Primjena vegetacijskih indeksa u kvalitativnom zoniranju vinograda i povećanju ekonomičnosti vinogradarske proizvodnje

Rendulić Jelušić, Ivana

Doctoral thesis / Disertacija

2022

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:204:947360

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

Repository / Repozitorij:

Repository Faculty of Agriculture University of Zagreb

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

Sveučilište u Zagrebu

AGRONOMSKI FAKULTET

Ivana Rendulić Jelušić

PRIMJENA VEGETACIJSKIH INDEKSA U KVALITATIVNOM ZONIRANJU VINOGRADA I POVEĆANJU EKONOMIČNOSTI VINOGRADARSKE PROIZVODNJE

DOKTORSKI RAD

Zagreb, 2022.

University of Zagreb

FACULTY OF AGRICULTURE

Ivana Rendulić Jelušić

USE OF SPECTRAL VEGETATION INDICES FOR VINEYARD QUALITY ZONAL MANAGEMENT AND ENHANCEMENT OF GRAPEVINE PRODUCTION ECONOMIC EFFICIENCY

DOCTORAL THESIS

Zagreb, 2022.

Sveučilište u Zagrebu

AGRONOMSKI FAKULTET

Ivana Rendulić Jelušić

PRIMJENA VEGETACIJSKIH INDEKSA U KVALITATIVNOM ZONIRANJU VINOGRADA I POVEĆANJU EKONOMIČNOSTI VINOGRADARSKE PROIZVODNJE

DOKTORSKI RAD

Mentori:

Prof.dr.sc. Marko Karoglan

Izv.prof.dr.sc. Branka Šakić Bobić

Zagreb, 2022.

University of Zagreb

FACULTY OF AGRICULTURE

Ivana Rendulić Jelušić

USE OF SPECTRAL VEGETATION INDICES FOR VINEYARD QUALITY ZONAL MANAGEMENT AND ENHANCEMENT OF GRAPEVINE PRODUCTION ECONOMIC EFFICIENCY

DOCTORAL THESIS

Supervisors:

Prof.dr.sc. Marko Karoglan

Izv.prof.dr.sc. Branka Šakić Bobić

Zagreb, 2022.

Bibliografska stranica

Bibliografski podaci:

- Znanstveno područje: Biotehničko područje
- Znanstveno polje: Poljoprivreda (Agronomija)
- Znanstvena grana: Vinogradarstvo i vinarstvo
- Institucija: Sveučilište u Zagrebu Agronomski fakultet
- Voditelji doktorskog rada: prof.dr.sc. Marko Karoglan i izv.prof.dr.sc. Branka Šakić Bobić
- Broj stranica: 239
- Broj slika: 41
- Broj tablica: 77
- Broj grafikona: 6
- Broj priloga: 1
- Broj literaturnih referenci: 143
- Datum obrane doktorskog rada: 16.12.2022.
- Sastav povjerenstva za obranu doktorskog rada:

    1. prof.dr.sc. Bernard Kozina, Sveučilište u Zagrebu Agronomski fakultet
    2. prof.dr.sc. Saša Žiković, Sveučilište u Rijeci Ekonomski fakultet
    3. izv.prof.dr.sc. Monika Zovko, Sveučilište u Zagrebu Agronomski fakultet
    4. izv.prof.dr.sc. Josip Juračak, Sveučilište u Zagrebu Agronomski fakultet
    5. izv.prof.dr.sc. Darko Preiner, Sveučilište u Zagrebu Agronomski fakultet

Rad je pohranjen u:

- Nacionalnoj i sveučilišnoj knjižnici u Zagrebu, Ulica Hrvatske bratske zajednice 4, p.p. 550, 10 000 Zagreb,
- Knjižnici Sveučilišta u Zagrebu Agronomskog fakulteta, Svetošimunska 25, 10 000 Zagreb

Tema rada prihvaćena je na sjednici Fakultetskog vijeća Sveučilišta u Zagrebu Agronomskog fakulteta, održanoj dana 03. studenoga 2020. godine te odobrena na 8. redovitoj elektroničkoj sjednici Senata Sveučilišta u Zagrebu, održanoj dana 16. ožujka 2021. u 352. akademskoj godini (2020./2021.)(Klasa: 643-03/21-08/13; Ur.broj: 380-130/134-21-2).

