a fraction of the unit. Furthermore, test-day records with lactation stage in (< 5 days and > 500 days), age at first calving in (< 21 and > 36 months), missing parity, missing breed, missing or nonsense daily milk traits (accordingly to ICAR standards, 2017), and missing or nonsense Ta and RH value were deleted from the dataset. After logical control dataset consisted of 1,636,192 test-day records from 117,659 Simmentals (10,599 farms) and 1,275,713 test-day records from 90,159 Holsteins (6,701 farms). Accordingly, to the parity, cows were divided into four classes: I, II, III, and IV. (animals in fourth and higher lactations). Furthermore, accordingly to location of farm, test day records were divided into three breeding regions: Eastern, Central, and Mediterranean. While, in accordance to the recording date, test day records were divided into four recording season: spring, summer, autumn, and winter.

For the logical control of data, determination of the variability of the analyzed groups of traits (production traits and microclimate parameters); and determination of the correlation between the analyzed groups of traits SAS/STAT (*SAS Institute Inc., 2000*) was used.

Results

The variability of production traits of dairy cows that is daily milk yield, daily fat, protein, lactose and urea content as well as somatic cell count accordingly to breed and parity, separately for each region (Eastern, Central, and Mediterranean) is presented in the Tables 1, 2, and 3.

Table 1. Variability (mean; SD) of daily production traits accordingly to breed and parity in Eastern region

Trait / Parity	Holstein				Simmental			
	I.	II.	III.	IV.	I.	II.	III.	IV.
DMY	21.50±7.8	24.23±10.4	24.57±10.7	23.45±10.5	15.42±5.1	16.60±6.1	17.20±6.4	16.61±6.2
DFC	4.09±0.9	4.13±1.0	4.13±1.0	4.11±1.0	4.12±0.9	4.12±0.9	4.10±0.9	4.06±0.9
DPC	3.41±0.4	3.44±0.5	4.00±0.5	3.36±0.45	3.45±0.5	3.49±0.5	3.47±0.5	3.43±0.5
DLC	4.53±0.2	4.44±0.2	4.41±0.2	4.36±0.26	4.57±0.2	4.50±0.2	4.46±0.2	4.42±0.3
DUC	23.24±9.0	23.95±9.2	23.49±9.3	22.67±9.6	21.34±11.6	21.54±11.7	21.70±11.7	21.28±11.6
SCC	16.42±1.9	16.77±2.1	17.07±2.1	17.34±2.2	16.12±2.0	16.44±2.1	16.64±2.1	17.03±2.2

* DMY – daily milk yield (kg); DFC – daily fat content (%); DPC – daily protein content (%); DLC – daily lactose content (%); DUC – daily urea content (mg/ml); SCC – log transformed somatic cell count

In Eastern region, the highest average daily milk yield (DMY) was determined in Holstein breed in third parity, while the lowest DMY was in Simmental breed in first parity. Daily fat content (DFC) was the lowest at the fourth parity in Simmental breed while the daily protein content (DPC) and daily lactose content (DLC) were the lowest in Holstein breed at the fourth parity. Daily urea content (DUC) was the highest at the second parity in Holstein breed. Finally, highest somatic cell count was determined in fourth parity in both breeds, with higher value determined in Holsteins.

Table 2. Variability (mean; SD) of daily production traits accordingly to breed and parity in Central region

Trait / Parity	Holstein				Simmental			
	I.	II.	III.	IV.	I.	II.	III.	IV.
DMY	18.31±6.4	19.55±7.8	19.91±8.0	19.00±7.7	14.86±5.3	15.74±6.2	16.05±6.3	15.17±5.9
DFC	4.26±0.9	4.31±0.9	4.28±0.9	4.20±0.9	4.27±0.8	4.22±0.9	4.22±0.9	4.11±0.9
DPC	3.40±0.5	3.46±0.5	3.41±0.5	3.36±0.5	3.45±0.5	3.51±0.5	3.47±0.5	3.43±0.5
DLC	4.53±0.2	4.45±0.2	4.41±0.2	4.37±0.2	4.57±0.2	4.50±0.2	4.47±0.2	4.43±0.2
DUC	21.13±10.4	20.85±10.4	20.18±10.4	19.43±10.3	19.77±10.2	19.69±10.4	19.45±10.3	18.86±10.2
SCC	16.59±2.1	16.99±2.1	17.23±2.2	17.62±2.2	16.08±2.0	16.41±2.1	16.65±2.1	17.03±2.2

* DMY – daily milk yield (kg); DFC – daily fat content (%); DPC – daily protein content (%); DLC – daily lactose content (%); DUC – daily urea content (mg/ml); SCC – log transformed somatic cell count

In dairy cattle reared in Central region, the lowest value of daily milk yield (DMY) was determined in Simmental breed at first parity, while the highest daily milk production was in Holstein breed at third parity. Daily fat content (DFC) was the highest in Holstein breed at the second parity while daily protein content (DPC) and daily lactose content (DLC) were the lowest at the fourth parity in Holstein breed. Daily urea content (DUC) was the lowest at the fourth parity in Simmental breed, while the highest was at first parity in Holstein breed. Similarly like in cows reared in Eastern region, the highest somatic cell count was determined in cows of both breed in fourth lactation.

Table 3. Variability (mean; SD) of daily production traits accordingly to breed and parity in Mediterranean region

Trait / Parity	Holstein				Simmental			
	I.	II.	III.	IV.	I.	II.	III.	IV.
DMY	21.71±7.7	23.44±9.9	24.20±10.5	22.61±10.7	13.51±5.0	14.19±5.9	14.43±6.1	14.20±5.3
DFC	3.84±0.8	3.88±0.9	3.86±0.9	3.81±0.9	4.17±0.9	4.13±0.9	4.16±1.0	4.12±1.0
DPC	3.35±0.4	3.38±0.4	3.34±0.4	3.26±0.4	3.48±0.4	3.49±0.5	3.43±0.5	3.43±0.4
DLC	4.53±0.2	4.43±0.2	4.40±0.2	4.33±0.3	4.54±0.2	4.48±0.2	4.45±0.2	4.41±0.2
DUC	22.38±8.8	23.24±9.2	23.27±9.4	22.69±9.6	21.04±10.0	22.25±10.6	21.21±10.3	20.66±9.9
SCC	16.05±1.9	16.47±2.1	16.90±2.2	17.32±2.3	15.96±2.0	16.32±2.2	16.67±2.2	17.06±2.3

* DMY – daily milk yield (kg); DFC – daily fat content (%); DPC – daily protein content (%); DLC – daily lactose content (%); DUC – daily urea content (mg/ml); SCC – log transformed somatic cell count

Similarly like in other regions, in Mediterranean region, the highest daily milk production was determined in cows in third parity in both breeds, with higher production in Holsteins. The highest daily fat content (DFC) was observed in first parity Simmentals while the highest value of daily protein content was determined in Simmentals in second parity. Similarly like in other regions, daily urea content was higher in Holsteins comparing to Simmental breed. Also, slightly higher values of somatic cell count were determined in Holsteins.

The variability of microclimate parameters that is ambient temperature, relative humidity and temperature-humidity index (THI) in the barns accordingly to breed, season and breeding region is presented in the Table 4.

The maximum ambient temperature (T) as well as the highest temperature-humidity index (THI) were recorded in the summer season in the Mediterranean region in the barns where Holstein cows were reared, while the minimum temperature was recorded in the winter season, also in Holsteins' barns but in other region – Eastern. Furthermore, the highest value of relative humidity (RH) was determined in Central region, in Simmentals' barns during the winter season.

Table 4. Variability (mean; SD) of microclimate parameters accordingly to breed, recording season and breeding region

Parameter / Season	Holstein				Simmental			
	Spring	Summer	Autumn	Winter	Spring	Summer	Autumn	Winter
Eastern region								
T	13.42±5.7	23.73±5.8	14.23±6.3	5.72±5.4	12.96±6.1	22.30±5.9	14.12±6.2	6.25±5.0
RH	66.44±12.8	64.18±13.3	67.06±13.9	69.58±14.7	67.90±11.1	67.28±11.4	70.05±10.8	71.31±11.3
THI	56.39±8.4	71.20±8.2	57.38±9.3	44.76±8.4	55.63±9.0	69.37±8.5	57.32±9.3	45.51±7.6
Central region								
T	15.69±5.8	23.90±5.0	16.20±5.7	9.31±4.5	15.91±5.7	24.05±5.1	16.58±5.6	9.88±4.4
RH	68.12±10.7	69.08±10.9	71.62±10.3	72.84±9.9	69.18±10.3	69.87±10.5	72.52±9.8	73.86±9.5
THI	59.70±8.5	72.00±7.5	60.57±8.6	50.09±7.0	60.03±8.5	72.30±7.6	61.15±8.5	50.91±6.9
Mediterranean region								
T	14.73±5.0	25.17±4.9	15.70±5.2	9.12±5.1	16.46±4.4	22.43±4.8	16.81±4.5	12.20±3.9
RH	68.75±9.5	70.58±11.1	70.06±8.9	70.73±10.0	70.18±10.6	69.37±11.5	72.26±9.7	71.43±9.9
THI	58.42±5.6	73.99±7.2	59.91±7.9	49.95±7.7	60.97±6.7	69.78±7.0	61.48±6.9	54.59±6.0

* T – ambient temperature (°C); RH – relative humidity; THI – temperature humidity index

Table 5. Correlations between the production traits and microclimate parameters accordingly to breed and breeding region

trait	Holstein						Simmental					
	DMY	DFC	DPC	DLC	DUC	SCC	DMY	DFC	DPC	DLC	DUC	SCC
Eastern region												
T	-	-	-	-	0.197	0.013	-0.011	-	-	0.0126	0.204	-
	0.032	0.105	0.134	0.019			0.123	0.124				0.021
RH	0.044	0.040	0.013	0.017	0.017	-	-0.014	0.010	0.016	-0.024	-	0.034
						0.222					0.042	
THI	-	-	-	-	0.195	0.013	-0.011	-	-	0.014	0.205	-
	0.033	0.106	0.133	0.016			0.134	0.125				0.022
Central region												
T	-	-	-	-	0.225	-	0.0034	-	-	0.018	0.226	-
	0.012	0.127	0.116	0.016		0.004		0.133	0.129			0.025
RH	-	0.039	0.038	-	-	0.020	-0.019	0.022	0.026	-0.025	-	0.021
	0.039			0.017	0.013						0.032	
THI	-	-	-	-	0.223	-	0.003	-	-	0.018	0.225	-
	0.012	0.136	0.115	0.016		0.004		0.133	0.128			0.025
Mediterranean region												
T	-	-	-	0.005	0.116	0.003	0.0066	-	-	0.005	0.170	-
	0.094	0.051	0.073					0.085	0.112			0.014
RH	-	-	0.018	0.002	-	0.009	-0.017	-	0.057	0.020	0.101	-
	0.065	0.016			0.083			0.001				0.008
THI	-	-	-	0.007	0.112	0.001	0.066	-	-	0.007	0.177	-
	0.094	0.053	0.072					0.084	0.106			0.015

* DMY – daily milk yield (kg); DFC – daily fat content (%); DPC – daily protein content (%); DLC – daily lactose content (%); DUC – daily urea content (mg/ml); SCC – log transformed somatic cell count; T – ambient temperature (°C); RH – relative humidity; THI – temperature humidity index; all correlation coefficients were statistically highly significant ($p < 0.001$)

The correlations between the production traits of dairy cows (daily milk yield, daily fat, protein lactose and urea content and somatic cell count) and the microclimate parameters (ambient temperature, relative humidity and temperature-humidity index – THI) in the barns accordingly to the breed and breeding region are presented in the Table 5. All determined correlation coefficients were statistically highly significant ($p < 0.001$). A negative effect of increased ambient temperature on daily milk yield (DMY) and daily fat, protein and lactose content (DFC, DPC and DLC) was determined in both breeds in all analysed regions. The most pronounced negative effect of increased ambient temperature of DMY in Holsteins was determined in Mediterranean region, while in Simmental breed the highest drop in daily milk production was observed in Central region. The negative effect of high relative humidity in the barns was observed in Holsteins reared in Central and Mediterranean region, as well as in Simmentals reared in Central region. The increase of temperature-humidity index resulted in decrease of daily milk yield, and high variability in daily compositions in both breeds in all analysed regions.

Discussion

Performed analysis indicate high variability of production traits due to cow's breed, parity as well as breeding region. Also, high variability of microclimate parameters in the barns due to season and breeding region was found. Furthermore, statistically highly significant ($p < 0.001$) correlations between the production traits and microclimate parameters were determined. Finally, the negative effect of inadequate microclimate on daily milk production was determined in both breeds in all breeding regions.

Accordingly, to Kadzere *et al.* (2002) the intensive genetic selection for high milk production resulted in changes in the thermoregulation physiology of dairy cattle. Larger frames and larger gastrointestinal tracts in high production animals enable them to digest more feed, but also creates more metabolic heat and reduces the animal's ability to regulate temperature heat stress environment meaning that increased milk yield, feed intake and metabolic heat the thermo-neutrality to lower temperatures. Furthermore, highly productive dairy cattle lose their ability to regulate body temperature at an air temperature of only 25 to 29°C. For example, Berman (2005) notified that increasing of daily production from 35 to 45 kg results in a higher sensitivity to thermal stress and reduces the threshold temperature for intermediate heat stress by 5°C. Gantner *et al.* (2011) pointed out that even in periods with lower temperatures when problems could be caused by high relative humidity, the heat stress condition may occur. Du Preez *et al.* (1990a) determined in dairy cows reared in South Africa, the decrease of milk yield at THI higher than 72 (22°C at 100% RH, 25°C at 50% RH, or 28°C at 20% RH). Casa and Ravelo

(2003) also determined significant decrease in milk production, in amount of 6% (9%) depending on the region, during the warmer months in Argentina. Bouraoui et al. (2002) reported decrease of 0.41 kg of milk / day for each point increase of THI above 69. The threshold value of THI depend on a many effects, for instance, lactation stage, parity, level of milk production, breed, breeding region, individual susceptibility to heat stress, etc. (Kadzere et al. 2002, Bohmanova 2006, Collier et al. 2006, Hansen 2013, Gantner et al. 2017). For example, Bouraoui et al. (2002) put the threshold on 65-69, Bernabucci et al. (2010) as well as Collier and Hall (2012) on 68, Du Preez et al. (1990a, b) on 72, while Bohmanova et al. (2007) depending on region defined threshold THI value 72 in Georgia, and 74 in Arizona. West (2003) determined a reduction in DMI by 0.85 kg with every 1°C rise in air temperature above a cow's thermoneutral zone, therefore this decrease in intake accounts approximately 36% of the decrease in milk production. Spiers et al. (2004) notified that milk yield decreases by 0.41 kg/cow/day for each THI unit increase of above 69, within a day after initiation of heat stress, feed intake decreased, while after 2 days of HS milk yield decreased. Gaafar et al. (2011) determined that increasing of THI in the winter season from 59.82 to 78.53 in the summer season, HS reduced total (305 days) and daily milk yield by 39.00%, 31.40% and 29.84%, relatively. According to Baumgard and Rhoads (2013), drop in milk production up to 50% in dairy animals might be due to reduced feed intake. Lambertz et al. (2014) pointed out that the difference in defined threshold values could be due to better adapted cows, farm management or housing.

Conclusion

Based on the conducted research, the negative effect of the increase of microclimate parameters on daily milk production in all cows regardless the breed and breeding region could be pointed out. Also, variability in daily production traits due to cow's breed, parity as well as breeding region as well as variability of microclimate parameters in the barns due to season and breeding region was found. Since genetic evaluation and selection of dairy cattle for heat resistance is only long-term method for heat stress managing, determined effect will be taken into account in the statistical model for estimation of genetic parameters and breeding values for heat resistance in dairy cattle.

Analiza proizvodnih karakteristika i mikroklimatskih parametara na farmama za proizvodnju mleka

Goran Vučković, Tina Bobić, Pero Mijić, Mirna Gavran, Klemen Potočnik, Vladan Bogdanović, Vesna Gantner

Rezime

Cilj istraživanja je bio određivanje varijabilnosti proizvodnih osobina (dnevni prinos i sastav mleka) i mikroklimatskih parametara (temperatura i vlažnost okoline) u objektima za držanje krava za proizvodnju mleka; kao i korelacija između analiziranih grupa osobina; 1.636.192 zapisa za grla simentalске rase i 1.275.713 zapisa test dana grla holštajn rase. Izvršene analize pokazuju veliku varijabilnost proizvodnih osobina zbog rase krava, pariteta kao i odgajivačkog regiona. Takođe je utvrđena velika varijabilnost mikroklimatskih parametara u objektima zbog sezone i odgajivačkog regiona. Pored toga, utvrđene su statistički vrlo značajne ($p < 0,001$) korelacije između proizvodnih svojstava i parametara mikroklimе. Konačno, negativan uticaj neadekvatne mikroklimе na svakodnevnu proizvodnju mleka utvrđen je kod obe rase u svim odgajivačkim regionima. Pošto je genetska procena i selekcija mlečnih goveda na otpornost na visoke temperature sredine samo dugoročna metoda za upravljanje toplotnim stresom, utvrđeni efekat biće uzet u obzir u statističkom modelu za procenu genetskih parametara i odgajivačkih vrednosti.

Ključne reči: proizvodne osobine, mlečne krave, parametri mikroklimе

References

- ALMEIDA G.L.P., PANDORFI H., GUSELINI C. (2011): Uso do Sistema de resfriamento adiabático evaporativo no conforto térmico de vacas da raça Girolando. *Revista Brasileira de Engenharia Agrícola e Ambiental* 15:754-760.
- BALFOUSSIA E., SKENDERI K., TSIRONI M., ANAGNOSTOPOULOS A.K., PARTHIMOS N., VOUGAS K., PAPASSOTIRIOU I., TSANGARIS G.T., CHROUSOS G.P. (2014): A proteomic study of plasma protein changes under extreme physical stress. *Journal of Proteomics*, 98 (2014) 1-14.
- BATTISTI D.S., NAYLOR R.L. (2009): Historical warnings of future food insecurity with unprecedented seasonal heat. *Science*, 323, 240-244.
- BAUMGARD L.H., RHOADS R.P. (2013). Effects of heat stress on postabsorptive metabolism and energetics. *Annual Review of Animal Biosciences*, 1: 311-337.
- BERNABUCCI U., LACETERA N., BAUMGARD L.H., RHOADS R.P., RONCHI B., NARDONE A. (2010): Metabolic and hormonal acclimation to heat stress in domestic ruminants. *Animal*, 4, 1167-1183.
- BOHMANOVA J. (2006): Studies on genetics of heat stress in US Holsteins. PhD thesis. Athens: University of Georgia.