SVEUČILIŠTE U ZAGREBU
AGRONOMSKI FAKULTET

IZJAVA O IZVORNOSTI

Ja, **Ivana Rendulić Jelušić**, izjavljujem da sam samostalno izradila doktorski rad pod naslovom:

PRIMJENA VEGETACIJSKIH INDEKSA U KVALITATIVNOM ZONIRANJU VINOGRADA I POVEĆANJU EKONOMIČNOSTI VINOGRADARSKE PROIZVODNJE

Svojim potpisom jamčim:

- da sam jedina autorica ovoga doktorskog rada;
- da je doktorski rad izvorni rezultat mojeg rada te da se u izradi istoga nisam koristila drugim izvorima osim onih koji su u njemu navedeni;
- da sam upoznata s odredbama Etičkog kodeksa Sveučilišta u Zagrebu (Čl. 19).

Zagreb, 16. prosinca 2022.

Ivana Rendulić Jelušić

Ocjena doktorskog rada

Ovaj doktorski rad ocijenilo je povjerenstvo u sastavu:

1. Prof.dr.sc. Bernard Kozina
redoviti profesor u trajnom zvanju Agronomskog fakulteta Sveučilišta u Zagrebu
2. Prof.dr.sc. Saša Žiković
redoviti profesor u trajnom zvanju Ekonomskog fakulteta Sveučilišta u Rijeci
3. Izv.prof.dr.sc. Monika Zovko
izvanredna profesorica Agronomskog fakulteta Sveučilišta u Zagrebu
4. Izv.prof.dr.sc. Josip Juračak
izvanredni profesor Agronomskog fakulteta Sveučilišta u Zagrebu
5. Izv.prof.dr.sc. Darko Preiner
izvanredni profesor Agronomskog fakulteta Sveučilišta u Zagrebu

Doktorski rad obranjen je na Agronomskom fakultetu Sveučilišta u Zagrebu, 16.12.2022. godine pred povjerenstvom u sastavu:

1. Prof.dr.sc. Bernard Kozina

_____

redoviti profesor u trajnom zvanju Agronomskog fakulteta Sveučilišta u Zagrebu

2. Prof.dr.sc. Saša Žiković

_____

redoviti profesor u trajnom zvanju Ekonomskog fakulteta Sveučilišta u Rijeci

3. Izv.prof.dr.sc. Monika Zovko

_____

izvanredna profesorica Agronomskog fakulteta Sveučilišta u Zagrebu

4. Izv.prof.dr.sc. Josip Juračak

_____

izvanredni profesor Agronomskog fakulteta Sveučilišta u Zagrebu

5. Izv.prof.dr.sc. Darko Preiner

_____

izvanredni profesor Agronomskog fakulteta Sveučilišta u Zagrebu

Informacije o mentorima

Mentor: Prof.dr.sc. Marko Karoglan

Marko Karoglan rođen je 24. rujna 1976. godine u Dubrovniku. Nakon završetka „Opće gimnazije" u Dubrovniku 1995. godine, upisuje Agronomski fakultet Sveučilišta u Zagrebu, smjer „Voćarstvo, vinogradarstvo i vinarstvo". Diplomirao je 2000. godine na istom Fakultetu, na Zavodu za vinogradarstvo i vinarstvo gdje iste godine počinje i raditi u svojstvu znanstvenog novaka. Odmah upisuje i poslijediplomski studij na Agronomskom fakultetu, smjer Bilinogojstvo. Magistarski rad naslova „Utjecaj djelomične defolijacije na dozrijevanje grožđa i kakvoću vina cv. Traminac mirisavi (Vitis vinifera L.)" obranio je 17.12.2004. godine. Doktorsku disertaciju naslova „Utjecaj dušične gnojidbe na kemijski sastav mošta i vina sorti Graševina, Chardonnay i Rizling rajnski (Vitis vinifera L.)" obranio je 18.06.2009. godine.
U znanstveno-nastavno zvanje docenta izabran je 15. lipnja 2011., a u znanstveno-nastavno zvanje izvanrednog profesora 5. travnja 2017. godine. U sadašnjem sustavu obrazovanja aktivno sudjeluje kao nositelj ili suradnik na modulima „Vinogradarstvo 2", „Osnove voćarstva i vinogradarstva", „Osnove vinogradarstva" i „Predikatna, pjenušava i specijalna vina" na preddiplomskom studiju (Bs), te „Tehnologija proizvodnje grožđa", „Table grapes production" i „Proizvodnja stolnog grožđa" na diplomskom studiju (Ms). Suradnik je na poslijediplomskom doktorskom studiju Poljoprivredne znanosti na modulu „Ampelofiziologija".
Od trenutka zapošljavanja aktivno sudjeluje u znanstveno–istraživačkom radu te popularizaciji struke. Bio je voditelj završenog projekta Ministarstva poljoprivrede, ribarstva i ruralnog razvoja RH (MPRRR): «Muškat ruža porečka - desertno vino», te više stručnih projekata. Sudjelovao je u realizaciji više znanstvenih projekata kao što su „Vinogradarstvo i klimatske promjene na području Hrvatske", „Potencijal polifenolnih spojeva sorti vinove loze", „Ampelografska i genetička evaluacija autohtonih sorata vinove loze" te „Solarizacija vinove loze". Osim toga, sudjeluje u provedbi europskih kompetitivnih projekata „Procjena tolerantnosti hrvatske germplazme vinove loze na sušu i „CroViZone – Prilagodba vinogradarskih zona RH klimatskim promjenama".
Od 2006. godine član je Povjerenstva za organoleptičko ocjenjivanje vina i voćnih vina. Član je Stručne skupine u Potkomisiji OIV-a (Organization International du Vigne et du Vin) za stolno i sušeno grožđe i nefermentirane proizvode, Komisije za vinogradarstvo. Član je Hrvatskog enološkog društva i Hrvatskog agrometeorološkog društva.
Aktivno se služi engleskim, a pasivno francuskim jezikom.