- BOHMANOVA J., MISZTAL I., COLE J.B. (2007): Temperature-humidity indices as indicators of milk production losses due to heat stress. *Journal of Dairy Science*, 90, 1947-1956.
- BOURAOU R., LAHMAR M., MAJDOUB A., DJEMALI M., BELYEA R. (2002): The relationship of temperature humidity-index with milk production of dairy cows in a Mediterranean climate. *Animal Research*, 51, 479-491.
- BOURAOU R., LAHMAR M., MAJDOUB A., DJEMALI M., BELYEA R. (2002): The relationship of temperature-humidity index with milk production of dairy cows in a Mediterranean climate. *Animal Research*, 51(6): 479-491.
- CASA A.C., RAVELO A.C. (2003): Assessing temperature and humidity conditions for dairy cattle in Cordoba, Argentina. *International Journal of Biometeorology*, 48, 6-9.
- COLLIER R.J., DAHL G.E., VAN BAALE M.J. (2006): Major advances associated with environmental effects on dairy cattle. *Journal of Dairy Science*, 89, 1244-1253.
- COLLIER R.J., HALL L.W. (2012): Quantifying heat stress and its impact on metabolism and performance. Tucson, Arizona: Department of Animal Sciences, University of Arizona.
- CORREA-CALDERON A., ARMSTRONG D., RAY D., DE NISE S., ENNS M., HOWISON C. (2004): Thermoregulatory responses of Holstein and Brown Swiss heat-stressed dairy cows to two different cooling systems. *International Journal of Biometeorology*, 48, 142-148.
- DAS R., SAILO L., VERMA N., BHARTI P., SAIKIA J., IMTIWATI, KUMAR R. (2016): Impact of heat stress on health and performance of dairy animals: A review. *Veterinary World*, 9(3): 260-268.
- DU PREEZ J.H., GIESECKE W.H., HATTINGH P.J. (1990A): Heat stress in dairy cattle and other livestock under Southern African conditions. I. Temperature-humidity index mean values during the four main seasons. *Onderstepoort Journal of Veterinary Research*, 57, 77-86.
- DU PREEZ J.H., HATTING P.J., GIESECKE W.H., EISENBERG B.E. (1990b): Heat stress in dairy cattle and other livestock under Southern African conditions. III. Monthly temperature-humidity index mean values and their significance in the performance of dairy cattle. *Onderstepoort Journal of Veterinary Research*, 57, 243-248.
- DUNN R.J.H., MEAD N.E., WILLETT K.M., PARKER D.E. (2014): Analysis of heat stress in UK dairy cattle and impact on milk yields. *Environmental Research Letters* 9, 064006.
- GAAAFAR H.M.A., GENDY M.E., BASSIOUNI M.I., SHAMIAH S.M., HALAWA A.A., HAMD M.A. (2011): Effect of heat stress on performance of dairy Friesian cow's milk production and composition. *Researcher*, 3(5): 85-93.
- GANTNER V., BOBIĆ T., GANTNER R., GREGIĆ M., KUTEROVAC K., NOVAKOVIĆ J., POTOČNIK K. (2017): Differences in response to heat stress due to production level and breed of dairy cows. *International Journal of Biometeorology* 61, 9, 1675- 1685.

- GANTNER V., MIJIĆ P., KUTEROVAC K., SOLIĆ D., GANTNER R. (2011). Temperature-humidity index values and their significance on the daily production of dairy cattle. *Mljekarstvo*, 61(1), 56-63.
- GAULY M., BOLLWEIN H., BREVES G., BRÜGEMANN K., DÄNICKE S., DAS, DEMELER J.G., HANSEN H., ISSELSTEIN J., KÖNIG S., LOHÖLTER M., MARTINSOHN M., MEYER U., POTTHOFF M., SANKER C., SCHRÖDER B., WRAGE N., MEIBAUM B., VON SAMSON-HIMMELSTJERNA G., STINSHOFF H., WRENZYCKI C. (2013): Future consequences and challenges for dairy cow production systems arising from climate change in Central Europe—A review. *Animal*, 7, 843-859.
- HAMMAMI H., BORMANN J., M'HAMDI N., MONTALDO H.H., GENGLER N. (2013): Evaluation of heat stress effects on production traits and somatic cell score of Holsteins in a temperate environment. *Journal of Dairy Science*, 96, 1844-1855.
- HANSEN P.J. (2013): Genetic control of heat stress in dairy cattle. In: *Proceedings 49th Florida Dairy Production Conference*, Gainesville, April 10, 2013.
- INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE – IPCC (2007): *Climate change 2007: The physical science basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge: Cambridge University Press.
- IPCC. CLIMATE CHANGE (2007): *Mitigation. Contribution of Working Group III to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change*. B. Metz, O.R. Davidson, P.R. Bosch, R. Dave, Meyer, L.A. eds. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA.
- KADZERE C.T., MURPHY M.R., SILANIKOVE N., MALTZ E. (2002): Heat stress in lactating dairy cows: a review. *Livestock Production Science*, 77, 59-91.
- KIBLER H.H. (1964): *Environmental physiology and shelter engineering. LXVII. Thermal effects of various temperature-humidity combinations on Holstein cattle as measured by eight physiological responses*. Research Bulletin, University of Missouri, College of Agriculture, Agricultural Experiment Station, 862.
- LAMBERTZ C., SANKER C., GAULY M. (2014): Climatic effects on milk production traits and somatic cell score in lactating Holstein-Friesian cows in different housing systems. *American Dairy Science Association. Journal of Dairy Science* 97 (1), 319-329.
- MIN L., ZHENG N., ZHAO S., CHENG J., YANG Y., ZHANG Y., YANG H., WANG J. (2016): Long-term heat stress induces the inflammatory response in dairy cows revealed by plasma proteome analysis. *Biochemical and Biophysical Research Communications*, 4, 471 (2): 296-302.
- NRC. (2007): *Nutrient Requirements of Small Ruminants, Sheep, Goats, Cervids, and New World Camelids*. National Academy Press, Washington, DC.
- RAVAGNOLO O., MISZTAL I., HOOGENBOOM G. (2000): Genetic component of heat stress in dairy cattle, development of heat index function. *Journal of Dairy Science*, 83, 2120-2125.

- REICZIGEL J., SOLYMOSI N., KÖNYVES L., MARÓTI-AGÓTS A., KERN A., BARTYIK J. (2009): Examination of heat stress caused milk production loss by the use of temperature-humidity indices. *Magy Allatorv*, 131: 137-144.
- SANTOS DALTRO D., FISCHER V., MÜNCHEN ALFONZO E.P., CALDERARO DALCIN V., TEMPEL STUMPF M., KOLLING G.J., MARCOS VINÍCIUS GUALBERTO BARBOSA DA SILVA, MCMANUS C. (2017): Infrared thermography as a method for evaluating the heat tolerance in dairy cows. *Revista Brasileira de Zootecnia / Brazilian Journal of Animal Science*, 46(5), 374-383.
- SAS Institute Inc. (2000). *SAS User's Guide*, version 8.2 ed. Cary, NC: SAS Institute Inc.
- SEGNALENI M., BERNABUCCI U., VITALI A., NARDONE A., LACETERA N. (2013): Temperature humidity index scenarios in the Mediterranean basin. *International Journal of Biometeorology*, 57, 451-458.
- SMITH D.L., SMITH T., RUDE B.J., WARD S.H. (2013): Short communication: Comparison of the effects of heat stress on milk and component yields and somatic cell score in Holstein and Jersey cows. *Journal of Dairy Science*, 96, 3028-3033.
- SPIERS D.E., SPAIN J.N., SAMPSON J.D., RHOADS R.P. (2004): Use of physiological parameters to predict milk yield and feed intake in heat-stressed dairy cows. *Journal of Thermal Biology*, 29(7-8): 759-764.
- ST-PIERRE N.R., COBANOV B., SCHNITKEY G. (2003): Economic losses from heat stress by US livestock industries. *Journal of Dairy Science*, 86, 52-77.
- UPADHYAY R.C., ASHUTOSH, SINGH S.V. (2009): Impact of climate change on reproductive functions of cattle and buffalo. In: Aggarwal, P.K., editor. *Global Climate Change and Indian Agriculture*. ICAR, New Delhi. 107-110.
- VASCONCELOS J. L. M., DEMETRIO D. G. B. (2011): Manejo reprodutivo de vacas sob estresse calórico. *Revista Brasileira de Zootecnia* 40:396-401.
- VITALI A., SAGNALINI M., BERTOCCHI L., BERNABUCCI U., NARDONE A., LACETERA N. (2009): Seasonal pattern of mortality and relationships between mortality and temperature humidity index in dairy cows. *Journal of Dairy Science*, 92, 3781-3790.
- WEST J.W. (2003): Effects of heat-stress on production in dairy cattle. *Journal of Dairy Science*, 86(6): 2131-2144.
- WEST J.W., HILL G.M., FERNANDEZ J.M., MANDEBVU P., MULLINIX B.G. (1999): Effect of dietary fiber on intake, milk yield, and digestion by lactating dairy cows during cool or hot, humid weather. *Journal of Dairy Science*, 82, 2455-2465.
- WHELOCK J.B., RHOADS R.P., VAN BAALE M.J., SANDERS S.R., BAUMGARD L.H. (2010): Effect of heat stress on energetic metabolism in lactating Holstein cows. *Journal of Dairy Science*, 93(2): 644-655.

Received 4 November 2019; accepted for publication 28 November 2019

Izvorni znanstveni rad broj 2 u obliku i izvornom jeziku na kojem je objavljen u znanstvenom časopisu

Naslova rada: **DEVELOPMENT AND SELECTION OF OPTIMAL STATISTICAL MODELS
TO EVALUATE THE EFFECT OF MICROCLIMATE PARAMETERS ON THE
VARIABILITY OF PRODUCTION TRAITS IN DAIRY COWS**

Autori: ***Goran Vučković, Mirna Gavran, Maja Gregić, Pero Mijić, Ranko Gantner, Muhamed
Brka, Vesna Gantner***

Tip rada: Izvorno znanstveni rad

Časopis: ***Radovi Poljoprivredno-prehrambenog fakulteta Univerziteta u Sarajevu***

Works of the Faculty of Agriculture and Food Sciences, University of Sarajevo

Kategorija: A2

Impakt faktor: -

Kvartil: -

Primljen na recenziju: 04. studeni 2019.

Prihvaćen za objavljivanje: 28. studeni 2019.

Status: Objavljen

Volumen: 69

Svezak: 3

Stranice: 77 – 88

WOS broj: -

DEVELOPMENT AND SELECTION OF OPTIMAL STATISTICAL MODELS TO EVALUATE THE EFFECT OF MICROCLIMATE PARAMETERS ON THE VARIABILITY OF PRODUCTION TRAITS IN DAIRY COWS

Goran Vučković¹, Mirna Gavran², Maja Gregić², Pero Mijić², Ranko Gantner²,
Muhammed Brka³, Vesna Gantner²

Original scientific paper

Summary

Currently we are living and producing in the world characterized by a climate change. For agriculture and livestock production, this change means, in most cases, deterioration of the environmental effect in numerous regions globally and consequently significant effect on livestock production in the world. Modern livestock production, most frequently implies high production per animal, meaning high milk production per cow in terms of dairy cattle production. The increase of production makes cows more susceptible to heat stress, meaning that heat stress will become an acute problem regardless of climate changes, that will only further emphasize this problem. High-producing dairy cows lose the ability to regulate their body temperature when the ambient temperatures reach 25-29°C. Furthermore, the intensive genetic selection for high milk production resulted in changed thermoregulation physiology meaning that the high-producing cows have larger frames and consequently larger gastrointestinal tracts that enable them to digest more feed. This creates more metabolic heat and reduces the ability of cows to regulate normal temperature at heat stress conditions. Finally, by increase of milk yield, feed intake and metabolic heat, the thermoneutrality of animal shifts to lower temperatures. Accordingly, to many researches, heat stress environment induces reduction in dry matter intake, milk production and reproductive performances. Also, heat stress conditions affect milk composition, somatic cell counts (SCC) and mastitis frequencies.

Since Pannonian region is characterized by the high prevalence of heat stress days, mostly during the summer season, the aim of this paper was to develop and select optimal models for evaluation of the effect of microclimate parameters on the variability of production traits in dairy cows.

Key words: *statistical modelling, microclimate, production traits, dairy cattle*

¹ Rinderunion Baden-Württemberg, Herbertingen, Germany

² Josip Juraj Strossmayer University of Osijek, Faculty of Agrobiotechnical Sciences Osijek, Department for animal production and biotechnology Osijek, Vladimira Preloga 1, 31000 Osijek, Croatia

³ University of Sarajevo, Faculty of Agriculture and Food Sciences, Department for Animal Breeding, Zmaja od Bosne 8, 71000 Sarajevo, Bosnia and Herzegovina

Correspondence: Vesna Gantner, Vladimira Preloga 1, vgantner@fazos.hr

INTRODUCTION

Today's cattle milk production is characterized by high cattle productivity requirements and increasingly pronounced unfavourable (micro)climate conditions. Accordingly, to the forecasts of the IPCC (2007) changes in climate will significantly affect agricultural, and especially animal production worldwide. Accordingly, Battisti and Naylor (2009) forecasted that by year 2050, most of the world will be exposed to median temperatures in the summer that will be higher than the highest recorded temperatures. In continuation, Reiczigel *et al.* (2009) in Hungary, as well as Dunn *et al.* (2014) in UK indicated an increase of heat stress days per year. Stated implies that the heat stress of high productive dairy cows will cause growing concern in dairy production in Europe (Gauly *et al.*, 2013). In the light of the anticipated changes, Segnalini *et al.* (2013) pointed out the necessity of adequate adaptation strategies in order to decrease negative effects of climate change on domestic animals. Since, high production makes cows more susceptible to heat stress, heat stress will become, and already is, a problem in intensive dairy breeding systems regardless the climate changes (Hansen, 2013). Bohmanova (2006) and Collier *et al.* (2006) pointed out that the level of milk production significantly alters the animal response to heat stress making high production animals more sensitive to heat stress than low production ones. Furthermore, Kadzere *et al.* (2002) emphasized that the intensive genetic selection for high milk production resulted in changes in the thermoregulation physiology of dairy cattle. Larger frames and larger gastrointestinal tracts in high production animals enable them to digest more feed, but also creates more metabolic heat and reduces the animal's ability to regulate temperature at heat stress environment meaning that increased milk yield, feed intake and metabolic heat shifts the thermoneutrality to lower temperatures. Accordingly, to many studies, heat stress conditions in dairy cattle reduce dry matter intake, milk production (West *et al.*, 1999; Casa and Ravelo, 2003; Gantner *et al.*, 2011) as well as reproductive performances (Bohmanova *et al.*, 2007; Ravagnolo *et al.*, 2000). Furthermore, heat stress alters the milk composition, somatic cell counts (SCC) and prevalence of mastitis (Bouraoui *et al.*, 2002; Collier *et al.*, 2012; Correa-Calderon *et al.*, 2004; Gantner *et al.*, 2011, 2017; Ravagnolo *et al.*, 2000; St-Pierre *et al.*, 2003; West 2003; Hammami *et al.*, 2013; Smith *et al.*, 2013). Finally, heat stress induces considerable profit loss (St-Pierre *et al.*, 2003). The most common measure of heat stress when dairy cattle are analysed is temperature-humidity index (THI). Temperature-humidity index is a measure that includes ambient temperature and relative humidity (Kibler, 1964). The THI threshold value at which heat stress affects milk production and feed intake vary, depending on study, from 68 to 72 (Du Preez *et al.*, 1990a, b; Bouraoui *et al.*, 2002; Bernabucci *et al.*, 2010; Gantner *et al.*, 2011; Collier and Hall, 2012). Finally, Vitali *et al.* (2009) emphasised the increased risk of animals' death in the environment characterised by THI = 80. Furthermore, the acclimatization to long-term stress results in proteomic changes indicated by expression of proteins related to inflammation (Balfoussia *et al.*, 2014). Min *et al.* (2016) concluded that long-term moderate heat stress may lead to

an inflammatory response in dairy cows with significantly pro-inflammatory factors. Those changes lead to increase of operating expenses of dairy farm that is to decrease of profitability of the dairy business.

Since Pannonian region is characterized by the high prevalence of heat stress days, mostly during the summer season, the aim of this paper was to develop and select optimal models for evaluation of the effect of microclimate parameters on the variability of production traits in dairy cows. Application of optimal statistical model in routine genetic evaluation and selection of more resistant animals will certainly contribute to realization of profitable and sustainable dairy farm.

MATERIALS AND METHODS

Test-day records of Holstein and dairy Simmental cows collected in the period from January 2005 to December 2013 provided by the Croatian Agricultural Agency were used for the statistical analysis. Test-day records were collected during the regular milk recording performed monthly in accordance to the alternative milk recording method (AT4 / BT4) on dairy cattle farms in Croatia. At each recording, measuring and sampling of milk were performed during the evening or morning milkings. Additionally, at each milk recording, ambient temperature and relative humidity were recorded. Based on measured ambient parameters, daily values of temperature-humidity index (THI) was calculated using the Kibler equation (1964):

$$THI = 1.8 * Ta - (1 - RH) * (Ta - 14.3) + 32$$

Where Ta is average temperature in degrees Celsius and RH is relative humidity as a fraction of the unit.

Test-day records with lactation stage in (< 5 days and > 500 days), age at first calving in (< 21 and > 36 months), missing parity, missing breed, and missing or nonsense daily milk traits (ICAR standards, 2017), Ta and RH value were deleted from the dataset. After logical control dataset consisted of 1,636,192 test-day records from 117,659 Simmentals (10,599 farms) and 1,275,713 test-day records from 90,159 Holsteins (6,701 farms).

Accordingly, to the parity, cows were divided into four classes: I., II., III., and IV. (animals in fourth and higher lactations). Furthermore, accordingly to location of farm, test day records were divided into three breeding regions: Eastern, Central, and Mediterranean. While, in accordance to the recording date, test day records were divided into 108 classes: 1/2005 to 12/2013. Basic statistical parameters of daily milk traits and microclimate parameters is presented in Table 1 and Table 2.

Goran Vučković, Mirna Gavran, Maja Gregić, Pero Mijić, Ranko Gantner, Muhamed Brka, Vesna Gantner

Tab. 1. Basic statistical parameters of analysed traits (daily milk traits and microclimate parameters, n = 1,275,713) for Holstein breed

Trait	mean	SD	CV	Min	Max
DMY	21.16	8.85	41.80	3.00	87.60
DFY	4.17	0.95	22.76	1.50	9.00
DPC	3.41	0.47	13.83	1.04	6.99
DLC	4.45	0.23	3.13	3.00	5.65
UREA	22.06	9.89	44.85	0.50	60.00
logSCC	16.88	2.12	12.58	12.29	22.25
T	15.07	7.97	52.89	-9.00	40.00
RH	68.66	12.39	18.04	30.00	99.00
THI	58.71	11.86	20.20	17.66	101.21

* DMY – daily milk yield (kg); DFC – daily fat content (%); DPC – daily protein content (%); DLC – daily lactose content (%); UREA – daily lactose content (mg/ml); logSCC – log transformed somatic cell count; T – ambient temperature (°C); RH – relative humidity; THI – temperature humidity index

Tab. 2. Basic statistical parameters of analysed traits (daily milk traits and microclimate parameters, n = 1,636,192) for Simmental breed

Trait	mean	SD	CV	Min	Max
DMY	15.56	8.85	38.17	3.00	94.00
DFY	4.17	0.95	21.46	1.50	9.00
DPC	3.46	0.47	13.38	1.12	7.00
DLC	4.48	0.23	5.12	3.00	5.83
UREA	19.90	9.89	53.56	0.50	60.00
logSCC	16.58	2.12	12.93	12.29	22.25
T	15.73	7.97	47.47	-9.00	40.00
RH	70.82	12.39	14.87	30.00	99.00
THI	59.77	11.86	20.20	16.03	101.21

* DMY – daily milk yield (kg); DFC – daily fat content (%); DPC – daily protein content (%); DLC – daily lactose content (%); UREA – daily lactose content (mg/ml); logSCC – log transformed somatic cell count; T – ambient temperature (°C); RH – relative humidity; THI – temperature humidity index

For the evaluation of the effect of microclimate parameters (T, RH, and THI) on the variability of production traits (daily milk yield and contents) in dairy cows several statistical models were developed and tested. Based on evaluation parameters (R^2 , CV and Root MSE of model) two models were selected as optimal for further analysis.

The relationship between daily milk traits (yields and contents) and microclimate parameters (T, RH, and THI) was analysed using PROC GLM procedure in SAS (SAS Institute Inc., 2000) in accordance to following model 1:

$$y_{ijklm} = \mu + b_1(d_i/305) + b_2(d_i/305)^2 + b_3 \ln(305/d_i) + b_4 \ln^2(305/d_i) + S_j + A_k + R_l + x_{ijklm} + e_{ijklm}$$

Furthermore, the variation in daily milk traits (yields and contents) due to heat stress was tested by least square analyses of variance for set THI values (68, 72) using PROC GLM / SAS accordingly to following model 2:

$$y_{ijklm} = \mu + b_1(d_i/305) + b_2(d_i/305)^2 + b_3 \ln(305/d_i) + b_4 \ln^2(305/d_i) + S_j + A_k + R_l + T_m + x_{ijklm} + e_{ijklm}$$

where y_{ijklm} = estimated daily milk trait;

μ = intercept;

b_1, b_2, b_3, b_4 = regression coefficients;

d_i = days in milk ($i = 5$ to 500 day);

S_j = fixed effect of recording season class j ($j = 1/2005$ to $12/2012$);

A_k = fixed effect of age at calving class k ($k = 21$ to 36 month);

R_l = fixed effect of breeding region l ($l = \text{Eastern, Central, and Mediterranean Croatia}$);

x_{ijklm} = fixed effect of microclimate parameter as linear regression – model 1;

T_m = fixed effect of THI class ($m = 0$ (normal condition – values under the given threshold) or $m = 1$ (heat stress condition – values equal and above the given threshold)) – model 2;

e_{ijklm} = residual.

The significance of the differences between the THI classes in model 2 was tested by t-test. The statistical analysis was performed separately for each breed (Holstein, and Simmental).

RESULTS AND DISCUSSION

The coefficients of linear regression between analysed daily milk traits (daily milk yield, daily fat, protein, lactose and urea content, and somatic cell count) and microclimate parameters (ambient temperature, relative humidity and temperature-humidity index – THI) in accordance to breed is presented in the Table 3. A statistically significant ($p < 0.05$) decrease in daily milk yield (DMY) and daily fat and protein content (DFC, and DPC) caused by the increase in ambient temperature (T) and THI was observed in both breeds. Furthermore, by increase of relative humidity (RH), in Holstein cows DMY, DFC and DPC increased, while in Simmental breed those traits decreased. The daily lactose content (DLC) showed very low variability due to variations in microclimate conditions. While the daily urea content (UREA), and somatic cell count (logSCC) increased in terms of increased daily T, RH and THI in both analysed breeds.

Tab. 3. The coefficients of linear regression between daily milk traits and microclimate parameters accordingly to breed

Trait	Holstein			Simmental		
	T	RH	THI	T	RH	THI
DMY	-0.0463	0.0023	-0.0315	-0.0483	-0.0068	-0.0320
DFC	-0.0004	0.0012	-0.0004	-0.0006	-0.0010	-0.0004
DPC	-0.0018	0.0003	-0.0011	-0.0011	-0.0001	-0.0007
DLC	-0.0005	0.0000	-0.0003	0.0001	0.0000	0.0001
UREA	0.0158	-0.0047	0.0102	0.0257	0.0050	0.0175
logSCC	0.0045	0.0019	0.0032	0.0003	0.0028	0.0002

* DMY – daily milk yield (kg); DFC – daily fat content (%); DPC – daily protein content (%); DLC – daily lactose content (%); UREA – daily lactose content (mg/ml); logSCC – log transformed somatic cell count; T – ambient temperature (°C); RH – relative humidity; THI – temperature humidity index; all coefficients of linear regression were statistically highly significant ($p < 0.05$)

Statistically significant ($p < 0.05$) difference in all analysed daily milk traits, with exception of log SCC, due to heat stress condition at $\text{THI} = 68$ was determined in both breeds (Table 4). Higher difference between the daily milk yield produced in normal condition comparing to heat stress condition in amount of 314 g of milk / day was determined in Holstein cows, while lower difference in amount of 296 g of milk / day was determined in Simmental cows. Furthermore, the amount of variation in daily fat/protein/lactose content and logSCC due to heat stress was similar in all cows. Daily urea content showed significant ($p < 0.05$) increase in all cows in terms of heat stress.

Tab. 4. LSmeans of daily milk traits regarding the heat stress (HS-0/HS-1) when threshold $\text{THI} = 68$ accordingly to breed

Trait	Holstein		Simmental	
	HS-0	HS-1	HS-0	HS-1
DMY	19.908 ^a	19.594 ^b	13.867 ^A	13.571 ^B
DFY	4.322 ^a	4.333 ^b	4.076 ^a	4.070 ^b
DPC	3.547 ^a	3.542 ^b	3.374 ^a	3.364 ^b
DLC	4.465 ^a	4.459 ^b	4.465 ^a	4.463 ^b
UREA	20.196 ^a	20.578 ^b	20.622 ^a	21.070 ^b
logSCC	15.947 ^a	15.955 ^a	16.306 ^a	16.300 ^a

*DMY – daily milk yield (kg); DFC – daily fat content (%); DPC – daily protein content (%); DLC – daily lactose content (%); UREA – daily lactose content (mg/ml); logSCC – log transformed somatic cell count; LSmeans within the same row and mastitis risk class marked with different letters (a, b) differ statistically significant ($p < 0.05$); HS-0: normal condition, HS-1: heat stress condition

The results of analyses of variance of daily milk traits regarding the heat stress conditions (HS-0/HS-1) when threshold $\text{THI} = 72$ according to breed is presented in the

Table 5. Similar trends as at lower THI value (68) was determined for all analysed traits in both breed while the determined differences were higher comparing to lower THI value. The daily milk yield, in Holstein breed, drop almost 0.5 kg per day due to increased heat stress, while Simmental cows exposed to heat stress at THI = 72 produced around 0.3 kg of milk per day less comparing to ones in normal conditions.

Tab. 5. LSmeans of daily milk traits regarding the heat stress (HS-0/HS-1) when threshold THI = 72 accordingly to breed

Trait	Holstein		Simmental	
	HS-0	HS-1	HS-0	HS-1
DMY	19.908 ^a	19.424 ^b	13.841 ^A	13.543 ^B
DFY	4.321 ^a	4.344 ^b	4.076 ^a	4.065 ^b
DPC	3.548 ^a	3.538 ^b	3.373 ^a	3.363 ^b
DLC	4.465 ^a	4.457 ^b	4.465 ^a	4.462 ^b
UREA	20.231 ^a	20.541 ^b	20.641 ^a	21.258 ^b
logSCC	15.946 ^a	15.967 ^a	16.305 ^a	16.301 ^a

*DMY – daily milk yield (kg); DFC – daily fat content (%); DPC – daily protein content (%); DLC – daily lactose content (%); UREA – daily lactose content (mg/ml); logSCC – log transformed somatic cell count; LSmeans within the same row and mastitis risk class marked with different letters (a, b) differ statistically significant ($p < 0.05$); HS-0: normal condition, HS-1: heat stress condition

The negative effect of increase of temperature and temperature humidity index on daily milk production was determined in all cows. The increase of ambient temperature for one degree, in both breeds, induces decrease of around 50 g of milk / day (with slightly higher decrease determined in Simmentals (-0.0483, vs -0.0463). Furthermore, the negative effect of high relative humidity in the barns was pronounced in Simmental than Holstein cows. Accordingly, to many studies, highly productive dairy cows lose their ability to regulate body temperature at an air temperature of 25 to 29°C. For instance, the increase in daily production from 35 to 45 kg results in a higher sensitivity to thermal stress and reduces the threshold temperature for intermediate heat stress by 5°C (Berman, 2005). Furthermore, the heat stress condition may occur even in periods with lower temperatures when problems could be caused by high relative humidity (Gantner *et al.*, 2011). The negative effect of high humidity on milk production was also confirmed by Bianca (1965). She determined that at 29°C and 40% RH milk yield of Holstein, Jersey and Brown Swiss cows produced 97, 93, and 98% of normal production, but when relative humidity increased to 90% milk production dropped to 69, 75, and 83% of normal level. Du Preez *et al.* (1990a) in dairy cows bred in South Africa, determined the decrease of milk yield at THI higher than 72 meaning at 22°C at 100% RH, 25°C at 50% RH, or 28°C at 20% RH. Significant decrease in milk production, in amount of 6% (9%) depending on the region, during the warmer months in Argentina was also determined by Casa and Ravelo (2003). Similarly, to results of this research, Bouraoui *et al.* (2002) reported decrease of 0.41 kg of milk / day for

each point increase of THI above 69. Accordingly, to many researches (Kadzere *et al.*, 2002; Bohmanova, 2006; Collier *et al.*, 2006; Hansen, 2013; Gantner *et al.*, 2017), the threshold value of THI depend on a many effect, for instance, lactation stage, parity, level of milk production, breed, breeding region, individual susceptibility to heat stress, etc. For instance, Bouraoui *et al.* (2002) put the threshold on 65-69, Bernabucci *et al.* (2010) as well as Collier and Hall (2012) on 68, Du Preez *et al.* (1990a, b) on 72, while Bohmanova *et al.* (2007) depending on region defined threshold THI value 72 in Georgia, and 74 in Arizona. Lambertz *et al.* (2014) pointed out that the difference in defined threshold values could be due to better adapted cows, farm management or housing.

CONCLUSIONS

In this research, application of selected optimal models for evaluation showed statistically highly significant ($p < 0.05$) effect of microclimate parameters (ambient temperature, T; relative humidity, RH and temperature-humidity index, THI) on the variability of analysed production traits in dairy cows (daily milk yield, daily fat, protein, lactose and urea content, and somatic cell count). Determined decrease in daily milk yield and daily fat and protein content caused by the increase in T and THI in both breeds showed to be statistically significant ($p < 0.05$). Furthermore, the daily urea content, and somatic cell count increased in terms of increased daily T, RH and THI in both analysed breeds. The daily lactose content showed very low variability due to variations in microclimate conditions.

The analyses of variance of daily milk traits regarding the heat stress conditions (normal or stressed: HS-0 / HS-1) at different threshold THI (68, and 72) showed statistically significant ($p < 0.05$) difference in all analysed daily milk traits, with exception of log SCC. Higher difference between the daily milk yield produced in normal condition comparing to heat stress condition was determined in Holstein cows, as well as at higher tested THI threshold value (72 vs. 68). Furthermore, the amount of variation in daily fat/protein/lactose content and logSCC due to heat stress was similar in all cows. Finally, daily urea content showed significant ($p < 0.05$) increase in all cows in heat stress environment with higher increase in Simmental breed and at more pronounced heat stress (higher THI threshold value, THI = 72).

Based on the obtained results, it could be emphasised that selected optimal statistical model could be used as the basis for further research aiming estimations of genetic parameters as well as breeding value for heat resistance.

REFERENCES

- Battisti, D. S., Naylor, R. L. (2009): Historical warnings of future food insecurity with unprecedented seasonal heat. *Science*, 323, 240-244.
- Bernabucci, U., Lacetera, N., Baumgard, L.H., Rhoads, R.P., Ronchi, B., Nardone, A. (2010): Metabolic and hormonal acclimation to heat stress in domestic ruminants. *Animal*, 4, 1167-1183.
- Bohmanova, J. (2006): Studies on genetics of heat stress in US Holsteins. PhD thesis. Athens: University of Georgia.
- Bohmanova, J., Misztal, I., Cole, J. B. (2007): Temperature-humidity indices as indicators of milk production losses due to heat stress. *J Dairy Sci.*, 90, 1947-1956.
- Bouraoui, R., Lahmar, M., Majdoub, A., Djemali, M., Belyea, R. (2002): The relationship of temperature humidity-index with milk production of dairy cows in a Mediterranean climate. *Animal Research*, 51, 479-491.
- Casa, A. C., Ravelo, A. C. (2003): Assessing temperature and humidity conditions for dairy cattle in Cordoba, Argentina. *Int. J Biometeorol.*, 48, 6-9.
- Collier, R. J., Dahl, G. E., van Baale, M. J. (2006): Major advances associated with environmental effects on dairy cattle. *J Dairy Sci.*, 89, 1244-1253.
- Collier, R. J., Hall, L. W. (2012): Quantifying heat stress and its impact on metabolism and performance. Tucson, Arizona: Department of Animal Sciences, University of Arizona.
- Correa-Calderon, A., Armstrong, D., Ray, D., de Nise, S., Enns, M., Howison, C. (2004): Thermoregulatory responses of Holstein and Brown Swiss heat-stressed dairy cows to two different cooling systems. *Int. J Biometeorol.*, 48, 142-148.
- Dunn, R. J. H., Mead, N. E., Willett, K. M., Parker, D. E. (2014): Analysis of heat stress in UK dairy cattle and impact on milk yields. *Environmental Research Letters* 9, 064006.
- Du Preez, J. H., Giesecke, W. H., Hattingh, P. J. (1990a): Heat stress in dairy cattle and other livestock under Southern African conditions. I. Temperature-humidity index mean values during the four main seasons. *Onderstepoort Journal of Veterinary Research*, 57, 77-86.
- Du Preez, J. H., Hattingh, P. J., Giesecke, W. H., Eisenberg, B. E. (1990b): Heat stress in dairy cattle and other livestock under Southern African conditions. III. Monthly temperature-humidity index mean values and their significance in the performance of dairy cattle. *Onderstepoort Journal of Veterinary Research*, 57, 243-248.
- Gantner, V., Mijić, P., Kuterovac, K., Solić, D., Gantner, R. (2011): Temperature-humidity index values and their significance on the daily production of dairy cattle. *Mljekarstvo*, 61(1), 56- 63.
- Gantner, V., Bobić, T., Gantner, R., Gregić, M., Kuterovac, K., Novaković, J., Potočnik, K. (2017): Differences in response to heat stress due to production level and breed of dairy cows. *Int. J Biometeorol.*, 61, 9; 1675- 1685.

- Gauly, M., Bollwein, H., Breves, G., Brügemann, K., Dänicke, S., Das, Demeler, J. G., Hansen, H., Isselstein, J., König, S., Lohölter, M., Martinsohn, M., Meyer, U., Potthoff, M., Sanker, C., Schröder, B., Wrage, N., Meibaum, B., von Samson-Himmelstjerna, G., Stinshoff, H., Wrenzycki, C. (2013): Future consequences and challenges for dairy cow production systems arising from climate change in Central Europe—A review. *Animal*, 7, 843-859.
- Hammami, H., Bormann, J., M'hamdi, N., Montaldo, H. H., Gengler, N. (2013): Evaluation of heat stress effects on production traits and somatic cell score of Holsteins in a temperate environment. *J Dairy Sci.*, 96, 1844-1855.
- Hansen, P. J. (2013): Genetic control of heat stress in dairy cattle. In: Proceedings 49th Florida Dairy Production Conference, Gainesville, April 10, 2013.
- Intergovernmental Panel on Climate Change – IPCC (2007): Climate change 2007: The physical science basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge: Cambridge University Press.
- Kadzere, C. T., Murphy, M. R., Silanikove, N., Maltz, E. (2002): Heat stress in lactating dairy cows: a review. *Livestock Production Science*, 77, 59-91.
- Kibler, H. H. (1964): Environmental physiology and shelter engineering. LXVII. Thermal effects of various temperature-humidity combinations on Holstein cattle as measured by eight physiological responses. *Research Bulletin*, University of Missouri, College of Agriculture, Agricultural Experiment Station, 862.
- Lambertz, C., Sanker, C., Gauly, M. (2014): Climatic effects on milk production traits and somatic cell score in lactating Holstein-Friesian cows in different housing systems. *American Dairy Science Association. J Dairy Sci.*, 97 (1), 319-329.
- Min, L., Zheng, N., Zhao, S., Cheng, J., Yang, Y., Zhang, Y., Yang, H., Wang, J. (2016): Long-term heat stress induces the inflammatory response in dairy cows revealed by plasma proteome analysis, *Biochemical and Biophysical Research Communications*, 4, 471 (2): 296-302.
- Ravagnolo, O., Misztal, I., Hoogenboom, G. (2000): Genetic component of heat stress in dairy cattle, development of heat index function. *J Dairy Sci.*, 83, 2120-2125.
- Reiczigel, J., Solymosi, N., Könyves, L., Maróti-Agóts, A., Kern, A., Bartyik, J. (2009): Examination of heat stress caused milk production loss by the use of temperature-humidity indices. *Magy Allatorv*, 131: 137-144.
- SAS Institute Inc. (2000): SAS User's Guide, version 8.2 ed. Cary, NC: SAS Institute Inc.
- Segnalini, M., Bernabucci, U., Vitali, A., Nardone, A., Lacetera, N. (2013): Temperature humidity index scenarios in the Mediterranean basin. *Int. J. Biometeorol.*, 57, 451-458.
- Smith, D. L., Smith, T., Rude, B. J., Ward, S. H. (2013): Short communication: Comparison of the effects of heat stress on milk and component yields and somatic cell score in Holstein and Jersey cows. *J Dairy Sci.*, 96, 3028-3033.

Razvoj i odabir optimalnih statističkih modela za procjenu značajnosti utjecaja mikroklimatskih parametara ...
Development and selection of optimal statistical models to evaluate the effect of microclimate parameters ...

- St-Pierre, N. R., Cobanov, B., Schnitkey, G. (2003): Economic losses from heat stress by US livestock industries. *J Dairy Sci.*, 86, 52–77.
- Vitali, A., Sagnalini, M., Bertocchi, L., Bernabucci, U., Nardone, A., Lacetera, N. (2009): Seasonal pattern of mortality and relationships between mortality and temperature humidity index in dairy cows. *J Dairy Sci.*, 92, 3781-3790.
- West, J. W., Hill, G. M., Fernandez, J. M., Mandevu, P., Mullinix, B. G. (1999): Effect of dietary fiber on intake, milk yield, and digestion by lactating dairy cows during cool or hot, humid weather. *Journal of Dairy Science*, 82, 2455-2465.
- West, J. W. (2003): Effects of heat-stress on production in dairy cattle. *J Dairy Sci.*, 86, 2131-2144.

RAZVOJ I ODABIR OPTIMALNIH STATISTIČKIH MODELA ZA PROCJENU ZNAČAJNOSTI UTJECAJA MIKROKLIMATSKIH PARAMETARA NA VARIJABILNOST PROIZVODNIH SVOJSTAVA MLIJEČNIH KRAVA

Rezime

Trenutno živimo i proizvodimo u svijetu koji karakteriziraju klimatske promjene. Za poljoprivredu, a osobito stočarstvo, ove promjene u većini slučajeva znače pogoršanje okolišnih uvjeta u brojnim regijama, te na globalnoj razini i posljedično značajan utjecaj na stočarsku proizvodnju u cijelom svijetu. Suvremena stočarska proizvodnja najčešće podrazumijeva visoku produktivnost po životinji, što u mliječnom govedarstvu znači visoku proizvodnju mlijeka po kravi. Povećanje proizvodnje čini krave osjetljivijim na toplinski stres, što znači da će toplinski stres postati akutni problem bez obzira na klimatske promjene, koje će ovaj problem samo još više naglasiti. Visoko proizvodne mliječne krave gube sposobnost regulacije tjelesne temperature kada temperatura okoline dosegne 25-29°C. Nadalje, intenzivna genetska selekcija usmjerena na visoku proizvodnju mlijeka rezultirala je izmijenjenom fiziologijom termoregulacije što znači da krave koje proizvode više imaju veće okvire i posljedično veće gastrointestinalne sustave koji im omogućuju probavu više hrane. Navedeno stvara više metaboličke topline i smanjuje sposobnost krava da reguliraju normalnu temperaturu u uvjetima toplinskog stresa. Naposljetku, povećanjem količine mlijeka, unosa hrane te metaboličke topline, termoneutralnost životinja prelazi na niže temperature. Sukladno brojnim istraživanjima, toplinski stres u krava inducira smanjenje unosa suhe tvari, proizvodnju mlijeka i reproduktivne performanse. Također, uvjeti toplinskog stresa utječu na sastav mlijeka, broj somatskih stanica (SCC) i učestalost mastitisa. Budući da se Panonska regija odlikuje velikom prevalencijom dana sa toplinskim stresom, uglavnom tijekom ljetne sezone, cilj ovog rada bio je razviti i odabrati optimalne modele za procjenu utjecaja mikroklimatskih parametara na varijabilnost proizvodnih svojstava u mliječnim krava.

Ključne riječi: *statističko modeliranje, mikroklima, proizvodna svojstva, mliječna goveda*

Izvorni znanstveni rad broj 3 u obliku i izvornom jeziku na kojem je objavljen u znanstvenom časopisu

Naslova rada: ***Genetic parameters and breeding values for daily milk production of Holstein cows in terms of heat stress***

Autori: ***Goran Vučković, Tina Bobić, Pero Mijić, Mirna Gavran, Maja Gregić, Klemen Potočnik, Vladan Bogdanović, Vesna Gantner***

Tip rada: Izvorni znanstveni rad

Časopis: ***Mljekarstvo***

Kategorija: A1

Impakt faktor: 1,111

Kvartil: Q3

Primljen na recenziju: 16.12.2019.

Prihvaćen za objavljivanje: 20.04.2020.