Mentor: Izv.prof.dr.sc. Branka Šakić Bobić

Branka Šakić Bobić rođena je 1978. godine u Zagrebu, gdje je pohađala osnovnu školu i opću gimnaziju u kojoj je maturirala 1996. godine s odličnim uspjehom. Diplomirala je na Agronomskom fakultetu Sveučilišta u Zagrebu, usmjerenje Bilinogojstvo, smjer Agrarna ekonomika 2004. godine. Od listopada 2004. godine zaposlena je na Zavodu za upravu poljoprivrednog gospodarstva (danas Zavod za menadžment i ruralno poduzetništvo) Agronomskog fakulteta Sveučilišta u Zagrebu kao asistentica. Kao asistentica sudjeluje u izvođenju nastave na preddiplomskim i diplomskim studijima Agronomskog fakulteta, sudjeluje u znanstvenim i stručnim projektima te se usavršava u zemlji i inozemstvu. MBA specijalistički poslijediplomski studij Poslovno upravljanje u agrobiznisu završava 2007. godine. Doktorsku disertaciju pod naslovom „Model poslovnog odlučivanja u sustavu proizvodnje krava-tele prema troškovnoj analizi“ obranila je 19. ožujka 2013. U rujnu 2013. godine izabrana je u suradničko zvanje višeg asistenta, u prosincu 2013. godine u znanstveno zvanje znanstvenog suradnika, u svibnju 2016. u znanstveno-nastavno zvanje docentica, u lipnju 2019. u znanstveno zvanje višeg znanstvenog suradnika, a u studenom 2021. u znanstveno-nastavno zvanje izvanredna profesorica.
Nositeljica je predmeta *Uvod u mikroekonomiju* preddiplomskog studija Agrarna ekonomika, predmeta diplomskih studija Agrobiznis i ruralni razvitak (*Projektni menadžment i projekti u agrobiznisu*) i Obnovljivi izvori energije u poljoprivredi (*Osnove bioekonomije*), te predmeta doktorskog studija Poljoprivredne znanosti *Teorija troškova.* Uz nositeljstva, suradnica je na preddiplomskim predmetima: *Osnove troškova i kalkulacija u poljoprivredi, Računovodstvo u poljoprivredi, Upravljanje farmom, Osnove agroekonomike, Agroekonomika u zaštiti bilja, Agroekonomika u animalnoj proizvodnji, Ekonomika nabave i korištenja poljoprivredne tehnike;* na diplomskim predmetima: *Financijski menadžment u agrobiznisu, Upravljanje troškovima u agrobiznisu, Studiji slučaja u agrobiznisu, Projektni menadžment energetskih kultura i gospodarenja otpadom u poljoprivredi,* a sudjeluje i u izvođenju nastave na engleskom jeziku na predmetima *Project Management and Projects at Agribusiness* (nositeljica), te *Financial management in agribusiness* (suradnica) te na poslijediplomskom specijalističkom studiju Poslovno upravljanje u agrobiznisu (MBA) na predmetima: *Corporate finance, Introduction into Business Reporting, Managerial Accounting i Thesis project consultation.* Sudjeluje u izvođenju nastave na sveučilišnom interdisciplinarnom poslijediplomskom specijalističkom studiju *Priprema i provedba EU projekata* na predmetu *Održivi razvoj.*
Samostalno i u koautorstvu objavila je preko 100 znanstvenih i stručnih radova, sudjelovala u više domaćih i međunarodnih znanstvenih skupova i projekata, te bila mentorica na preko 50 završnih, diplomskih, doktorskih radova te stručnih studentskih projekata.
Od 2015.-2021. godine bila je voditeljica diplomskog studija *Agrobiznis i ruralni razvitak*, a od 2021. godine je predstojnica *Zavoda za menadžment i ruralno poduzetništvo.* Članica je vijeća preddiplomskog studija *Agrarna ekonomika* i diplomskog studija *Agrobiznis i ruralni razvitak*, te ISVU koordinator na ustanovi. Članica je Fakultetskog vijeća od 2017., Vijeća biotehničkog područja (2017.-2021.), uredničkog odbora znanstvenog časopisa Journal of Central European Agriculture (JCEA) od 2016.-2021., Ocjenjivačkog odbora za ocjenjivanje lokalne razvojne strategije LAG-ova koji će se sufinancirati kroz Mjeru 202 – „Priprema i provedba lokalnih strategija ruralnog razvoja“ unutar IPARD programa od 2013., Nacionalnog FADN odbora pri Ministarstvu poljoprivrede od 2016., Odbora za ruralni razvoj i tehnološke inovacije pri HPK od 2020., Hrvatskog agroekonomskog društva od 2004.
Aktivno govori engleski, te pasivno francuski i njemački jezik.