Status: Objavljen

Volumen: 70

Svezak: 3

Stranice: 201 – 209

WOS broj: WOS:000542670900006

ORIGINAL SCIENTIFIC PAPER | UDK: 637.112 | doi: 10.15567/mljekarstvo.2020.0306
 RECEIVED: 16.12.2019. | ACCEPTED: 20.04.2020.

Genetic parameters and breeding values for daily milk production of Holstein cows in terms of heat stress

Goran Vučković¹, Tina Bobić^{2*}, Pero Mijić²,
 Mirna Gavran², Maja Gregić², Klemen Potočnik³,
 Vladan Bogdanović⁴, Vesna Gantner²

¹ Rinderunion Baden-Württemberg, Herberlingen, Ökofer Strasse 41, 88518 Herberlingen Germany

² University of J. J. Strossmayer in Osijek, Faculty of Agrobiotechnical Sciences Osijek, Department for animal production and biotechnology Osijek, Vladimira Preloga 1, 31000 Osijek, Croatia

³ University of Ljubljana, Biotechnical Faculty, Department of Animal Science, Groblje 3, Domžale, Slovenia

⁴ University of Belgrade, Faculty of Agriculture, Belgrade, Serbia

*Corresponding author: E-mail: tbobic@fazos.hr

Abstract

In order to estimate the variance components as well as the breeding value for daily milk production of Holstein cows in terms of heat stress defined as different THI threshold values (68, 70, and 72) 1,275,713 test-day records from 90,159 cows were used. Temperature-humidity index (THI) calculated from ambient temperature and relative humidity recorded in the barns on the milk recording day was used as the measure of heat stress. Daily milk production was analysed as a bivariate variable, in the normal conditions (under the set THI_{threshold} value), and in terms of heat stress (above the set THI_{threshold} value) using a model that accounted variances due to lactation stage, calving season, age at calving, breeding region, parity, permanent environment, interaction between year and year, and individual animal. The estimated high genetic correlations between the daily milk production in normal and heat stress conditions, as well as high correlations among the EBVs in normal and heat stress conditions, point out that Holstein cows with high productivity in normal condition will sustain an alike level of production even in terms of heat stress. These results indicate that the Holstein cows are very well acclimatized to the environmental conditions at dairy farms in Croatia. However, these findings should be taken with caution, given that measurements of microclimate parameters were conducted only once at a milk recording day, so the reliability of such measurements could be questionable. In conclusion, in order to realize a completely unambiguous conclusion, further studies that include multiple daily measurements of microclimatic parameters in the farms facilities are necessary.

Key words: daily milk production, heat stress, genetic parameters, Holstein

Introduction

Nowadays dairy cattle farms are faced with number of challenges that hinder their active participation in sustainable agricultural and rural development in the European countries. One of the recently more and more pronounced challenge is deterioration of environmental conditions highly correlated to the occurring changes of climate worldwide. These changes frequently lead to adverse (micro)climate on dairy cattle farms and to exposure of animals to heat stress. Heat stress conditions in dairy cows results in the reduction of dry matter intake, milk production and reproductive performances (West et al., 1999; Casa and Ravelo, 2003; Gantner et al., 2011; Bohmanova et al., 2007; Ravagnolo et al., 2000) as well as in changes in the milk composition, somatic cell counts (SCC) and mastitis prevalence (Bouraoui et al., 2002; Collier et al., 2012; Correa-Calderon et al., 2004; Gantner et al., 2011, 2017; Ravagnolo et al., 2000; St-Pierre et al., 2003; West, 2003; Hammami et al., 2013; Smith et al., 2013). All of the above mentioned finally results in considerable loss of dairy farm profit (St-Pierre et al., 2003). The threshold value, a point at which ambient temperatures exceed an animal's thermoneutral zone and animal's performance start to decrease depends on the breed, the breeding region, the lactation stage and parity, the production level, as well as on animal's individual capability to manage a stressful environment (Bohmanova et al., 2007; Gantner et al., 2011, 2017). For instance, previous researches reported the temperature-humidity index value - THI (index that combines ambient temperature and relative humidity) of environment in interval from 68 to 72 results in deterioration of productive and reproductive performances of dairy cattle (Ravagnolo et al., 2000; Bouraoui et al., 2002; Casa and Ravelo, 2003; Freitas et al., 2006; Bohmanova et al., 2007; Bernabucci et al., 2010; Collier and Hall, 2012; Hammami et al., 2013; Smith et al., 2013; Lambertz et al., 2014; Gantner et al., 2017). Furthermore, the intensive genetic selection of dairy cattle aiming to increase the milk production shifted the animal's thermoneutrality to lower temperatures (Kadzere et al., 2002; Bohmanova, 2006; Collier et al., 2006). Since

changes of climate became our reality, Segnalini et al. (2013) emphasized the necessity of developing strategies to alleviate their impact on livestock production especially in highly intensive production systems. The methods for reduction of the heat stress effect on dairy cows could be classified as short-term and long-term ones. Short-term methods imply farm management optimisation (feeding adjustment and farm's cooling systems), while long-term methods mean the selection of dairy cattle that are more resistant to heat stress environment. Due to the antagonism between heat tolerance and productivity, it is very challenging to implement the selection for heat resistance. It is inevitable to identify the heat tolerant phenotypes and to develop selection methods and statistical models that combine the entire knowledge to achieve the desired goals. Thermo-neutral threshold and drops in milk production were commonly used in many previous types of research. For example, Ravagnolo et al. (2000) used a broken line model to describe genetic components of the reaction to heat stress. Aguilar et al. (2009) used the test-day models that included a random regression on a function of the temperature-humidity index. Brügemann et al. (2011) and Carabano et al. (2014) used polynomials of a second or third order in order to describe the norm of reaction of milk production across the heat load scale. Furthermore, the determination of adequate criteria for the selection for each evaluation model is extremely important. In the broken line model, as selection criteria, both the thermotolerance threshold and the slope of animal's response could be used. On the other hand, in the case of higher-order polynomials used to describe the animal's reaction to heat stress, the slope of the individual polynomial curve under moderate or severe heat stress could be used as criteria for selection (Carabaño et al., 2014). In order to apply long-term mitigation method that is simple from a practical point of view this research aimed to estimate variance components as well as breeding value for daily milk production of Holstein cows in terms of heat stress defined as different THI threshold values (68, 70, and 72). Daily milk production was analysed as a bivariate variable in normal conditions (under the set $THI_{threshold}$ value) and in terms of heat stress (above the set $THI_{threshold}$ value).

Material and methods

Test-day records of Holstein cows collected during the regular milk recording in the period from January 2005 to December 2013 were provided by the Croatian Agricultural Agency. At each milk recording, measuring and sampling of milk were performed during the evening or morning milkings (AT4 or BT4 method). Furthermore, at each recording, ambient temperature and relative humidity in the barns were recorded. Test-day records with lactation stage in (< 5 days and > 400 days), age at first calving in (< 21 and > 36 months), missing parity, missing breed, missing or nonsense daily milk traits (accordingly to ICAR standards, 2017), and missing or nonsense Ta and RH value were deleted from the dataset. After logical control dataset consisted of 1.275,713 test-day records from 90.159 Holsteins reared on 6.701 farms. Accordingly, to the parity, cows were divided into seven classes: 1., ..., 7. (animals in seventh and higher lactations). Furthermore, according to the location of the farm, test-day records were divided into 16 breeding regions. In accordance to the calving date, test-day records

were divided into four recording seasons: spring (March, April, and May), summer (June, July, and August) autumn (September, October, and November), and winter (December, January, and February). Based on the measured microclimate parameters, the temperature-humidity index (THI) was calculated using the equation by Kibler (1964):

$$THI = 1.8 \times Ta - (1 - RH) \times (Ta - 14.3) + 32$$

where Ta presents the average temperature in degrees Celsius while RH is the relative humidity as a fraction of the unit.

A function (f) of THI was created as follows:

$$f(THI) = \begin{cases} 0 & \text{if } THI \leq THI_{threshold} \\ 1 & \text{if } THI > THI_{threshold} \end{cases}$$

where $THI_{threshold}$ was set to 68, 70, and 72.

For the estimation of variance components and breeding values of the daily milk production of Holstein cows in terms of heat stress following bivariate model was used:

$$y_{ijklmnop} = \mu + b_1 (d_i / 305) + b_2 (d_i / 305)^2 + b_3 \ln(305 / d_i) + b_4 \ln^2(305 / d_i) + S_j + b_5 ac_k + b_6 ac_k^2 + R_l + P_{lm} + Pe_n + Hy_o + a_p + e_{ijklmnop}$$

where $y_{ijklmnop}$ = estimated daily milk production at $THI = 0$ and $THI = 1$;

μ = intercept;

$b_1, b_2, b_3, b_4, b_5, b_6$ = regression coefficients;

d_i = days in milk ($i = 5, \dots, 400$ day);

S_j = fixed effect of calving season class j ($j = 1/2005, 2/2005, \dots, 4/2012$);

ac_k = fixed effect of age at calving as square regression;

R_l = fixed effect of breeding region l ($l = 01, \dots, 16$);

P_{lm} = fixed effect of parity m ($m = 01, \dots, 07$; nested within the lactation curve);

Pe_n - random permanent environmental effect for the cow;

Hy_o - random effect of interaction between year and year;

a_p - random additive genetic effect for the cow;

$e_{ijklmnop}$ = random residual effect.

For the preparation and logical control of data SAS/STAT (SAS Institute Inc., 2000) was used. For estimation of variance components for milk production of dairy cows VCE-6, version 6.0.3-dev (Kovač

et al., 2012) was used. Furthermore, breeding values of Holstein cows in terms of heat stress defined as different values of THI threshold values (68, 70, and 72) were estimated using the same software.

Results and discussion

In this study, the animal's reaction to heat stress environment was analysed using the bivariate model where the daily milk production in the normal conditions ($THI = 0$) was taken as the first variable while the daily milk production in the environment characterised by heat stress ($THI = 1$) was taken as the second one. The estimated variance components for daily milk production in regard to the set threshold values ($THI_{threshold}$ in 68, 70 or 72) are presented in Table 1. The variance for the permanent environment when $THI = 0$ ranged from 11.386 kg² to 11.641 kg², while for $THI = 1$ ranged from 11.190 kg² to 11.841 kg² depending on set $THI_{threshold}$ value. Obtained results indicate that at higher THI values the effect of the permanent environment was more prominent. The variance for the herd-year interaction also increased as the $THI_{threshold}$ value increased, with higher variance values determined in terms of heat stress ($THI = 1$). On contrary, the estimated

variance for the animal decreased with increase of $THI_{threshold}$ value, with lower variance values determined in heat stress conditions.

Similarly, Aguilar et al. (2009) determined that the evaluated additive genetic variance for milk, fat, and protein yields highly depends on THI value, stage of lactation, parity, and statistical model used for the evaluation. Aguilar et al. (2009) ascertained that the function of total additive genetic variance and THI had a typical quadratic shape, which corresponded to findings of Ravagnolo and Misztal (2000). Moreover, the genetic variance for heat tolerance significantly enlarged at the end of lactation and in higher parities. The effect of lactation stage on the additive genetic variance among the highest values defined at the end of lactation (DIM in 300) was also recognized by Brügemann et al. (2011). Same authors determined the reduction of additive genetic variance and permanent environment variance for test-day protein yield in terms of increasing THI value that is from 21 to 72.

TABLE 1. Estimated variances and covariance for daily milk production of Holstein cows in regard to set threshold values ($THI_{threshold}$ in 68, 70, or 72)

Effect	Variance ($THI = 0$)	Variance ($THI = 1$)	Covariance
$THI_{threshold}$ in 68 (DMY 48.28 vs 45.33)			
Penv	11.6407 ± 0.08523 kg ²	11.1895 ± 0.11864 kg ²	9.7591 ± 0.08779 kg ²
Hyear	8.27282 ± 0.15181 kg ²	9.71132 ± 0.19553 kg ²	8.11141 ± 0.15721 kg ²
Animal	9.80707 ± 0.13229 kg ²	9.20131 ± 0.15652 kg ²	8.96254 ± 0.12544 kg ²
Residual	18.5586 ± 0.030809 kg ²	15.2324 ± 0.058844 kg ²	-
$THI_{threshold}$ in 70 (DMY 48.27 vs 44.79)			
Penv	11.5145 ± 0.08552 kg ²	11.3893 ± 0.13122 kg ²	9.7225 ± 0.08825 kg ²
Hyear	8.31285 ± 0.15667 kg ²	9.75394 ± 0.20254 kg ²	8.14021 ± 0.16185 kg ²
Animal	9.76130 ± 0.13339 kg ²	9.07161 ± 0.16561 kg ²	8.91184 ± 0.12865 kg ²
Residual	18.6856 ± 0.031694 kg ²	14.5760 ± 0.064901 kg ²	-
$THI_{threshold}$ in 72 (DMY 48.23 vs 44.31)			
Penv	11.3858 ± 0.07841 kg ²	11.8413 ± 0.15383 kg ²	9.7582 ± 0.09426 kg ²
Hyear	8.34451 ± 0.15330 kg ²	9.96719 ± 0.21632 kg ²	8.19485 ± 0.16508 kg ²
Animal	9.71994 ± 0.13159 kg ²	8.91724 ± 0.17880 kg ²	8.83270 ± 0.13134 kg ²
Residual	18.7763 ± 0.032042 kg ²	13.5879 ± 0.077664 kg ²	-

*Penv - permanent environment; Hyear - herd-year interaction

TABLE 2. The estimated ratios and correlations for daily milk production of Holstein cows in regard to set threshold values (THI_{threshold} in 68, 70, or 72)

Effect	Ratio (THI = 0)	Ratio (THI = 1)	Correlation
THI_{threshold} in 68			
Penv	0.24111 ± 0.1866E-02	0.24682 ± 0.2668E-02	0.85509 ± 0.3966E-02
Hyear	0.17135 ± 0.2744E-02	0.21421 ± 0.3544E-02	0.90496 ± 0.3784E-02
Animal	0.20313 ± 0.2565E-02	0.20296 ± 0.3276E-02	0.94349 ± 0.4040E-02
Residual	0.38440 ± 0.1453E-02	0.33600 ± 0.2001E-02	-
THI_{threshold} in 70			
Penv	0.23852 ± 0.1807E-02	0.25428 ± 0.2957E-02	0.84900 ± 0.4218E-02
Hyear	0.17220 ± 0.2816E-02	0.21777 ± 0.3715E-02	0.90401 ± 0.3827E-02
Animal	0.20220 ± 0.2624E-02	0.20253 ± 0.3525E-02	0.94705 ± 0.4411E-02
Residual	0.38707 ± 0.1508E-02	0.32542 ± 0.2163E-02	-
THI_{threshold} in 72			
Penv	0.23609 ± 0.1736E-02	0.26722 ± 0.3485E-02	0.84040 ± 0.4581E-02
Hyear	0.17303 ± 0.2755E-02	0.22492 ± 0.4003E-02	0.89858 ± 0.4381E-02
Animal	0.20155 ± 0.2547E-02	0.20123 ± 0.3853E-02	0.94874 ± 0.5090E-02
Residual	0.38934 ± 0.1503E-02	0.30663 ± 0.2326E-02	-

*Penv - permanent environment; Hyear - herd-year interaction

The estimated variance ratios and correlations for daily milk production of Holstein cows in regard to set threshold values (THI threshold in 68, 70 or 72) are shown in Table 2. Variability of the daily milk production due to the permanent environment ranged from 23.61 to 26.72 % depending on environmental characteristics. The effect of the permanent environment was most pronounced in the barns with THI values higher than 72. The amount of variability of daily milk production due to herd-year interaction ranged between 17.14 % - 22.5 % with the highest proportion of variability determined in an environment characterized by heat stress and at highest THI threshold value. Lastly, heritability for daily milk production in normal conditions (THI = 0) ranged between 20.16 % - 20.31 %. The determined values of heritability in terms of heat stress (THI = 1) were similar and ranged between 20.12 and 20.30 %. The obtained results indicate a very important role of herd management in mitigation of heat stress on dairy farms. The

estimated genetic correlations were high and differed, depending on THI threshold value, from 94.35 % at the lowest THI (68) to 94.87 % at the highest analysed THI (72) value. High values of estimated genetic correlations between the daily milk production in normal conditions and the daily milk production in conditions defined by heat stress signify that cows with high performance in normal conditions will maintain alike production levels also in terms of heat stress.

Sanchez et al. (2009) defined comparatively constant values of heritability for daily milk production as a function of THI (ranged from 60 to 90). Aguilar et al. (2009) stated that the values of heritability for milk yield depend on lactation stage, parity and THI value including the highest values at the end of lactation, and in third parity, with insignificantly increase at higher THIs. Ravagnolo and Misztal (2000) defined a slight increase of heritability for protein yield as well as a piddling reduction of heritability for fat yield with increasing THI from

TABLE 3. Basic statistics of estimated breeding values (EBV) for daily milk production of Holstein cows in regard to set threshold values (THI_{threshold} in 68, 70, or 72)

THI	EBV (THI - 0)					EBV (THI - 1)					r
	mean	SD	CV	MIN	MAX	mean	SD	CV	MIN	MAX	
68	100.675	14.30	14.21	52.028	147.961	100.672	14.30	14.20	52.030	147.957	0.98642
70	100.679	14.30	14.21	52.028	147.960	100.620	14.30	14.22	52.029	147.955	0.98819
72	100.670	14.31	14.21	52.028	147.960	100.693	14.29	14.19	52.028	147.958	0.98908

*r - correlation between the EBV in normal (THI - 0) and heat stress environment (THI - 1); all correlation coefficients were statistically highly significant ($p < 0.001$)

72 to 85. On contrary, Brügemann et al. (2011) concluded that the values of heritability for protein yield were highest at lower THI values (but with THI in interval 21-72) and at the end of lactation. The same authors indicated that the impact of the lactation stage on heritability values was more noticeable than the effect of THI. Aguilar et al. (2009) advised that the genetic correlations between parities for the effect of heat tolerance varied from 0.56 to 0.79 indicated variations in heat tolerance due to parity.

Basic statistics of the estimated breeding values (EBV) for daily milk production of Holstein cows in normal and heat stress environment in regard to set threshold values (THI_{threshold} in 68, 70, or 72) is presented in Table 3. The mean values of EBVs, despite the environmental conditions, amounted to approximately 100.6. Additionally, the mean value of EBVs for daily milk production in normal conditions was the highest at the mean THI value (70), while in heat stress condition the highest EBVs were at the highest THI value (72). The correlations within the EBVs in normal and heat stress conditions was high and differed between 98.64-98.91 % showing a great bond between cow's productivity in normal and heat stress environment.

Aguilar et al. (2009) in the study of genetic elements of heat stress for dairy cattle concluded that the value of genetic variance for heat tolerance for milk yield depends on the applied model (random regression vs repeatability model). For the analysis of variance components of response to heat stress Ravagnolo et al. (2000) applied the so-called broken line model that is characterized

by the thermoneutrality threshold and the slope of production decrease after the determined threshold. Moreover, in some studies (Brügemann et al., 2011; Menendez-Buxadera et al., 2012; Carabaño et al., 2014) the variation in the day milk production in terms of heat stress was defined as polynomial functions that permit more flexible approach than the broken line models. Accordingly, to Gaughan et al. (2012) one of the principal obstacles in the application of any evaluation model is way of combination of micro/climate variables. Carabaño et al. (2014) emphasized the importance of defining the proper period between the test-day and the date when measurements of micro/climate occurred. Also, it is extremely important to define the proper selection criteria for every evaluation model. In the broken line model, as selection criteria, both the thermotolerance threshold and the incline of the animal's response could be applied. Carabaño et al. (2014) stated that in the example of higher-order polynomials used to represent the animal's response to heat stress as criteria for selection, the slope of the particular polynomial curve under moderate or severe heat stress could be used. Sánchez et al. (2009) emphasized that the application of the model in practice will indicate the animals with higher adaptation capabilities that is those cows who have lower decrease in production as well as a later reaction on environmental stress). Besides, Carabaño et al. (2014) stated the variability in genetic response and the re-ranking of animals thus to various temperatures pointing out some interaction between the genotype and (micro)climate. Aiming to simplification of practical

selection of animals for resistance to heat stress in this study, the daily milk production was analysed as a bivariate variable in the normal conditions (under the set $THI_{threshold}$ value), and in terms of heat stress (above the set $THI_{threshold}$ value). The estimated high genetic correlations between the daily milk production in normal and heat stress conditions, as well as high correlations among the EBVs in normal and heat stress conditions, point out that Holstein cows with high productivity in normal condition will sustain an alike level of production even in terms of heat stress. Given the obtained results, good acclimatization of Holstein cows to environmental conditions on dairy cattle farms could be assumed.

Conclusions

The results obtained in this study point to the fact that the Holstein cows are very well acclimatized to the environmental conditions at dairy farms in Croatia. However, the results should be taken with caution, given that measurements of microclimate parameters were conducted only once at a milk recording day, so the reliability of such measurements could be questionable. In conclusion, in order to realise a completely unambiguous conclusion, further studies that include multiple daily measurements of microclimatic parameters in the farms facilities are necessary.

Genetski parametri i uzgojne vrijednosti za dnevnu proizvodnju mlijeka holstein krava u uvjetima toplinskog stresa

Sažetak

Prilikom procjene komponenti varijance te uzgojnih vrijednosti za dnevnu proizvodnju mlijeka krava holstein pasmine u uvjetima toplinskog stresa koji je definiran pri različitim graničnim vrijednostima THI -a (68, 70, i 72) korišteno je ukupno 1.275,713 zapisa na kontrolni dan prikupljenih na 90.159 krava. Temperaturno-humidni indeks (THI) koji je izračunat na osnovu izmjerene temperature i relativne vlage u stajama na dan kontrole mliječnosti, korišten je kao mjera toplinskog stresa. Prilikom statističke analize, dnevna proizvodnja mlijeka uvažena je kao bivariatno svojstvo i to u normalnim uvjetima (ispod $THI_{threshold}$ vrijednosti) te u uvjetima toplinskog stresa (iznad $THI_{threshold}$ vrijednosti). Primijenjeni statistički model uvažio je varijabilnost uslijed stadija laktacije, sezone teljenja, dobi pri teljenju, regije uzgoja, pariteta, permanentnog okoliša, interakcije između stada i godine te pojedine životinje. Procijenjene visoke vrijednosti genetske korelacije između dnevne proizvodnje mlijeka u normalnim te u uvjetima toplotnog stresa, kao i vrlo visoke vrijednosti korelacija između procijenjenih uzgojnih vrijednosti za dnevnu proizvodnju mlijeka (EBV) u normalnim i toplinsko stresnim uvjetima indiciraju da će visoko proizvodna grla u normalnim okolišnim uvjetima sličnu razinu proizvodnje održati i u uvjetima toplinskog stresa. Dobiveni rezultati ukazuju na činjenicu da su krave holstein pasmine vrlo dobro aklimatizirane na okolišne uvjete na farmama mliječnih goveda u Hrvatskoj. Međutim, ove rezultate treba uzeti s dozom opreza, obzirom da su mjerenja mikroklimatskih parametara u objektima provođena samo jednom na dan kontrole mliječnosti, tako da pouzdanost tih mjerenja može biti upitna. Zaključno, kako bismo utvrdili potpuno nedvosmislen zaključak, neophodna su daljnja istraživanja u kojima će se provoditi višestruka dnevna mjerenja mikroklimatskih parametara u farmskim objektima.

Ključne riječi: dnevna proizvodnja mlijeka, toplinski stres, genetski parametri, holstein pasmina

References

1. Aguilar, I., Misztal, I., Tsuruta, S. (2009): Genetic components of heat stress for dairy cattle with multiple lactations. *Journal of Dairy Science* 92, 5702–5711. <https://doi.org/10.3168/jds.2008-1928>.
2. Bernabucci, U., Lacetera, N., Baumgard, L.H., Rhoads, R.P., Ronchi, B., Nardone, A. (2010): Metabolic and hormonal acclimation to heat stress in domestic ruminants. *Animal* 4, 1167–1183. <https://doi.org/10.1017/S175173111000090X>.
3. Biffani, S., Bernabucci, U., Vitali, A., Lacetera, N., Nardone, A. (2016): Short communication: effect of heat stress on the non-return rate of Italian Holstein cows. *Journal of Dairy Science* 99, 5837–5843. <https://doi.org/10.3168/jds.2015-10491>.
4. Bohmanova, J. (2006): Studies on genetics of heat stress in US Holsteins. PhD thesis. Athens: University of Georgia.
5. Bohmanova, J., Misztal, I., Cole, J.B. (2007): Temperature-humidity indices as indicators of milk production losses due to heat stress. *Journal of Dairy Science* 90, 1947–1956. <https://doi.org/10.3168/jds.2006-513>.
6. Bouraoui, R., Lahmar, M., Majdoub, A., Djemali, M., Belyea, R. (2002): The relationship of temperature humidity-index with milk production of dairy cows in a Mediterranean climate. *Animal Research* 51, 479–491. <https://doi.org/10.1051/animres:2002036>.
7. Bradford, H.L., Fragomeni, B.O., Bertrand, J.K., Lourenco D.A.L., Misztal, I. (2016): Genetic evaluations for growth heat tolerance in Angus cattle. *Journal of Animal Science* 94, 4143–4150. <https://doi.org/10.2527/jas.2016-0707>.
8. Brügemann, K., Gernand, E., von Borstel, U. U., König, S. (2011): Genetic analyses of protein yield in dairy cows applying random regression models with time-dependent and temperature x humidity-dependent covariates. *Journal of Dairy Science* 94, 4129–4139. <https://doi.org/10.3168/jds.2010-4063>.
9. Carabaño, M.J., Bachagha, K., Ramón, M., Díaz, C. (2014): Modeling heat stress effect on Holstein cows under hot and dry conditions: Selection tools. *Journal of Dairy Science* 97, 7889–7904. <https://doi.org/10.3168/jds.2014-8023>.
10. Casa, A.C., Ravelo, A.C. (2003): Assessing temperature and humidity conditions for dairy cattle in Cordoba, Argentina. *International Journal of Biometeorology* 48, 6–9. <https://doi.org/10.1007/s00484-003-0179-x>.
11. Collier, R.J., Dahl, G.E., van Baale, M.J. (2006): Major advances associated with environmental effects on dairy cattle. *Journal of Dairy Science* 89, 1244–1253. [https://doi.org/10.3168/jds.s0022-0302\(06\)72193-2](https://doi.org/10.3168/jds.s0022-0302(06)72193-2).
12. Collier, R.J., Hall, L.W. (2012): Quantifying heat stress and its impact on metabolism and performance. Tucson, Arizona: Department of Animal Sciences, University of Arizona.
13. Correa-Calderon, A., Armstrong, D., Ray, D., de Nise, S., Enns, M., Howison, C. (2004): Thermoregulatory responses of Holstein and Brown Swiss heat-stressed dairy cows to two different cooling systems. *International Journal of Biometeorology* 48, 142–148. <https://doi.org/10.1007/s00484-003-0194-y>.
14. Freitas, M., Misztal, I., Bohmanova, J., Torres, R. (2006): Regional differences in heat stress in U.S. Holsteins. Proc 8th World Congr. Genet. Appl. Livest. Prod., Commun. 01–11, Instituto Prociencia, Belo Horizonte, Brazil.
15. Gantner, V., Mijić, P., Kuterovac, K., Solić, D., Gantner, R. (2011): Temperature-humidity index values and their significance on the daily production of dairy cattle. *Mljekarstvo* 61 (1), 56–63.
16. Gantner, V., Bobić, T., Gantner, R., Gregić, M., Kuterovac, K., Novaković, J., Potočnik, K. (2017): Differences in response to heat stress due to production level and breed of dairy cows. *International Journal of Biometeorology* 61, 9, 1675–1685. <https://doi.org/10.1007/s00484-017-1348-7>.
17. Gaughan, J.B., Mader, T.L., Gebremedhim, K.G. (2012): Rethinking heat index tools for livestock. In: Collier, R.J., and J.L. Collier. *Environmental physiology of livestock*. Chichester, West Sussex, UK: Wiley-Blackwell. <https://doi.org/10.1002/9781119949091.ch14>.
18. Hammami, H., Bormann, J., M'hamdi, N., Montaldo, H.H., Gengler, N. (2013): Evaluation of heat stress effects on production traits and somatic cell score of Holsteins in a temperate environment. *Journal of Dairy Science* 96, 1844–1855. <https://doi.org/10.3168/jds.2012-5947>.
19. Hubbard, K.G., Stooksbury, D.E., Hahn, G.L., Mader, T.L. (1999): A climatologic perspective on feedlot cattle performance and mortality related to the temperature-humidity index. *Journal of Production Agriculture* 12, 650–653. <https://doi.org/10.2134/jpa1999.0650>.
20. Kadzere, C.T., Murphy, M.R., Silanikove, N., Maltz, E. (2002): Heat stress in lactating dairy cows: a review. *Livestock Production Science* 77, 59–91. [https://doi.org/10.1016/s0301-6226\(01\)00330-x](https://doi.org/10.1016/s0301-6226(01)00330-x).

21. Lambertz, C., Sanker, C., Gauly, M. (2014): Climatic effects on milk production traits and somatic cell score in lactating Holstein-Friesian cows in different housing systems. *Journal of Dairy Science* 97, 319-329. <https://doi.org/10.3168/jds.2013-7217>
22. Menéndez-Buxadera, A., Molina, A., Arrebola, F., Clemente, I., Serradilla J.M. (2012): Genetic variation of adaptation to heat stress in two Spanish dairy goat breeds. *Journal of Animal Breeding and Genetics* 129, 306-315. <https://doi.org/10.1111/j.1439-0388.2011.00984.x>
23. Ravagnolo, O., Misztal, I. (2000): Genetic component of heat stress in dairy cattle, parameter estimation. *Journal of Dairy Science* 83, 2126-2130. [https://doi.org/10.3168/jds.s0022-0302\(00\)75095-8](https://doi.org/10.3168/jds.s0022-0302(00)75095-8)
24. Sánchez, J. P., Misztal, I., Aguilar, I., Zumbach, B., Rekaya, R. (2009): Genetic determination of the onset of heat stress on daily milk production in the US Holstein cattle. *Journal of Dairy Science* 92, 4035-4045. <https://doi.org/10.3168/jds.2008-1626>
25. Segnalini, M., Bernabucci, U., Vitali, A., Nardone, A., Lacetera, N. (2013): Temperature humidity index scenarios in the Mediterranean basin. *International Journal of Biometeorology* 57, 451-458. <https://doi.org/10.1007/s00484-012-0571-5>
26. Smith, D.L., Smith, T., Rude, B.J., Ward, S.H. (2013): Comparison of the effects of heat stress on milk and component yields and somatic cell score in Holstein and Jersey cows. *Journal of Dairy Science* 96, 3028-3033. <https://doi.org/10.3168/jds.2012-5737>
27. St-Pierre, N.R., Cobanov, B., Schnitkey, G. (2003): Economic losses from heat stress by US livestock industries. *Journal of Dairy Science* 86, 52-77. [https://doi.org/10.3168/jds.s0022-0302\(03\)74040-5](https://doi.org/10.3168/jds.s0022-0302(03)74040-5)
28. West, J.W., Hill, G.M., Fernandez, J.M., Mandevu, P., Mullinix, B.G. (1999): Effect of dietary fiber on intake, milk yield, and digestion by lactating dairy cows during cool or hot, humid weather. *Journal of Dairy Science* 82, 2455-2465. [https://doi.org/10.3168/jds.s0022-0302\(99\)75497-4](https://doi.org/10.3168/jds.s0022-0302(99)75497-4)
29. West, J.W. (2003): Effects of heat-stress on production in dairy cattle. *Journal of Dairy Science* 86, 2131-2144. [https://doi.org/10.3168/jds.s0022-0302\(03\)73803-x](https://doi.org/10.3168/jds.s0022-0302(03)73803-x)

Izvorni znanstveni rad broj 4 u obliku i izvornom jeziku na kojem je objavljen u znanstvenom časopisu

Naslova rada: **ESTIMATION OF GENETIC PARAMETERS AND BREEDING VALUES FOR DAILY MILK PRODUCTION OF DAIRY SIMMENTALS IN TERMS OF HEAT STRESS**

Autori: **Goran VUČKOVIĆ, Tina BOBIĆ, Pero MIJIĆ, Mirna GAVRAN, Maja GREGIĆ, Klemen POTOČNIK, Vladan BOGDANOVIĆ, Vesna GANTNER**

Tip rada: Izvorni znanstveni rad

Časopis: **Genetika**

Kategorija: A1

Impakt faktor: 0,761

Kvartil: Q4

Primljen na recenziju: 14.11.2019.

Prihvaćen za objavljivanje: 18.05.2020.

Status: Objavljen

Volumen: 52

Svezak: 2

Stranice: 641 – 650

WOS broj: WOS:000577916600017

UDC 575.
<https://doi.org/10.2298/GENSR2002641V>
 Original scientific paper

ESTIMATION OF GENETIC PARAMETERS AND BREEDING VALUES FOR DAILY MILK PRODUCTION OF DAIRY SIMMENTALS IN TERMS OF HEAT STRESS

Goran VUČKOVIĆ¹, Tina BOBIĆ^{2*}, Pero MIJIĆ², Mima GAVRAN², Maja GREGIĆ²,
 Klemen POTOČNIK³, Vladan BOGDANOVIĆ⁴, Vesna GANTNER²

¹ Rinderunion Baden-Württemberg, Herberlingen, Germany

² Department for animal production and biotechnology, Faculty of agrobiotechnology Osijek, University of Josip Juraj Strossmayer in Osijek, Osijek, Croatia

³ Department of Animal Science, Biotechnical Faculty, University of Ljubljana, Ljubljana, Slovenia

⁴ Faculty of Agriculture, University of Belgrade, Belgrade, Serbia

Vučković G., T. Bobić, P. Mijić, M. Gavran, M. Gregić, K. Potočnik, V. Bogdanović, V. Gantner (2020). *Estimation of genetic parameters and breeding values for daily milk production of dairy Simmentals in terms of heat stress.* - Genetika, Vol 52, No.2, 641-650.

Variance components for daily milk production as well as breeding value of dairy Simmentals for daily milk production in terms of heat stress defined as different values of THI threshold values (72, 74, and 76) were estimated using 1,636,192 test-day records provided by the Croatian Agricultural Agency. Temperature-humidity index (THI) calculated from ambient temperature and relative humidity recorded in the barns on the milk recording day was used as the measure of heat stress. Bivariate estimation model accounted variances due to lactation stage, calving season, age at calving, breeding region, parity, permanent environment, interaction between year and year, and individual animal. Obtained high genetic correlations between the daily milk production in normal and condition characterized by heat stress, as well as very high correlations between the EBVs in normal and heat stress conditions indicate animals' high level of acclimatization to the environment on dairy cattle farms. Since microclimate measurements were carried out only once at a milk recording day, these results should be taken with caution. Generally, further research with multiple daily measurements of the microclimate parameters in the facilities is necessary to provide a fully unambiguous conclusion.

Keywords: daily milk yield, heat stress, resistance, genetic parameters, Simmental breed.

Corresponding authors: Tina Bobić, Department for animal production and biotechnology Osijek, Josip Juraj Strossmayer University of Osijek, Faculty of Agrobiotechnical Sciences Osijek, Osijek, Croatia, Tel: +385 31 554 859; fax: +385 31 554 853. E-mail: tbobic@fazos.hr

INTRODUCTION

Dairy farming and welfare is affected by various factors due to complex interactions between the animal and the environment with its different factors (LAMBERTZ *et al.*, 2014). According to MOSELEY *et al.* (2012) mean annual temperatures are predicted to rise by 1°C for the period of 2021 to 2050 and 2.5°C for the period of 2071 to 2100 in Lower Saxony compared with the reference period of 1971 to 2000. With increasing of the adverse climate change, SEGNALE *et al.* (2013) pointed out the necessity of adequate adaptation strategies in order to decrease negative effects of climate change on domestic animals. In intensive dairy breeding systems, the heat stress is a huge problem, because the high production makes cows more susceptible to heat stress (HANSEN, 2013). The level of milk production significantly alters the animal response to heat stress (WEST *et al.*, 2003; COLLIER *et al.*, 2006; GANTNER *et al.*, 2011; DUNN *et al.*, 2014), because the intensive genetic selection for higher milk production resulted in changes in the thermoregulation physiology of dairy cattle, which means that larger animals with higher production have larger gastrointestinal tracts enable them to digest more feed, but also creates more metabolic heat and reduces the animal's ability to regulate temperature at heat stress environment (KADZERE *et al.*, 2002). Besides of the negative influence on the production level, the heat stress has also a negative influence on following traits: dry matter intake, milk composition, reproductive performances, somatic cell counts (SCC) and prevalence of mastitis (CASA and RAVELO, 2003; BOHMANOVA *et al.*, 2007; COLLIER *et al.*, 2012; HAMMAMI *et al.*, 2013; SMITH *et al.*, 2013; LAMBERTZ *et al.*, 2014; GANTNER *et al.*, 2017). Finally, accordingly to research of ST-PIERRE *et al.* (2003) heat stress induces considerable profit loss.

The temperature-humidity index (THI) is a commonly used indicator for determination of the heat stress influence on productivity of dairy cows (HUBBARD *et al.*, 1999; GANTNER *et al.*, 2011). THI incorporates the effects of ambient temperature as well as relative humidity, and according to previous research THI threshold value at which heat stress affects milk production and feed intake range from 68 to 72 (BOURAOU *et al.*, 2002; BERNABUCCI *et al.*, 2010; COLLIER and HALL, 2012). There are numerous methods of minimizing the impact of heat stress on dairy cattle. These methods could be categorised as short-term and long-term methods. Short-term methods include optimization of feeding and application of different cooling systems in farm buildings, while long-term methods imply selection of dairy cattle for resistance to heat stress. Determination of the effect of heat stress on milk production and the estimation of genetic components of heat stress resistance were studied in previous research. MISZTAL (1999) proposed a model fitting a comfort zone, with no effect of temperature on production. SCHAEFFER (2004) emphasised that longitudinal data are commonly analysed with random regression models. DRUET *et al.* (2003), SILVESTRE *et al.* (2005) and BOHMANOVA *et al.* (2007) concluded that splines can be used to model (co)variances in test-day models. Furthermore, MISZTAL (2006) point out that the linear splines are easily interpretable, and have good numerical properties and local effects. SÁNCHEZ *et al.* (2009) used thermotolerance threshold and the subsequent slope of decay for each animal in the complex model. According to RAVAGNOLO and MISZTAL (2000) the additive genetic variability for heat stress tolerance are important for milk, fat and protein production of primiparous cows. Genetic evaluation for heat tolerance for Holstein cows were established BOHMANOVA *et al.* (2005), and they concluded that daughters of bulls with high genetic merit for heat tolerance had lower milk yields, higher contents of milk solids, more

robust bodies, better udders, longer productive lives, and higher pregnancy rates than daughters of bulls with low genetic merit for heat tolerance. AQUILAR *et al.* (2009), using the test-day models that included a random regression on a function of THI, concluded that phenotypic variance and additive genetic effects for heat stress and yield traits increased greatly from the first to third parity, and consequently, later parity cows are expected to be much more susceptible to heat stress than are primiparous cows. BRUGEMANN *et al.* (2011) used a random regression models for genetic analyses of protein yield in dairy cows, and concluded that additive genetic variances for daily protein yield decreased with increasing degrees of heat stress and were lowest at the beginning of lactation and at extreme value of THI. CARABAÑO *et al.* (2014) established that Legendre polynomial model provided better explanation and fit than the splines model to describe changes in production and SCC along the range of studied temperatures at the phenotypic level as well as for the individual components. Since climate change and consequently heat stress becomes the reality of the world that we are living and producing, there is a necessity of adequate adaptation strategies aiming decrease of negative effects of climate change on domestic animals (SEGNALINI *et al.*, 2013). Therefore, in order to apply long-term mitigation method, the objectives of this study were estimation of variance components for milk production as well as estimation of breeding value of dairy Simmentals in terms of heat stress defined as different values of THI threshold values (72, 74, and 76).