Zahvala

Željela bih zahvaliti svima koji su bili uz mene na ovom dinamičnom putovanju u svijet znanosti i istraživanja.

Na samom početku mog profesionalnog i znanstvenog puta, pun vjere da je to dobar put za mene, bio je mr.sc. Josip Kraljičković, pročelnik Upravnog odjela za poljoprivredu, ruralni razvitak i šumarstvo Zagrebačke županije, koji je uz naš zajednički posao u Zagrebačkoj županiji i vješto mentorstvo šefa i učitelja zaslužan što sada pišem ovu zahvalu. Znanstveni put bio je duži nego li smo očekivali, ali stečena znanja su vrijedna truda i veliki zalog za budućnost. Hvala Vam na pomoći, poticanju i uvjerenju da se sve može postići trudom i radom.

Hvala Zagrebačkoj županiji i županu mr.sc. Stjepanu Kožiću, koji je uvijek spreman pomoći u provedbi i financiranju znanstvenih istraživanja koja doprinose boljitku poljoprivrednih proizvođača, što je bio slučaj i s mojim istraživanjem koje je provedeno na području Zagrebačke županije i financirano sredstvima Zagrebačke županije.

Hvala kolegama i vinarima Tomac, Šember, Kos i Puhelek-Purek koji su bili spremni sudjelovati u istraživanju i omogućili nam kvalitetnu provedbu istraživanja u svojim vinogradima, ali i lijepa druženja uz svoja vina po završetku terenskog posla.

Hvala svim profesorima i kolegama s Agronomskog fakulteta koji su sudjelovali na mom znanstvenom putu. Posebno zahvaljujem prof.dr.sc. Bernardu Kozina za nesebičnu stručnu i ljudsku podršku, a koju imam još od studija i diplomskog rada. Zahvaljujem i prof.dr.sc. Nikoli Miroševiću, prof.dr.sc. Jasminki Karoglan Kontić, prof.dr.sc. Ediju Maletiću, prof.dr.sc. Zoranu Grgiću, prof.dr.sc. Ani Jeromel, izv.prof.dr.sc Ana Mariji Jagatić Korenika i izv.prof.dr.sc. Josipu Juračaku. Posebno hvala kolegicama i prijateljicama dr.sc. Mireli Osrečak, dr.sc. Ivani Puhelek, Marini Anić, dipl.ing., kolegama Aleksandru Brodskom, dipl.ing. i doc.dr.sc. Marinu Mihaljeviću Žulju što su bili vrhunska i zabavna „ekipa za odraditi posao“ u svim terenskim istraživanjima.

Puno hvala prof.dr.sc. Saši Žikoviću s Ekonomskog fakulteta u Rijeci koji je svojim bogatim ekonomskim znanjem usmjerio i moje istraživanje na moguće investicije u pametnom vinogradarstvu, a svojim jednostavnim ljudskim pristupom učinio ekonomiju razumljivom i zanimljivom, čak i meni.

Posebno hvala mojim mentorima prof.dr.sc. Marku Karoglanu i izv.prof.dr.sc. Branki Šakić Bobić koji su svojim znanstvenim i stručnim doprinosom usmjerili moje istraživanje, ali i uvijek bili na raspolaganju za sva pitanja, nedoumice i savjete- znanstvene i prijateljske.