MATERIAL AND METHODS

Test-day records of dairy Simmental cows reared in Croatia were obtained from the Croatian Agricultural Agency. Test-day records were collected in the period from January 2005 to December 2013 during the regular milk recording (AT4 or BT4 method). At each recording, measuring and sampling of milk were performed during the evening or morning milking, and also, at each recording, ambient temperature and relative humidity in the barns were recorded. Furthermore, test-day records with lactation stage in (< 5 days and > 400 days), age at first calving in (< 21 and > 36 months), missing parity, missing breed, missing or nonsense daily milk traits (accordingly to ICAR standards, 2017), and missing or nonsense Ta and RH value were deleted from the dataset. After logical control dataset consisted of 1,636,192 test-day records from 117,659 Simmentals reared on 10,599 farms. Accordingly, to the parity, cows were divided into seven classes: 1., ..., 7. (animals in seventh and higher lactations). Furthermore, accordingly to location of farm, test day records were divided into 16 breeding regions. In accordance to the calving date, test day records were divided into four recording season: spring (March, April, and May), summer (June, July, and August) autumn (September, October, and November), and winter (December, January, and February). Based on measured microclimate parameters, temperature-humidity index (THI) was calculated using the equation by KIBLER (1964):

$$THI = 1.8 \times Ta - (1 - RH) \times (Ta - 14.3) + 32$$

Where Ta presents the average temperature in degrees Celsius while RH is the relative humidity as a fraction of the unit.

A function (f) of THI was created as follows:

$$f(THI) = \begin{cases} 0, & \text{if } THI \leq THI_{threshold} \\ 1, & \text{if } THI > THI_{threshold} \end{cases}$$

where $THI_{threshold}$ was set to 72, 74, and 76.

For estimation of variance components for milk production as well as for estimation of breeding values of dairy Simmental cows in terms of heat stress following bivariate model was used:

$$y_{ijklmnop} = \mu + b_1(d_i/305) + b_2(d_i/305)^2 + b_3 \ln(305/d_i) + b_4 \ln^2(305/d_i) + S_j + b_5 ac_k + b_6 ac_k^2 + R_l + P_{lm} + Pe_n + Hy_o + a_p + e_{ijklmnop}$$

where $y_{ijklmnop}$ = estimated daily milk production at $THI = 0$ and $THI = 1$;

μ = intercept;

$b_1, b_2, b_3, b_4, b_5, b_6$ = regression coefficients;

d_i = days in milk ($i = 5, \dots, 400$ day);

S_j = fixed effect of calving season class j ($j = 1/2005, 2/2005, \dots, 4/2012$);

ac_k = fixed effect of age at calving as square regression;

R_l = fixed effect of breeding region l ($l = 01, \dots, 16$);

P_{lm} = fixed effect of parity m ($m = 01, \dots, 07$; nested within the lactation curve);

Pe_n – random permanent environmental effect for the cow;

Hy_o – random effect of interaction between herd and year;

a_p – random additive genetic effect for the cow;

$e_{ijklmnop}$ = random residual effect.

For the preparation and logical control of data SAS/STAT (SAS Institute Inc., 2000) was used. For estimation of variance components for milk production of dairy cows VCE-6, version 6.0.3-dev (KOVAC *et al.*, 2012) was used. Furthermore, breeding values of dairy Simmental cows in terms of heat stress defined as different values of THI threshold values (72, 74, and 76) were estimated using same software.

RESULTS AND DISCUSSION

In this research the animal response to heat stress was analysed using bivariate model where the daily milk production in normal conditions ($THI = 0$) was taken as first variable while the daily milk production in heat stress environment ($THI = 1$) was taken as second variable. The results of estimation of variance components for daily milk production of dairy Simmentals, accordingly to the set threshold values ($THI_{threshold}$ in 72, 74, or 76) are presented in Table 1. The variance for permanent environment when $THI = 0$ ranged from 3.627 kg² to 3.579 kg², while for $THI = 1$ ranged from 3.577 kg² to 3.670 kg² depending of $THI_{threshold}$ value indicating that at higher THI values the effect of permanent environment was more pronounced. Similar trend of variance increase in normal condition regarding the $THI_{threshold}$ value was also observed for variability due to herd-year interaction and residual variance. In terms of heat stress ($THI = 1$), regarding the set $THI_{threshold}$ value, the decrease of residual variance was observed, while the herd-year variance increased. Estimated variance for animal was slightly higher in terms of heat stress as well as at higher values of set $THI_{threshold}$ with exception when THI in 76.

AGUILAR *et al.* (2009) determined that the estimated additive genetic variance for milk, fat, and protein yields highly depends of THI , days in milk (DIM), parity, and statistical model used for the estimation. Similarly like in study of RAVAGNOLO and MISZTAL (2000), AGUILAR *et al.* (2009) find out that the function of total additive genetic variance and THI had a typical

quadratic shape. Furthermore, the genetic variance for heat tolerance significantly increased at the end of lactation and in higher parities. The influence of lactation stage on the additive genetic variance with the highest values determined at the end of lactation (DIM = 300) was also observed by BRUGEMANN *et al.* (2011). Same authors also determined the decrease of additive genetic variance and permanent environment variance for test-day protein yield in terms of increasing THI value (from 21 to 72).

Table 1. Estimated variances and covariance for milk production of dairy Simmental cows accordingly to set threshold values (THI threshold in 72, 74, or 76)

Effect	Variance (THI = 0)	Variance (THI = 1)	Covariance
THI threshold in 72			
Penv	3.62684 ± 0.023704 kg ²	3.57655 ± 0.054748 kg ²	3.18274 ± 0.029340 kg ²
Hyear	4.39042 ± 0.057105 kg ²	5.35418 ± 0.080783 kg ²	4.22085 ± 0.061951 kg ²
Animal	5.25454 ± 0.056325 kg ²	5.25809 ± 0.078944 kg ²	5.07305 ± 0.058007 kg ²
Residual	8.94054 ± 0.012533 kg ²	7.54261 ± 0.038398 kg ²	-
THI threshold in 74			
Penv	3.59892 ± 0.024255 kg ²	3.61619 ± 0.065184 kg ²	3.18366 ± 0.032497 kg ²
Hyear	4.39700 ± 0.055753 kg ²	5.50066 ± 0.089483 kg ²	4.25371 ± 0.063407 kg ²
Animal	5.23564 ± 0.053151 kg ²	5.25395 ± 0.087959 kg ²	5.09532 ± 0.058297 kg ²
Residual	8.96415 ± 0.013173 kg ²	7.40636 ± 0.045108 kg ²	-
THI threshold in 76			
Penv	3.57874 ± 0.022982 kg ²	3.69503 ± 0.082649 kg ²	3.17386 ± 0.036770 kg ²
Hyear	4.40475 ± 0.053216 kg ²	5.58089 ± 0.097791 kg ²	4.25124 ± 0.065262 kg ²
Animal	5.22721 ± 0.052722 kg ²	5.17235 ± 0.099102 kg ²	5.10041 ± 0.064147 kg ²
Residual	8.97953 ± 0.013315 kg ²	7.28479 ± 0.052614 kg ²	-

*Penv – permanent environment; Hyear – herd-year interaction

Estimated variance ratios and correlations for daily milk production of dairy Simmental cows accordingly to set threshold values (THI threshold in 72, 74, or 76) are presented in the Table 2. The variability of daily milk production due to permanent environment ranged from 16.13-17.00% depending of environment characteristics. The effect of permanent environment was the most pronounced in the barns with THI > 76. The amount of variability of milk production due to herd-year interaction ranged between 19.77%-25.68% with the highest proportion of variability determined in environment characterized by heat stress and at highest THI threshold value. Finally, heritability for daily milk production in normal conditions (THI = 0) was around 23.50%, while in terms of heat stress heritability was higher and ranged between 23.78-24.20%.

Estimated genetic correlations was high and ranged, depending of THI threshold value, from 96.13% at the lowest THI (72) to 98.09% at the highest analysed THI (76) value. High values of estimated genetic correlations between the daily milk production in normal conditions and the daily milk production in conditions characterised with heat stress indicate that cows with high performance in normal condition will retain similar production level even in terms of heat stress.

SANCHEZ *et al.* (2009) determined relatively constant values of heritability for daily milk production as a function of THI (ranged from 60 to 90). AGUILAR *et al.* (2009) reported that

values of heritability for milk yield depends on lactation stage, parity and THI value with the highest values at the end of lactation, and in third parity, with slightly increase at higher THIs. RAVAGNOLO and MISZTAL (2000) determined a slightly increase of heritability for protein yield as well as slightly decrease of heritability for fat yield with increasing THI from 72 to 85. Contrary, BRUGEMANN *et al.* (2011) determined that the values of heritability for protein yield were highest at lower THI values (but with THI in interval 21 – 72) and at the end of lactation. Same authors emphasized that the effect of lactation stage on heritabilities was more pronounced than the effect of THI. AGUILAR *et al.* (2009) reported that the genetic correlations among parities for the effect of heat tolerance ranged from 0.56 to 0.79 indicated differences in heat tolerance due to parity.

Table 2. Estimated ratios and correlations for milk production of dairy Simmental cows accordingly to set threshold values (THI threshold in 72, 74, or 76)

Effect	Ratio (THI – 0)	Ratio (THI – 1)	Correlation
THI threshold in 72			
Penv	0.16328 ± 0.1117E-02	0.16458 ± 0.2509E-02	0.88370 ± 0.6348E-02
Hyear	0.19766 ± 0.2286E-02	0.24638 ± 0.3164E-02	0.87056 ± 0.3506E-02
Animal	0.23656 ± 0.2312E-02	0.24196 ± 0.3384E-02	0.96513 ± 0.3312E-02
Residual	0.40250 ± 0.1189E-02	0.34708 ± 0.2144E-02	-
THI threshold in 74			
Penv	0.16215 ± 0.1138E-02	0.16605 ± 0.2996E-02	0.88250 ± 0.7366E-02
Hyear	0.19810 ± 0.2205E-02	0.25259 ± 0.3433E-02	0.86493 ± 0.3936E-02
Animal	0.23589 ± 0.2190E-02	0.24126 ± 0.3719E-02	0.97150 ± 0.3927E-02
Residual	0.40387 ± 0.1209E-02	0.34010 ± 0.2495E-02	-
THI threshold in 76			
Penv	0.16128 ± 0.1073E-02	0.17002 ± 0.3690E-02	0.87280 ± 0.9648E-02
Hyear	0.19850 ± 0.2114E-02	0.25679 ± 0.3768E-02	0.85744 ± 0.4453E-02
Animal	0.23556 ± 0.2162E-02	0.23799 ± 0.4268E-02	0.98090 ± 0.5076E-02
Residual	0.40466 ± 0.1188E-02	0.33519 ± 0.2930E-02	-

*Penv – permanent environment; Hyear – herd-year interaction

The variability of estimated breeding values (EBV) for daily milk production of dairy Simmental cows in normal and heat stress environment accordingly to set threshold values (THI threshold in 72, 74, or 76) is presented in the Table 3. Mean values of EBVs, regardless the environmental conditions, amounted around 100.5. Furthermore, mean value of EBVs for daily milk production in normal conditions was the highest at the lowest THI value, while in heat stress condition the highest EBVs was at highest THI value. The correlations between the EBVs in normal and heat stress conditions was high and ranged between 99.48-99.76% indicating strong link between cow's productivity in normal and heat stress environment.

AGUILAR *et al.* (2009) in the analysis of genetic components of heat stress for dairy cattle determined that the value of genetic variance for heat tolerance for milk yield depends of the used model (random regression model vs repeatability model). RAVAGNOLO *et al.* (2000) for the analysis of variance components of response used the so-called broken line model. This model is

defined by the thermoneutrality threshold and the slope of production decrease after defined threshold value. Furthermore, in some research (BRÜGEMANN *et al.*, 2011; MENENDEXBUXADERA *et al.*, 2012; CARABAÑO *et al.*, 2014) the variation in daily production due to heat stress was described as polynomial functions that enable more flexible approach comparable to broken line models. One of the main problems in the application of any evaluation model is how to combine (micro)climate variables (GAUGHAN *et al.*, 2012) as well as the definition of the lag between the test-day and the date with measurements of (micro)climate (CARABAÑO *et al.*, 2014). In continuation, the determination of the adequate selection criteria for each evaluation model is very important. In the broken line model, as selection criteria, both the thermotolerance threshold and the slope of animal's response could be used. In the case of higher-order polynomials used to describe the animal's reaction to heat stress, the slope of the individual polynomial curve under moderate or severe heat stress could be used as criteria for selection (CARABAÑO *et al.*, 2014). Accordingly, to SÁNCHEZ *et al.* (2009) the practical application of model will show the animals with higher adaptation (those who have lower performance decrease as well as a later onset of environmental stress). Furthermore, CARABAÑO *et al.* (2014) reported the variability in genetic response and the reranking of animals accordingly to different temperatures indicating some interaction between the genotype and (micro) climate.

Table 3. Variability of estimated breeding values (EBV) for daily milk production of dairy Simmental cows in terms of heat stress accordingly to set threshold values (THI threshold in 72, 74, or 76)

THI	EBV (THI = 0)					EBV (THI = 1)					r
	mean	SD	CV	MIN	MAX	mean	SD	CV	MIN	MAX	
72	100.486	13.32 5	13.26	52.127	147.98 1	100.423	13.32 6	13.27	52.106	147.98 0	0.9947 7
74	100.482	13.32 5	13.26	52.122	147.98 1	100.446	13.32 3	13.26	52.107	147.98 0	0.9959 1
76	100.481	13.32 4	13.26	52.126	147.98 1	100.451	13.32 3	13.26	52.116	147.98 0	0.9976 2

*r – correlation between the EBV in normal (THI = 0) and heat stress environment (THI = 1); all correlation coefficients were statistically highly significant ($p < 0.001$)

In order to simplify the practical selection of animals for resistance to heat stress, in this research, daily milk production was analysed as bivariate variable, in the normal conditions (under the set THI threshold value), and in terms of heat stress (above the set THI threshold value). Estimated very high genetic correlations between the daily milk production in normal and heat stress condition, as well as very high correlations between the EBVs in normal and heat stress conditions show that high-performance cows in the normal condition will maintain a similar level of production even in terms of heat stress. Given the obtained results, good acclimatization of dairy Simmental cows to environmental conditions on dairy cattle farms could be assumed.

CONCLUSIONS

Estimated high genetic correlations between the daily milk production in normal and condition characterized by heat stress, as well as very high correlations between the EBVs in

normal and heat stress conditions. These results should be taken with caution, since microclimate measurements were carried out only once at a milk recording day, therefore the question is whether they could be relevant as such. Generally, further research with multiple daily measurements of the microclimate parameters in the facilities is necessary to provide a fully unambiguous conclusion.

ACKNOWLEDGMENT

We would like to express gratitude to the Croatian Agricultural Agency (CAA) for providing the milk recording data (test-day records) and pedigree data.

Received, November 14th, 2019

Accepted May 18th, 2020

REFERENCES

- AGUILAR, I., I., MISZTAL, S., TSURUTA (2009): Genetic components of heat stress for dairy cattle with multiple lactations. *J. Dairy Sci.*, 92(11): 5702-5711.
- BERNABUCCI, U., N., LACETERA, L.H., BAUMGARD, R.P., RHOADS, B., RONCHI, A., NARDONE (2010): Metabolic and hormonal acclimation to heat stress in domestic ruminants. *Animal*, 4(7): 1167-1183.
- BOHMANOVA, J., I., MISZTAL, S., TSURUTA, H.D., NORMAN, T.J., LAWLOR (2005): National genetic evaluation of milk yield for heat tolerance of United States Holsteins. *Interbull Bull*, 33: 160-162.
- BOHMANOVA, J., I., MISZTAL, J.B., COLE (2007): Temperature-humidity indices as indicators of milk production losses due to heat stress. *J. Dairy Sci.*, 90(4): 1947-1956.
- BOHMANOVA, J., J., JAMROZIK, F., MIGLIOR, I., MISZTAL, P.G., SULLIVAN (2007): Legendre polynomials versus linear splines in the Canadian test-day model. *Interbull Bull*, 37: 42-48.
- BOURAOUTI, R., M., LAHMAR, A., MAJDOUB, M., DJEMALI, R., BELYEA (2002): The relationship of temperature humidity-index with milk production of dairy cows in a Mediterranean climate. *Anim. Res.*, 51(6): 479-491.
- BRÜGEMANN, K., E., GERNAND, U.U., VON BORSTEL, S., KONIG (2011): Genetic analyses of protein yield in dairy cows applying random regression models with time-dependent and temperature x humidity-dependent covariates. *J. Dairy Sci.*, 94(8): 4129-4139.
- CASA, A.C., A.C., RAVELO (2003): Assessing temperature and humidity conditions for dairy cattle in Cordoba, Argentina. *Int. J. Biometeorol.*, 48: 6-9.
- CARABAÑO, M.J., K., BACHAGHA, M., RAMÓN, C., DÍAZ (2014): Modelling heat stress effect on Holstein cows under hot and dry conditions: Selection tools. *J. Dairy Sci.*, 97(12): 7889-7904.
- COLLIER, R.J., L.W., HALL (2012): Quantifying heat stress and its impact on metabolism and performance. Tucson, Arizona: Department of Animal Sciences, University of Arizona.
- COLLIER, R.J., G.E., DAHL, M.J., VAN BAAL (2006): Major advances associated with environmental effects on dairy cattle. *J. Dairy Sci.*, 89(4): 1244-1253.
- DRUET, T., F., JAFFRÉZIC, D., BOICHARD, V., DUCROCQ (2003): Modeling lactation curves and estimation of genetic parameters for first lactation test-day records of French Holstein cows. *J. Dairy Sci.*, 86(7): 2480-2490.
- DUNN, R.J.H., N.E., MEAD, K.M., WILLETT, D.E., PARKER (2014): Analysis of heat stress in UK dairy cattle and impact on milk yields. *Environ. Res. Lett.*, 9(6): 064006.
- GANTNER, V., P., MIUĆ, K., KUTEROVAC, D., SOLIĆ, R., GANTNER (2011): Temperature-humidity index values and their significance on the daily production of dairy cattle. *Mljekarstvo*, 61(1): 56-63.
- GANTNER, V., T., BOBIĆ, R., GANTNER, M., GREGIĆ, K., KUTEROVAC, J., NOVAKOVIĆ, K., POTOČNIK (2017): Differences in response to heat stress due to production level and breed of dairy cows. *Int. J. Biometeorol.*, 61(9): 1675-1685.

- GAUGHAN, J.B., T.L., MADER, K.G., GEBREMEDHIM (2012): Rethinking heat index tools for livestock. In: Collier, R. J., and J. L. Collier. Environmental physiology of livestock. Chichester, West Sussex, UK: Wiley-Blackwell.
- HAMMAMI, H., J., BORMANN, N., M'HAMDI, H.H., MONTALDO, N., GENGLER (2013): Evaluation of heat stress effects on production traits and somatic cell score of Holsteins in a temperate environment. *J. Dairy Sci.*, 96(3): 1844–1855.
- HANSEN, P.J. (2013): Genetic control of heat stress in dairy cattle. In: Proceedings 49th Florida Dairy Production Conference, Gainesville, April 10, 2013.
- HUBBARD, K.G., D.E., STOOKSBURY, G.L., HAHN, T.L., MADER (1999): A climatologic perspective on feedlot cattle performance and mortality related to the temperature-humidity index. *J. Prod. Agric.*, 12(4): 650-653.
- KADZERE, C.T., M.R., MURPHY, N., SILANKOVE, E., MALTZ (2002): Heat stress in lactating dairy cows: a review. *Livest. Sci.*, 77(1): 59-91.
- KIBLER, H.H. (1964): Environmental physiology and shelter engineering. LXVII. Thermal effects of various temperature-humidity combinations on Holstein cattle as measured by eight physiological responses. Research Bulletin, University of Missouri, College of Agriculture, Agricultural Experiment Station, 862.
- KOVAČ, M., E., GROENEVELD, A., GARCIA-CORTEZ (2012): VCE-6, version 6.0.3-dev.
- LAMBERTZ, C., C. SANKER, M. GAULY (2014): Climatic effects on milk production traits and somatic cell score in lactating Holstein-Friesian cows in different housing systems. *J. Dairy Sci.*, 97(1): 319-329.
- MENÉNDEZ-BUXADERA, A., A., MOLINA, F., ARREBOLA, I., CLEMENTE, J.M., SERRADILLA (2012): Genetic variation of adaptation to heat stress in two Spanish dairy goat breeds. *J. Anim. Breed Genet.*, 129(4): 306–315.
- MISZTAL, I. (1999): Model to study genetic component of heat stress in dairy cattle using national data. *J. Dairy Sci.*, 82(Suppl. 1): 32. (Abstr.)
- MISZTAL, I. (2006): Properties of random regression models using linear splines. *J. Anim. Breed Genet.*, 123(2): 74-80.
- MOSELEY, C., O., PANFEROV, C., DÖRING, J., DIETRICH, U., HABERLANDT, V., EBERMANN, D., RECHID, F., BEESE, D., JACOB (2012): Empfehlung für eine niedersächsische Strategie zur Anpassung an die Folgen des Klimawandels. Niedersächsisches Ministerium für Umwelt, Energie und Klimaschutz, Regierungskommission Klimaschutz, Hannover, Germany. Accessed Aug. 15, 2012.
- RAVAGNOLO, O., I., MISZTAL, G., HOOGENBOOM (2000): Genetic component of heat stress in dairy cattle, development of heat index function. *J. Dairy Sci.*, 83(9): 2120-2125.
- SÁNCHEZ, J.P., R., REKAYA, I., MISZTAL (2009): Reaction norm model subject to threshold response for genetic evaluation on heat tolerance. *Genet. Sel. Evol.*, 41:10.
- SCHAEFFER, L.R. (2004): Application of random regression models in animal breeding. *Livest. Prod. Sci.*, 86(1-3): 35-45.
- SEGNALENI, M., U., BERNABUCCI, A., VITALI, A., NARDONE, N., LACETERA (2013): Temperature humidity index scenarios in the Mediterranean basin. *Int. J. Biometeorol.*, 57(3): 451–458.
- SILVESTRE, A.M., F., PETIM-BATISTA, J., COLACO (2005): Genetic parameter estimates of Portuguese dairy cows for milk, fat, and protein using a spline test-day model. *J. Dairy Sci.*, 88(3): 1225-1230.
- SMITH, D.L., T., SMITH, B.J., RUDE, S.H., WARD (2013): Short communication: Comparison of the effects of heat stress on milk and component yields and somatic cell score in Holstein and Jersey cows. *J. Dairy Sci.*, 96(5): 3028–3033.
- ST-PIERRE, N.R., B., COBANOV, G., SCHNITKEY (2003): Economic losses from heat stress by US livestock industries. *J. Dairy Sci.*, 86(E. Suppl.): 52–77.
- WEST, J.W. (2003): Effects of heat-stress on production in dairy cattle. *J. Dairy Sci.*, 86(6): 2131-2144.

**PROCENA GENETSKIH PARAMETARA I OPLEMENJIVAČKIH VREDNOSTI ZA
DNEVNU PROIZVODNJU MLEKA SIMENTALSKJE RASE U USLOVIMA
TOPLOTNOG STRESA**

Goran VUČKOVIĆ¹, Tina BOBIĆ², Pero MIJIĆ², Mima GAVRAN², Maja GREGIĆ²,
Klemen POTOČNIK³, Vladan BOGDANOVIĆ⁴, Vesna GANTNER²

¹Rinderunion Baden-Württemberg, Herberlingen, Nemačka

²Zavod za animalnu proizvodnju i biotehnologiju, Fakultet agrobiotehničkih znanosti Osijek,
Sveučilište Josipa Juraja Strossmayera u Osijeku, Osijek, Hrvatska

³Odeljenje za zootehniku, Biotehnički fakultet, Univerzitet u Ljubljani, Ljubljana, Slovenija

⁴Poljoprivredni fakultet, Univerzitet u Beogradu, Beograd, Srbija

Izvod

Komponente varijanse za dnevnu proizvodnju mleka kao i oplemenjivačka vrednost mlečnih krava simentalске rase za dnevnu proizvodnju mleka u uslovima toplotnog stresa definisanoj pri različitim vrednostima THI-a (72, 74 i 76) procenjene su upotrebom 1.636.192 zapisa na kontrolni dan. Temperaturno-humidni indeks (THI) izračunat na osnovu temperature okoline i relativne vlage izmerene u stajama na kontrolni dan, korišćen je kao mera toplotnog stresa. Bivarijantni model procene uvažio je varijance usled stadijuma laktacije, sezone telenja, dobu na telenju, regije uzgoja, pariteta, permanentne spoljašnje sredine, interakcije između stada i godine te pojedine životinje. Dobijena visoka genetska korelacija između dnevne proizvodnje mleka u normalnim i uslovima toplotnog stresa, kao i vrlo visoka korelacija između procenjenih oplemenjivačkih vrednosti (EBV) u normalnim i toplotno stresnim uslovima, ukazuju na visok nivo aklimatizacije životinja na spoljašnju sredinu na farmama mlečnih goveda. Budući da su merenja mikroklimе sprovedena samo jednom na kontrolni dan, ove je rezultate potrebno uzimati s oprezom. Nadalje, potrebna su dalja istraživanja s višestrukim dnevnim merenjima mikroklimatskih parametara u objektima kako bi se dobio potpuno nedvosmislen zaključak.

Primljeno 14.XI.2019.

Odobreno 18. V. 2020

Analiza proizvodnih svojstva i mikroklimatskih parametara na farmama mliječnih krava

Prošireni sažetak

Tijekom vrućih ljetnih mjeseci povećava se osjetljivost krava na toplinski stres, smanjuje se proizvodnja mlijeka i reproduktivna učinkovitost. Također je dokazano da su visokoproduktivne mliječne krave osjetljivije na toplinski stres, jer povećavanjem proizvodnje mlijeka, krave proizvode više metaboličke topline. Toplinski stres uzrokuje značajan pad financijske dobiti na farmama mliječnih krava. Toplinski stres smatra se kombinacijom temperature i vlažnosti zraka koja prelazi zonu ugone kod krava. Najčešća mjera toplinskog stresa kod mliječnih goveda je temperaturno-humidni indeks (THI) koji uključuje temperaturu okoline i relativnu vlažnost zraka. Vrijednost THI praga pri kojoj toplinski stres utječe na proizvodnju mlijeka i unos hrane varira, ovisno o studiji a kreće se od 68 do 72, a kod THI = 80 povećan je rizik od smrti kod krava. Visokoproduktivne mliječne krave gube sposobnost reguliranja tjelesne temperature na temperaturi zraka od samo 25 do 29°C, kao što i povećanje dnevne proizvodnje s 35 na 45 kg rezultira većom osjetljivošću na toplinski stres i smanjuje prag osjetljivosti za 5°C na toplinski stres. Stanje toplinskog stresa kod krava može nastati i kod nižih temperatura okoline, ako je prisutna visoka relativna vlaga zraka. Postoje brojne metode za smanjenje učinka toplinskog stresa kod mliječnih krava, a to su kratkoročne i dugoročne metode. Kratkoročne metode uključuju optimizaciju hranjenja i primjenu različitih rashladnih sustava u stajama, dok dugoročne metode podrazumijevaju odabir muznih krava koje su otpornije na toplinski stres.

Kao preduvjeti za genetsku evaluaciju i selekciju mliječnih goveda na rezistentnost na toplinski stres, ciljevi ovog rada bili su:

1. Određivanje fenotipske varijabilnosti analiziranih skupina svojstava: a. statistička analiza proizvodnih svojstava (dnevna količina i sastav mlijeka) mliječnih krava u selekciji, b. statistička analiza parametara mikrokline (ambijentalna temperatura i vlaga) u stajama;

2. Određivanje korelacije između analiziranih skupina osobina.

Za analizu varijabilnosti proizvodnih svojstava i mikroklimatskih parametara korišteni su dnevni zapisi o holstein i simentalnim mliječnim kravama uzgajanim u Hrvatskoj. Skupljanje dnevnih zapisa radilo se pri službenoj kontroli mliječnosti, jednom mjesečno, alternativnom metodom (AT4 / BT4) u razdoblju od siječnja 2005. do prosinca

2013. godine. Prilikom kontrole mlijeka je mjerena temperatura okoline i relativna vlaga u stajama, na temelju izmjerenih mikroklimatskih parametara izračunat je temperaturno-humidni indeks (THI). Nadalje, dnevni zapisi sa stadijima laktacije u (< 5 dana i > 500 dana), dob pri prvom teljenju (< 21 i > 36 mjeseci), a podaci sa nedostajućim paritetom, pasminom, ili besmislenim dnevnim svojstvima mlijeka (u skladu s ICAR standardima, 2017.), nedostajućim ili besmislenim vrijednostima Ta i RH su izbrisani iz skupa podataka. Nakon logičke provjere, skup podataka sastojao se od 1.636.192 dnevnih zapisa prikupljen od 117.659 simentalских krava (10.599 farmi) i 1.275.713 dnevnih zapisa prikupljen od 90.159 holstein krava (6.701 farme).

Krave su prema paritetu podijeljene u četiri razreda: I., II., III. i IV. (životinje u četvrtoj i višoj laktaciji). Nadalje, u skladu s lokacijom farme, dnevni zapisi podijeljeni su u tri uzgojna područja: istočno, središnje i mediteransko. U skladu s datumom prikupljanja dnevni zapisi podijeljeni su u četiri sezone prikupljanja: proljeće, ljeto, jesen i zima.

Provedene analize ukazuju na visoku varijabilnost proizvodnih svojstava s obzirom na pasminu krava, paritet kao i područje uzgoja. Također, pronađena je velika varijabilnost mikroklimatskih parametara ovisno o sezoni i području uzgoja. Nadalje, utvrđene su statistički vrlo značajne ($p < 0,001$) korelacije između proizvodnih svojstava i mikroklimatskih parametara. Konačno, utvrđen je negativni učinak neprikladne mikroklimе kod obje pasmine na dnevnu proizvodnju mlijeka u svim uzgojnim područjima.

Na temelju provedenog istraživanja, može se istaknuti negativan učinak povećanja mikroklimatskih parametara na dnevnu proizvodnju mlijeka kod svih krava bez obzira na pasminu i uzgojno područje. Budući da je genetska procjena i odabir mliječnih krava otpornih na toplinu dugoročna metoda za upravljanje toplinskim stresom, utvrđeni učinak uzeti će se u obzir u statističkom modelu za procjenu genetskih parametara i uzgojnih vrijednosti koje pridonose otpornosti na toplinu kod mliječnih krava .

Razvoj i odabir optimalnih statističkih modela za procjenu značajnosti utjecaja mikroklimatskih parametara na varijabilnost proizvodnih svojstava mliječnih krava

Prošireni sažetak

Budući da panonsko područje ima veliku pojavnost dana sa toplinskim stresom, uglavnom tijekom ljetne sezone, cilj ovog rada bio je razviti i odabrati optimalne modele za procjenu utjecaja mikroklimatskih parametara na varijabilnost proizvodnih svojstava mliječnih krava. Primjena optimalnog statističkog modela pri rutinskoj genetskoj procjeni i odabiru otpornijih životinja moglo bi pridonijeti razvoju profitabilne i održive farme mliječnih krava.

Za statističku analizu korišteni su dnevni zapisi iz redovite kontrole mliječnosti holstein i simentalčkih krava prikupljeni u razdoblju od siječnja 2005. do prosinca 2013., a njih je osigurala Hrvatska agencija za poljoprivredu i hranu. Prilikom kontrole mlijeka je mjerena temperatura okoline i relativna vlaga u stajama, na temelju izmjerenih mikroklimatskih parametara izračunat je temperaturno-humidni indeks (THI). Nadalje, dnevni zapisi su stadijima laktacije u (< 5 dana i > 500 dana), dob pri prvom teljenju (< 21 i > 36 mjeseci), a podaci su nedostajućim paritetom, pasminom, ili besmislenim dnevnim svojstvima mlijeka (u skladu s ICAR standardima, 2017.), nedostajućim ili besmislenim vrijednostima Ta i RH su izbrisani iz skupa podataka. Nakon logičke provjere, skup podataka sastojao se od 1.636.192 dnevnih zapisa prikupljen od 117.659 simentalčkih krava (10.599 farmi) i 1.275.713 dnevnih zapisa prikupljen od 90.159 holstein krava (6.701 farme). Krave su prema paritetu podijeljene u četiri razreda: I., II., III. i IV. (životinje u četvrtoj i višoj laktaciji). Nadalje, u skladu s lokacijom farme, dnevni zapisi podijeljeni su u tri uzgojna područja: istočno, središnje i mediteransko. U skladu s datumom prikupljanja dnevni zapisi podijeljeni su u četiri sezone prikupljanja: proljeće, ljeto, jesen i zima. Dok su, u skladu s datumom zapisa, dnevni zapisi podijeljeni su u 108 razreda: 1/2005. do 12/2013. Za procjenu učinka mikroklimatskih parametara (T, RH i THI) na varijabilnost proizvodnih svojstava (dnevna količina mlijeka i sastav) kod mliječnih krava razvijeno je i testirano nekoliko statističkih modela. Na temelju parametara procjene (R^2 , CV i Root MSE modela) dva su modela odabrana kao optimalna za daljnju analizu. Model 1 analizira odnos između dnevnih svojstava mlijeka (količina i sastav) i mikroklimatskih parametara (T, RH i THI) analiziran

je pomoću procedure PROC GLM iz SAS (SAS Institute Inc., 2000). Model 2 analizira varijacije u dnevnim svojstvima mlijeka (količina i sastav) zbog toplinskog stresa testiran je analizom varijance najmanjih kvadrata za postavljene vrijednosti THI (68, 72) pomoću PROC GLM / SAS. Utvrđeno smanjenje dnevne količine mlijeka i dnevni udio masti i bjelančevina uzrokovanih porastom T i THI kod obje pasmine pokazale su se statistički značajnima ($p < 0,05$). Nadalje, dnevni sadržaj uree i broj somatskih stanica povećao se zbog povećanih dnevnih vrijednosti T, RH i THI kod obje analizirane pasmine. Dnevni sadržaj laktoze pokazao je vrlo malu varijabilnost zbog varijacije u mikroklimatskim uvjetima. Analiza varijance dnevnog sastava mlijeka s obzirom na uvjete toplinskog stresa (normalno ili pod stresom: HS-0 / HS-1) pri različitim pragovima THI (68 i 72) pokazala je statistički značajnu ($p < 0,05$) razliku u svim analiziranim dnevnim svojstvima mlijeka, osim logSCC. Veća razlika između dnevne količine mlijeka proizvedene u normalnom stanju u odnosu na uvjete s toplinskim stresom utvrđena je kod holstein krava, kao i kod većih vrijednosti praga THI (72 prema 68). Nadalje, količina dnevnih varijacija sadržaja masti / proteina / laktoze i logSCC zbog toplinskog stresa bila je slična kod svih krava. Konačno, dnevni sadržaj uree pokazao je značajan ($p < 0,05$) porast kod svih krava u uvjetima toplinskog stresa sa nešto većim porastom kod simentalke pasmine pri izraženijem toplinskom stresu (viša vrijednost praga THI, THI = 72). Na temelju dobivenih rezultata moglo bi se naglasiti da je odabran optimalan statistički model koji bi se mogao koristiti kao osnova za daljnja istraživanja s ciljem procjene genetskih parametara kao i za uzgoj goveda sa većom otpornošću na toplinu.

*Genetski parametri i uzgojne vrijednosti za dnevnu proizvodnju mlijeka holstein krava u
uvjetima toplinskog stresa*

Prošireni sažetak

Kako bi se omogućila primjena dugoročne metoda mitigacije koja je jednostavna za uporabu u praksi, cilj ovoga rada bio je procijena komponente varijance kao i uzgojna vrijednost za dnevnu proizvodnju mlijeka krava holstein pasmine u uvjetima toplinskog stresa definirane kao različite vrijednosti praga temperaturno-humidnog indeksa (THI) (68, 70, i 72). THI je izračunat na osnovu izmjerene temperature i relativne vlage zraka u stajama na dan redovite kontrole mliječnosti. Dnevna proizvodnja mlijeka analizirana je kao bivarijantna varijabla u normalnim uvjetima (ispod zadanog praga THI vrijednosti) i u uvjetima toplinskog stresa (iznad zadanog praga THI vrijednosti). Skup podataka koji je ustupila Hrvatska agencija za poljoprivredu i hranu, sastojao se od 1.275.713 dnevnih zapisa od 90.159 holstein krava uzgajanih na 6.701 farmi, prikupljeni su u razdoblju od siječnja 2005. do prosinca 2013. godine.

Primijenjeni statistički model uvažio je varijabilnost uslijed stadija laktacije, sezone teljenja, dobi pri teljenju, regije uzgoja, pariteta, permanentnog okoliša, interakcije između stada i godine te pojedine životinje. U ovom istraživanju reakcija životinja na toplinski stres je analizirana bivarijantnim modelom gdje je dnevna proizvodnja mlijeka u normalnim uvjetima ($THI = 0$) uzeta kao prva varijabla, dok je dnevna proizvodnja mlijeka u okolini s toplinskim stresom ($THI = 1$) uzeta kao druga varijabla. Varijanca za trajnu okolinu kada je $THI = 0$ bila je u rasponu od 11.386 kg^2 do 11.641 kg^2 , dok se za $THI = 1$ kretala od 11.190 kg^2 do 11.841 kg^2 , ovisno o postavljenoj vrijednosti THI_{prag} . Dobiveni rezultati pokazuju da je pri višim THI vrijednostima učinak trajne okoline bio istaknutiji. Varijanca međugodišnje interakcije također se povećala kako je povećana vrijednost THI_{prag} , s većim vrijednostima varijance utvrđenim u terminima toplinskog stresa ($THI = 1$). Suprotno tome, procijenjena varijanca za životinju smanjivala se s porastom od THI_{prag} vrijednosti, s nižim vrijednostima varijance utvrđenim u uvjetima toplinskog stresa. Varijabilnost dnevne proizvodnje mlijeka zbog trajne okoline kretala se od 23,61 do 26,72%, ovisno o karakteristikama okoline. Učinak trajne okoline bio je najizraženiji u stajama s THI vrijednostima većim od 72. Varijabilnost dnevne proizvodnje mlijeka zbog međugodišnje

interakcije kretala se između 17,14% - 22,5% s najvećim udjelom varijabilnosti utvrđenim u okolini, koji karakterizira toplinski stres i pri najvišoj vrijednosti THI_{prag} . Posljednje, nasljednost za dnevnu proizvodnju mlijeka u normalnim uvjetima ($THI = 0$) kretala se između 20,16% - 20,31 %. Utvrđene vrijednosti nasljednosti u uvjetima toplinskog stresa ($THI = 1$) bile su slične i kretale su se između 20,12 i 20,30%. Dobiveni rezultati ukazuju na vrlo važnu ulogu upravljanja stadom za ublažavanje toplinskog stresa na farmama mliječnih krava. Procijenjene genetske korelacije bile su visoke i podijeljene su, ovisno o vrijednosti praga THI , od 94,35% na najnižem THI (68) do 94,87% na najvišoj analiziranoj vrijednosti THI (72). Visoke vrijednosti procijenjene genetske korelacije između dnevne proizvodnje mlijeka u normalnim uvjetima i dnevne proizvodnje mlijeka u uvjetima s toplinskim stresom pokazuju da će krave s visokim performansama u normalnim uvjetima održati jednake razine proizvodnje i u uvjetima toplinskog stresa. Srednje vrijednosti UV holstein krava za dnevnu proizvodnju mlijeka, unatoč uvjetima u okolišu, iznosile su otprilike 100,6. Uz to, srednja vrijednost UV za dnevnu proizvodnju mlijeka u normalnim uvjetima bila je najveća pri srednjoj vrijednosti THI (70), dok je u toplinski stresnim uvjetima UV imao najveću vrijednost THI (72). Korelacija UV u normalnim uvjetima i uvjetima toplinskog stresa bila je visoka i iznosila je između 98,64 i 98,91% pokazujući visoku povezanost između produktivnosti krava u normalnim uvjetima i uvjetima toplinskog stresa.