Veliku zahvalu za nesebično dijeljenje svojih stručnih znanja i česte razgovore o mom radu umjesto prijateljske kave, dugujem prijateljicama mr.sc. Sandri Žager i Mirni Krivokuća te kolegi Zoranu Tonkoviću bez čije pomoći bih još uvijek svladavala osnove GIS-a. Hvala svim mojim prijateljima i kumovima, posebice Lidiji Baliji i mr.sc. Gordani Matašin, koje su me već odavno od milja okitile ovom titulom i time mi samo dale snagu da ovaj dio školovanja privedem kraju.

Životno hvala ide mojim roditeljima Mariji i Petru, koji su vjerovali i očekivali da će doći i ovaj dan te su svojom nesebičnom roditeljskom podrškom ispratili sve godine mog školovanja. Hvala mojoj sestri Ani i šogoru Dženanu te mojoj obitelji Jelušić za veliku podršku na ovom putu.

I na kraju, ali najvažnije, najveću zahvalnost za strpljenje, razumijevanje, podršku i neprekidni poticaj za uspjeh dugujem suprugu Tinu i sinu Lovri koji su najviše osjetili sate i sate provedene uz računalo uz sve veće hrpe papira po stanu. Lovro se i dan danas pita koga to mama misli liječiti i od samog spomena riječi na „d“ nije mu svejedno. Dečki moji, hvala vam! Volim vas!

SAŽETAK

Digitalizacija vinogradarske proizvodnje u posljednjih tridesetak godina doprinosi brzom razvoju novih tehnologija za praćenje proizvodnje, ali i prihvaćanju i usvajanju novih spoznaja vezanih uz varijabilnost vinograda i mogućnost iskorištavanja varijabilnosti za povećanje ekonomske učinkovitosti proizvodnje. Korištenjem bespilotnih letjelica opremljenih multispektralnim kamerama te analizom podataka putem vegetacijskih indeksa moguće je donositi kvalitetnije odluke za upravljanje vinogradarskom proizvodnjom, ali i maksimizirati učinke proizvodnje u agronomskom, enološkom i ekonomskom smislu. Cilj ovog istraživanja bio je utvrditi povezanost vegetacijskih indeksa (NDVI, NDRE, OSAVI) sa svojstvima vinove loze i grožđa kako bi se učinkovito identificirale dvije različite kvalitativne zone grožđa unutar istog vinograda, s ciljem selektivne berbe grožđa i povećanja prihoda od vinogradarske i vinarske proizvodnje.
Istraživanje je provedeno tijekom 2019. i 2020. godine na području Zagrebačke županije na četiri različite lokacije i četiri različite površine vinograda manje od 1 ha (0,33 ha; 0,47 ha; 0,65 ha i 0,93 ha). U istraživanje su bile uključene dvije sorte vinove loze- 'Kraljevina' (*Vitis vinifera* L.) u vinogorju Zelina i 'Pinot crni' (*Vitis vinifera* L.) u vinogorju Plešivica-Okić. Podaci su prikupljani bespilotnom letjelicom opremljenom multispektralnom kamerom u tri različite fenofaze razvoja vinove loze te obrađeni i analizirani u ArcGIS programskom paketu. Provedeno je i ručno uzorkovanje i mjerenje sastavnica prinosa i kvalitativnih svojstava grožđa na unaprijed odabranim ciljanim trsovima. Podaci su analizirani postupcima deskriptivne, inferencijalne te multivarijatne statistike, kako bi se dobio najprediktivniji vegetacijski indeks za kvalitativno zoniranje vinograda na svakoj lokaciji i u obje godine. Metodom ankete i desk istraživanja prikupljeni su podaci za analizu ekonomske opravdanosti ulaganja u kvalitativno zoniranje i selektivnu berbu te su izrađene financijske analize investicije za dva moguća scenarija- samostalna i uslužna provedba kvalitativnog zoniranja.
Rezultati istraživanja mogućnosti primjene vegetacijskih indeksa za kvalitativno zoniranje vinograda pokazali su kako su vegetacijski indeksi učinkovit alat za procjenu bujnosti i varijabilnosti u vinogradu te kako uspješno opisuju i povezuju sastavnice prinosa i kvalitativna svojstva grožđa s rezultatima spektralnih mjerenja. NDVI kao najviše korišten vegetacijski indeks u dosadašnjim istraživanjima i u se ovom istraživanju pokazao najprediktivnijim vegetacijskim indeksom za određivanje zona bujnosti i kvalitativno zoniranje vinograda. NDRE, iako vrlo skromno korišten u dosadašnjim istraživanjima za određivanje zona bujnosti i kvalitativno zoniranje vinograda u ovom istraživanju pokazao se dovoljno prediktivnim za praktične svrhe provedbe selektivne berbe u vegetacijskoj sezoni u kojoj se prikupljaju podaci. S obzirom na termin prikupljanja podataka za kvalitativno zoniranje putem vegetacijskih indeksa NDVI i NDRE, potrebno je višegodišnje praćenje određenog vinograda i analiza mogućih interakcija u samom vinogradu kako bi se definirao termin prikupljana podataka za učinkovito kvalitativno zoniranje i selektivnu berbu. OSAVI, kao najmanje korišten vegetacijski indeks u dosadašnjim istraživanjima i u ovom se istraživanju pokazao najmanje prediktivan, odnosno niti u jednom terminu prikupljanja podataka kao niti na jednoj lokaciji provedbe istraživanja, OSAVI nije bio najprediktivniji vegetacijski indeks za određivanje zona bujnosti i kvalitativno zoniranje vinograda. Primjena vegetacijskih indeksa kao osnove za kvalitativno zoniranje vinograda i selektivnu berbu grožđa u vinogradima do 1ha, s ciljem proizvodnje dva različita tipa „super premium“ vina od iste sorte grožđa i iz istog vinograda, može dovesti do povećanja financijske koristi za vinogradara. Dodatno, utvrđeno je da se korištenje usluge specijalizirane tvrtke za snimanje bespilotnom letjelicom i obradu i analizu prikupljenih podataka pokazuje financijski isplativijim rješenjem od ulaganja u opremu i samostalnog provođenja kvalitativnog zoniranja od strane vinogradara.