Dobiveni rezultati ukazuju na činjenicu da su krave holstein pasmine vrlo dobro aklimatizirane na okolišne uvjete na farmama mliječnih krava u Hrvatskoj. Međutim, ove rezultate treba uzeti s dozom opreza, obzirom da su mjerenja mikroklimatskih parametara u objektima provedena samo jednom na dan kontrole mliječnosti, tako da pouzdanost tih mjerenja može biti upitna. Zaključno, kako bismo utvrdili potpuno nedvosmislen zaključak, neophodna su daljnja istraživanja u kojima će se provoditi višestruka dnevna mjerenja mikroklimatskih parametara u farmskim objektima.

Procjena genetskih parametara i uzgojnih vrijednosti za dnevnu proizvodnju mlijeka simentalke pasmine krava u uvjetima toplinskog stresa

Prošireni sažetak

Cilj istraživanja bio je procijeniti komponente varijance kao i uzgojnu vrijednost za dnevnu proizvodnju mlijeka krava simentalke pasmine u uvjetima toplinskog stresa, definirane kao različite vrijednosti praga THI (72, 74, i 76). Dnevna proizvodnja mlijeka analizirana je kao bivarijantna varijabla u normalnim uvjetima (ispod zadanog praga THI vrijednosti) i u uvjetima toplinskog stresa (iznad zadanog praga THI vrijednosti). Za potrebe ovoga istraživanja korišteni su dnevni zapisi iz redovite kontrole mliječnosti (Metoda AT4 ili BT4) o simentalnim kravama uzgajanim u Hrvatskoj. Testni dnevni zapisi prikupljeni su u razdoblju od siječnja 2005. do prosinca 2013. godine. Pri svakoj kontroli mlijeka, mjerenje i uzorkovanje mlijeka provodi se tijekom večernje ili jutarnje mužnje i pri svakoj kontroli mjerena je temperatura okoliša i relativna vlažnost zraka u stajama. Nadalje, testni dnevni zapisi sa stadijem laktacije u (<5 dana i > 400 dana), gdje je dob kod prvog teljenja (<21 i > 36 mjeseci), gdje nedostaje paritet ili pasmina, nedostajuća ili besmislena dnevna svojstva mlijeka (u skladu s ICAR standardima, 2017.), nedostajuće ili besmislene Ta i RH vrijednosti izbrisane su iz skupa podataka. Nakon logičke kontrolne skup podataka sastojao se od 1.636.192 dnevnih zapisa od 117.659 simentalnih krava uzgajanih na 10.599 farmi.

U ovom istraživanju reakcija životinja na okoliš sa toplinskim stresom analizirana je bivarijantnim modelom gdje je dnevna proizvodnja mlijeka u normalnim uvjetima (THI = 0) uzeta kao prva varijabla dok je dnevna proizvodnja mlijeka u okolišu s toplinskim stresom (THI = 1) uzeta kao druga varijabla. Varijanca za trajni okoliš kada je THI = 0 bila je u rasponu od 3.627 kg² do 3.579 kg², dok se za THI = 1 kretala od 3.577 kg² do 3.670 kg², ovisno o postavljenoj vrijednosti THI prag, ukazujući na to da je pri višim THI vrijednostima učinak trajnog okoliša bio istaknutiji. Uočen je sličan trend povećanja varijance u normalnom stanju s obzirom na vrijednosti THI prag zbog varijabilnosti uslijed međudjelovanja stada i rezidualne varijance. U uvjetima toplinskog stresa (THI = 1), s obzirom na postavljenu vrijednost THI prag, uočeno je smanjenje rezidualne varijance, dok se povećala varijanca međudjelovanja stada. Procijenjena varijanca za životinju bila je nešto veća u uvjetima toplinskog stresa kao i pri višim vrijednostima postavljenog THI prag s izuzetkom kada je THI jednak 76. Varijabilnost dnevne proizvodnje mlijeka zbog trajnog

okoliša kretala se od 16,13 do 17,00%, ovisno o karakteristikama okoliša. Učinak trajnog okoliša bio je najizraženiji u stajama s $THI > 76$. Varijabilnost dnevne proizvodnje mlijeka zbog međugodišnje interakcije kretala se između 19,77% - 25,68% s najvećim udjelom varijabilnosti utvrđenim u okolišu koji karakterizira toplinski stres i pri najvišoj vrijednosti THI prag. Posljednje, heritabilitet za dnevnu proizvodnju mlijeka u normalnim uvjetima ($THI = 0$) bila je približno 23,50% dok su vrijednosti nasljednosti u uvjetima toplinskog stresa ($THI = 1$) bile više i kretale su se u rasponu od 23,78 do 24,20%. Procijenjene genetske korelacije bile su visoke i podijeljene su, ovisno o vrijednosti praga THI , od 96,13% na najnižem THI (72) do 98,09% na najvišoj analiziranoj vrijednosti THI (76). Visoke vrijednosti procijenjene genetske korelacije između dnevne proizvodnje mlijeka u normalnim uvjetima i dnevne proizvodnje mlijeka u uvjetima s toplinskim stresom pokazuju da će krave s visokim performansama u normalnim uvjetima održati jednake razine proizvodnje i u uvjetima toplinskog stresa. Srednje vrijednosti uzgojnih vrijednosti za dnevnu proizvodnju mlijeka, unatoč uvjetima u okolišu, iznosile su otprilike 100,5. Uz to, srednja vrijednost UV za dnevnu proizvodnju mlijeka u normalnim uvjetima bila najveća pri najnižoj vrijednosti THI 72, dok je u toplinski stresnim uvjetima UV imala najveću vrijednost pri najvećoj vrijednosti THI 76. Korelacija UV u normalnim uvjetima i uvjetima toplinskog stresa bila je visoka i razlikovala se između 99,48 i 99,76% pokazujući veliku vezu između produktivnosti krava u normalnim uvjetima i uvjetima toplinskog stresa.

Procijenjene su visoke genetske korelacije između dnevne proizvodnje mlijeka u normalnim uvjetima i uvjetima koje karakterizira toplinski stres, kao i vrlo visoke korelacije između procijenjenih uzgojnih vrijednosti u normalnim i toplinsko stresnim uvjetima. Ove rezultate treba uzimati s oprezom, budući da su mjerenja mikroklimatskih parametara provedena samo jednom na dan kontrole mliječnosti, pa je pitanje jesu li takvi podaci relevantni. Zaključno, da bi dobili potpuno jednoznačan zaključak, nužna su daljnja ispitivanja koja uključuju višekratna dnevna mjerenja mikroklimatskih parametara na farmama.

SAŽETAK

Svakodnevno svjedočimo sve bržim te sve izraženijim klimatskih promjenama u cijelom svijetu. Navedene će promjene rezultirati sve nepogodnijim klimatskim uvjetima za poljoprivrednu, a osobito stočarsku proizvodnju (IPCC, 2007.). Stočarski sektor, izuzev što doprinosi ukupnoj emisiji stakleničkih plinova antropogenog porijekla, sa druge strane, trpi i značajne gubitke uslijed uzrokovanih klimatskih promjena. U intenzivnoj proizvodnji mlijeka u stajskom uzgoju, kada mliječne krave većinom borave u farmskim objektima, u svrhu realizacije genetskog proizvodnog potencijala grla, moraju biti osigurani optimalni mikroklimatski uvjeti. U uvjetima visoke temperature te visoke relativne vlage u objektu krave su u toplinskom stresu što inducira smanjenje konzumacije suhe tvari te smanjenje proizvodnje mlijeka. Nadalje, mijenja se i sastav mlijeka, dolazi do porasta broja somatskih stanica i pojavnosti mastitisa, te narušavanja reproduktivnih performanci. Uslijed navedenoga, uvjeti toplinskog stresa mogu izazvati i značajne financijske gubitke u proizvodnji mlijeka. Najčešća mjera toplinskog stresa je temperaturno-humidni indeks (THI) koji predstavlja kombinaciju ambijentalne temperature i relativne vlažnosti. Postoje brojne metode smanjivanja utjecaja toplinskog stresa na mliječne krave i to kratkoročne te dugoročne. Kratkoročne metode podrazumijevaju optimizaciju hranidbe te primjenu različitih sustava hlađenja u objektima na farmi, dok dugoročne metode znače selekciju mliječnih goveda na otpornost na toplinski stres. Uvažavajući neupitnost klimatskih promjena i neizbježnost povećanja obujma ukupne stočarske te govedarske proizvodnje u Republici Hrvatskoj, proizlazi nužnost razvoja i implementacije okolišno i ekonomski održivih proizvodnih sustava.

Stoga je glavni cilj istraživanja ove doktorske disertacije bio utvrđivanje fenotipske i genetske varijabilnosti proizvodnih karakteristika mliječnih goveda uslijed toplinskog stresa te, temeljem dobivenih rezultata, razvoj metodologije genetske evaluacije mliječnih goveda na svojstvo rezistentnosti na toplinski stres. U tu svrhu realizirano je sljedeće: utvrđena je fenotipska varijabilnost proizvodnih karakteristika (dnevna količina te sastav mlijeka) mliječnih krava pod uzgojno-seleksijskim radom, te mikroklimatskih parametara (ambijentalna temperatura i vlaga) u objektima; utvrđena je povezanosti između istraživanih grupa svojstava; razvijeni su i odabrani optimalni statistički modeli za procjenu značajnosti utjecaja mikroklimatskih parametara na varijabilnost proizvodnih karakteristika mliječnih

krava; procijenjene su komponente varijance i kovarijance te uzgojna vrijednost za svojstva mliječnosti mliječnih krava u uvjetima toplinskog stresa.

Za statističku analizu korištena je baza podataka kontrole mliječnosti preuzeta je od Hrvatske agencije za poljoprivredu i hranu (HAPIH). Za analizu definiranih ciljeva korišteni su podaci kontrole mliječnosti krava holstein i simentalke pasmine prikupljeni u razdoblju od siječnja 2005. do prosinca 2013. godine. Nakon logičke kontrole baza podataka sastojala se od 1.636.192 zapisa na kontrolni dan 117.659 krava simentalke pasmine (sa 10.599 farmi) i 1.275.713 zapisa na kontrolni dan 90.159 krava holstein pasmine (sa 6.701 farmi). Za pripremu podataka, logičnu kontrolu varijabli te statističku analizu korišten je statistički paket SAS. Prilikom procjene komponenti varijance i kovarijance odabranih statističkih modela, te procjene uzgojnih vrijednosti mliječnih krava za svojstvo rezistentnosti na toplinski stres korišten je program VCE-6.

Temeljem provedene statističke analize utvrđena je varijabilnost u dnevnim svojstvima mliječnosti uslijed utjecaja pasmine, laktacije te uzgojnog područja; varijabilnost parametara mikroklima u stajama uslijed utjecaja sezone i uzgojnog područja; negativan utjecaj povećanja parametara mikroklima na dnevnu proizvodnost; analiza genetskih parametara pokazuje izraženiji učinak stalnog okruženja, višu procijenjenu varijancu za individualni utjecaj životinje pri višim vrijednostima THI-a; procijenjeni omjeri varijance i korelacije za dnevnu proizvodnju mlijeka u odnosu na definiranu vrijednost praga THI-a ukazuju na vrlo važnu ulogu upravljanja stadom u ublažavanju toplinskog stresa na mliječnim farmama; vrijednosti heritabiliteta za dnevnu proizvodnju mlijeka krava holstein pasmine u normalnim i stresnim uvjetima iznosile su oko 20%, dok su u simentalke pasmine iznosile oko 24%; procijenjene visoke genetske korelacije između dnevne proizvodnje mlijeka u normalnim uvjetima i uvjetima toplinskog stresa, kao i visoke korelacije između UV-ima u normalnim uvjetima i uvjetima toplinskog stresa, indiciraju da će mliječne krave s visokom produktivnošću u normalnom stanju održati jednaku razinu proizvodnje čak i u uvjetima toplinskog stresa. U cilju pojednostavljenja provedbe selekcije mliječnih grla na rezistentnost na toplinski stres u praksi u ovom je istraživanju dnevna proizvodnja mlijeka analizirana kao bivarijantna varijabla i to u normalnim uvjetima (ispod THI_{prag} vrijednosti), i u uvjetima toplinskog stresa (iznad THI_{prag} vrijednosti). Bivarijantna analiza znači da se za svako grlo procjenjuje UV u normalnim uvjetima te u uvjetima toplinskog stresa odnosno da uzgajivači prilikom selekcije uvažavaju onu uzgojnu vrijednost sukladno okolišnim uvjetima u farmskim objektima.

SUMMARY

Every day we are witnessing faster and more pronounced climate change worldwide. These changes will result in increasingly unfavourable climatic conditions for agricultural and, in particular, livestock production (IPCC, 2007). The livestock sector, in addition to contributing to the total greenhouse gas emissions of anthropogenic origin, on the other hand, also suffers significant losses due to climate change. In intensive milk production in stable breeding, when dairy cows mostly stay in farms, to realize the genetic production potential of the herd, optimal microclimatic conditions must be ensured. In conditions of high temperature and high relative humidity in the building, cows are under heat stress, which induces a reduction in dry matter consumption and a reduction in milk production. Furthermore, as the composition of milk changes, there is an increase in the number of somatic cells and the incidence of mastitis and impaired reproductive performance. As a result, heat stress conditions also induce significant financial losses in milk production. The most common measure of heat stress is the temperature-humidity index (THI) which is a combination of ambient temperature and relative humidity. There are numerous methods of reducing the impact of heat stress on dairy cows, both short-term and long-term. Short-term methods include optimization of feeding and the application of different cooling systems in facilities on the farm, while long-term methods mean the selection of dairy cattle for resistance to heat stress. Recognizing the unquestionability of climate change and the inevitability of increasing the volume of total livestock and cattle production in the Republic of Croatia, the necessity of developing and implementing environmentally and economically sustainable production systems arises.

Therefore, the main goal of this doctoral dissertation was to determine the phenotypic and genetic variability of production characteristics of dairy cattle due to heat stress and, based on the results, to develop a methodology for genetic evaluation of dairy cattle for heat stress resistance. For the realization of the above, the following was realized: phenotypic variability of production traits (daily yield and composition of milk) of dairy cows under breeding and selection work, and microclimatic parameters (ambient temperature and humidity) in facilities; the relationships between the analysed groups of traits were determined; optimal statistical models have been developed and selected to estimate the significance of the effect of microclimatic parameters on the variability of production traits

of dairy cows; the components of variance and covariance and the breeding value for the milk production of dairy cows under heat stress conditions were estimated.

The milk recording database taken from the Croatian Agency for Agriculture and Food (HAPIH) was used for statistical analysis. Holstein and Simmental cow milk recording data collected in the period from January 2005 to December 2013 were used to research the defined objectives. After logical control, the database consisted of 1,636,192 records on the test day of 117,659 Simmental cows (from 10,599 farms) and 1,275,713 records on the test day of 90,159 Holstein cows (from 6,701 farms). The SAS statistical package (SAS Institute Inc., 2000) was used for data preparation, logical control of variables and statistical analysis. The program VCE-6 was used to estimate the components of variance and covariance of selected statistical models, and to estimate the breeding values of dairy cows for the resistance to heat stress.

Based on the performed statistical analysis following was determined: variability in daily traits of milk production due to the effect of breed, parity and breeding area; variability of microclimate parameters in stables due to the effect of season and breeding area; the negative impact of increasing microclimate parameters on daily productivity; analysis of genetic parameters shows a more pronounced effect of the permanent environment, and higher estimated variance for individual animal effect at higher THI values; the estimated ratios of variance and correlation for daily milk production related to the defined THI threshold values indicate a very important role of herd management in alleviating heat stress on dairy farms; heritability values for daily milk production of Holstein cows under normal and stressful conditions were about 20%, while in Simmental breeds they were about 24%; estimated high genetic correlations between daily milk production under normal and heat stress conditions, as well as high correlations between UVs under normal and heat stress conditions, indicate that high-productivity dairy cows will maintain the same level of production even under conditions heat stress. To simplify the implementation of the selection of dairy cows for resistance to heat stress in routine in this study, daily milk production was analyzed as a bivariate variable in normal conditions (below THI threshold), and in conditions of heat stress (above THI threshold). Bivariate analysis means that UV is estimated for each cow under normal conditions and under conditions of heat stress, that breeders take into account the breeding value in accordance with the environmental conditions in farms.

ŽIVOTOPIS

Goran Vučković rođen je 5. lipnja 1982. godine u Bosanskom Šamcu, Bosna i Hercegovina. Maturirao je u Đakovu. Trenutno živi i radi u gradu Aalenu u Njemačkoj. Od kolovoza 2015. godine zaposlen je kao Inspektor za uzgoj u govedarstvu u firmi Rinderunion Baden-Württemberg koja je smještena u Herbertingenu. Kao primarna djelatnost mu je ocjenjivanje prvotelki sljedećih pasmina: holstein, simentalaska i smeđe govedo, te savjetovanje za najbolje moguće sparivanje krava na temelju njihovih ocjena. Zadužen je za organizaciju i sudjelovanje na aukcijama krava i teladi, te prodaju steonih junica za izvoz i sudjelovanje na sajmovima i edukacijama za uzgajivače. Na Poljoprivrednom fakultetu u Osijeku radio je kao stručni suradnik i to od siječanja 2012. do kolovoza 2015. godine. U tom je vremenu bio angažiran na pisanju stručnih i znanstvenih radova, te provedbi terenskog rada na različitim znanstvenim projektima. Jedan od projekata je bio mjerenje mikroklimatskih parametara u objektima za krave u proizvodnji mlijeka. Nakon završetka studija radio je kao tehnolog na Farmi muznih krava Mala Branjevina i to od studenog 2009. do siječnja 2012. godine, gdje je organizirao poslove na farmi te nadgledao radnike. Osim toga, vodio je evidenciju o narudžbi i potrošnje hrane te vršio ocjenu prvotelki. Nadalje, na farmi Mala Branjevina vodio je cjelokupnu reprodukciju i to od hormonalnog usklađivanja za osjemenjivanje do zasušivanja krava. U srpnju 2009. godine stekao je zvanje diplomirani inženjer poljoprivrede Općeg smjera na Poljoprivrednom fakultetu u Osijeku.

Posjeduje aktivno znanje njemačkog jezika, te engleskog na razini B1. Kao računalne vještine i kompetencije, poznaje osnove rada na računalu, i to MS Office-u (Word™, Excel™ i PowerPoint™) te se profesionalno služi ALPRO™ herd management system. Posjeduje vozačku dozvolu B kategorije.

CURRICULUM VITAE

Goran Vučković was born on June 5, 1982 in Bosanski Šamac, Bosnia and Herzegovina. He currently lives and works in the city of Aalen in Germany. Since August 2015, he has been employed as an Inspector for Cattle Breeding at Rinderunion Baden-Württemberg, located in Herbertingen. His primary activity is the evaluation of first calving cows for the following breeds: Holstein, Simmental and Brown Swiss, and consulting for the best possible cows mating based on their evaluations. Furthermore, he is in charge of organizing and participating in cows and calves' auctions, export and selling of pregnant heifers, and participating in fairs and training for breeders. From January 2012 to August 2015, he worked at the Faculty of Agriculture in Osijek as an expert associate. During that period, he was engaged in writing professional and scientific papers and conducted fieldwork on various scientific projects. One of the conducted projects was the measurement of microclimatic parameters in facilities for dairy production. After graduating, he worked as a technologist at the Mala Branjevina dairy farm from November 2009 until January 2012, where he organized work and supervised the farmworkers. In addition, he was charged for first calving cows linear scoring, and keeping food orders and consumption records. Furthermore, on the Mala Branjevina farm, he led the entire reproduction, from hormonal adjustment for insemination to drying of the cow. In July 2009, he acquired the title, graduate agricultural engineer of the General course at the Faculty of Agrobiotechnical Sciences Osijek.

He has an active knowledge of German and English at the B1 level. As computer skills and competencies, he possesses basic computer knowledge, namely MS Office (Word TM, Excel TM and PowerPoint) and professionally uses the ALPRO herd management system. He has a category B driver's license.