Ključne riječi: kvalitativno zoniranje; bespilotna letjelica; multispektralna kamera; vegetacijski indeksi; NDVI; NDRE; OSAVI; selektivna berba; ekonomska opravdanost; uslužno snimanje.

EXTENDED SUMMARY

USE OF SPECTRAL VEGETATION INDICES FOR VINEYARD QUALITY ZONAL MANAGEMENT AND ENHANCEMENT OF GRAPEVINE PRODUCTION ECONOMIC EFFICIENCY

The digitization of viticulture in the last thirty years contributes to the rapid development of new technologies for monitoring production and the acceptance and adoption of new knowledge about the variability of vineyards and the possibility of using variability to increase the economic efficiency of production. The uniform vineyard management can be justified by the simplicity of carrying out all vineyard operations as long as the winegrower is satisfied with the final grape quality. Identifying different quality zones based on variations within the vineyard can allow winegrowers to obtain higher revenues from grape growing and wine production. By using unmanned aerial vehicles (UAV) equipped with multispectral cameras and analysing the collected data using vegetation indices, it is possible to make better decisions for differentiated vineyard management, maximizing the agronomic, oenological and economic impact of viticulture production. The main objective of this study was to determine the most predictive vegetation index for grape quality zoning, among three different vegetation indices (NDVI, NDRE, and OSAVI) at three different grapevine growth stages, which can be efficiently used in commercial vineyards for selective harvesting and the production of different wine types. In addition, an economic analysis of the costs and revenues of implementing grape quality zoning and selective harvesting in small vineyards (up to 1 ha) was performed, along with the calculations of the potential revenue increases after selective harvesting and production of different wine types from the same grapevine variety and vineyard.

The first chapter, *Introduction,* focuses on the problem description and presents the main aspects of quality zonal management and the main hypotheses and objectives of the study. The hypotheses that were established and tested in this study are: (1) there is a difference in the relationship between vegetative indices (NDVI, NDRE, OSAVI) and vigour at three different grapevine growth stages (GS) for two grapevine varieties; (2) there is a relationship between different vigour zones and vegetative, yield, and grape quality components; (3) there is economic justification for using vegetative indices for vineyard quality zonal management and selective harvesting in vineyards up to 1 ha.

The second chapter *Overview of the Previous Research* focuses on related previous research on vineyard variability, precision viticulture, remote sensing, vegetation indices, vineyard quality zonal management and relevant studies on the economic efficiency of precision viticulture. The main reason for studying vineyard variability is its influence on grape yield and quality. Variability can be caused by various factors (natural factors, human actions, factors beyond control, etc.), but regardless of its source, monitoring and managing of variability has the goal of helping winegrowers to achieve the greatest possible efficiency in viticulture production. In order to monitor the different parameters and the related changes in the vineyard throughout the growing season, many new tools and technologies are being developed and used in viticulture. There are two main groups of technologies that are being used: data-intensive technologies and automated technologies, which are differentiated according to the main outcomes that result from the use of each technology. Data-intensive technologies, such as vigour and yield monitoring and mapping, soil condition mapping, and environmental data collection can improve understanding of the factors causing variability, but also require additional skills to use the technologies effectively and it is much more difficult to estimate economic efficiency. Much research has been done on the capabilities of UAVs. UAVs have been used to assess grape yield and quality, water stress, photosynthetic activity, disease, pest and weed incidence, but also to detect missing vines, estimate vine height, estimate damage caused by flooding and drought, etc. In the last twenty years, much research has been done with vegetation indices (mainly NDVI), and these spectral vegetation measurements have been used to describe vine and grape characteristics such as vigour, yield, grape quality,

health status, etc. Previous research has shown that vegetation indices can be good predictive tools for vigour-based quality management zones and for assessing vineyard variability. Some of the most commonly used vegetation indices in viticulture are NDVI, NDRE, and OSAVI. The relationship between vigour zones and yield and grape quality components has been confirmed in many previous studies, which showed that high vigour zones delineated mainly with NDVI had higher yield per vine, lower sugar concentration, and higher total titratable acidity than vines from low or medium vigour zones. Selective harvesting is defined as the split-picking of grapes at harvest according to different yield/quality criteria with the aim of producing different products to take advantage of the observed variability in vineyard performance. In the economic analysis, the investment in the new technology must be considered in relation to the expected benefits for the winegrowers. The potential profitability of precision farming can only be evaluated in comparison to management without precision farming. The economic aspect of selective harvesting mainly refers to the differentiation of grapes from different quality zones with different future wine prices.

The third chapter *Materials and Methods* focuses on all the information on how the research was conducted. The research was conducted in 2019 and 2020 in the area of Zagreb County in four different locations and on four different vineyard areas of less than 1 ha (0.33 ha, 0.47 ha, 0.65 ha and 0.93 ha). Two grapevine varieties were included in the study - 'Kraljevina' (*Vitis vinifera* L.) in the Zelina winegrowing region and 'Pinot noir' (*Vitis vinifera* L.) in the Plešivica winegrowing region. Using a UAV DJI Inspire 1 Pro equipped with a multispectral camera (Micasense RedEdge.MXTM, Seattle, WA, USA) multispectral images were acquired each year at the experimental sites at three different grapevine GS: berries beginning to soften, Brix starts increasing (GS 34); berries with intermediate Brix values (GS 36); and berries harvest-ripe (GS 38). After each flight, images were processed using ATLAS MicaSense app (MicaSense, Seattle, DC, USA), Pix4D software package (Pix4D, Lausanne, Switzerland) and ArcGIS software package (Environmental Systems Research Institute (ESRI) (2012), ArcGIS Release 10.1, Redlands, CA, USA). Interpolated maps representing two vigour zones using NDVI, NDRE, or OSAVI were generated for each site and flight and used for subsequent statistical analyses. Manual sampling and measurements of yield and grape quality components were performed on pre-selected target vines. The number of target vines was determined according to the area of vineyard. Each target vine was assigned to a vigour zone (high or low) based on the two zones previously defined. In addition, for each map created, the percentage of vineyard area in low and high vigour zones was calculated to allow for economic efficiency calculations for grape quality zoning and selective harvesting based on the vegetation indices. The collected grape quality components were subjected to a clustering procedure at each site and in each year, with the *K-means clustering* procedure set for two clusters. In this way, two different grape quality clusters (clusters of better and inferior grape quality) were obtained and used for comparison with the target vine vigour zone structures (categorical variable) based on NDVI, NDRE, and OSAVI vigour maps at three different grapevine GSs. The target vines belonging to the low vigour zone (green in vigour maps) were characterised with better grape quality components, while the target vines belonging to the high vigour zone (red in vigour maps) were characterised with inferior grape quality components. The vegetative index whose classification structure of target vines vigour (categorical variable) most closely matched the cluster structure of determined grape quality was considered the most predictive. Using the survey method and secondary desk research, data were collected for the analysis of the economic efficiency of investment in quality zonal management and selective harvesting. Financial analyses of the investment for two scenarios: the winegrower performing quality zonal management himself and the winegrower as a user of a commercial service for quality zonal management.

In the chapters *Results* and *Discussion,* all the research results are presented and discussed: interpolated maps for each site, each vegetation index, each GS and both years; results of the clustering procedure and of the overlap between two classification structures (vigour and grape quality) for the most predictive vegetation index, together

with the descriptive statistical analysis and the results of testing the statistical significance of the differences between the two vigour zones based on the most predictive vegetation index. Finally, the results of the economic efficiency and financial analysis are presented. All costs (fixed and variable) and potential revenues from grape and wine production after selective harvesting were calculated. Investment analysis were prepared for all sites and two possible scenarios, profit or loss statements and relevant financial criteria for investment analysis were calculated (NPV, IRR, payback period, discounted payback period, mIRR). A two-year study on the possibility of using three different vegetation indices- NDVI, NDRE and OSAVI- for grape quality zoning has shown that they are effective tools for assessing vigour and variability in small vineyards in Zagreb County and that they can successfully describe yield and grape quality components and link them to the results of spectral measurements. However, there are differences in the effectiveness of estimating the relationship between vigour, yield, and grape quality components depending on the vegetation index used and the grapevine's GS. The NDVI as the most commonly used vegetation index in previous studies, in this study also proved to be the most predictive for delineating vigour zones and grape quality zoning of vineyards. NDVI was the most predictive vegetation index four times (out of seven) and at all sites. In addition, the percentage of overlap of classification quality structures was 81%-93%, making it the most predictive vegetation index for quality zoning. Further research is needed to determine the ideal time period for UAV data acquisition depending on climatic conditions during the growing season. Although NDRE has been used very modestly in previous studies for delineating vigour zones and grape quality zoning of vineyards, it proved to be the most predictive vegetation index three times (out of seven) at three sites. At these sites, NDRE successfully delineated grape quality zones at later grapevine GSs, and the zones were statistically significant. It can be said that the use of NDRE for grape quality zoning of vineyards is sufficiently predictive for purposes such as selective harvesting in the growing season in which the data are collected. OSAVI, the least used vegetation index in previous studies, was also found to be the least predictive in this study for delineating vigour zones and grape quality zoning of vineyards. OSAVI was not the most predictive at any grapevine GS or any study site. These results are consistent with previous studies in which OSAVI was used primarily to estimate the nitrogen content in grapevines for targeted nitrogen fertiliser applications. The potential economic efficiency of grape quality zoning and selective harvesting was evident in this study. The potential sales revenue from the production of "super-premium" wines after selective harvest was 14% to 45% higher than the total revenue that could be generated from the production of "quality" wines at all sites. Considering that all the wineries are small, family-owned boutique wineries and the selling prices of their wines were above average, the important finding is that they can use high- and low-quality zones to produce two types of "super-premium" wines. In terms of investment, both grape quality zoning scenarios (A- the winegrower performs grape quality zoning himself, B- the winegrower uses a commercial service for grape quality zoning) resulted in potentially higher profits and the financial criteria suggested that this would be an investment that can bring higher profits in a very short payback period, despite the higher costs required to implement grape quality zoning and selective harvesting. Using a commercial service provider for grape quality zoning resulted in even higher potential profits and lower risks for the winegrower.

It can be concluded that vegetation indices NDVI and NDRE are effective tools for vineyard quality zonal management and can enhance the economic efficiency of viticulture through selective harvesting and the production of two types of "super-premium" wines from small vineyard areas up to 1 ha. Further research could be considered for the use of OSAVI on images where row segmentation has already been done and where grapevine vegetation and soil data are already separated. In addition, the ideal UAV data acquisition period for grape quality zoning still needs to be studied.

Keywords: quality zoning; UAV; multispectral camera; vegetation indices; NDVI; NDRE; OSAVI; selective harvesting; economic efficiency; commercial service.

SADRŽAJ

1. UVOD ---------- 1

1.1. Hipoteze i ciljevi istraživanja ---------- 3

2. PREGLED RELEVANTNE LITERATURE ---------- 4

2.1. Varijabilnost unutar vinograda ---------- 4

2.2. Precizno vinogradarstvo ---------- 6

2.2.1. Alati i tehnologije za precizno vinogradarstvo ---------- 7

2.2.2. Prednosti i korištenje alata i tehnologija za precizno vinogradarstvo ---------- 12

2.3. Daljinsko praćenje vinove loze ---------- 14

2.3.1. Daljinsko praćenje vinove loze bespilotnim letjelicama ---------- 15

2.3.2. Senzori za daljinsko praćenje vinove loze bespilotnim letjelicama ---------- 17

2.4. Vegetacijski indeksi ---------- 20

2.4.1. Vegetacijski indeksi za praćenje bujnosti i varijabilnosti vinove loze ---------- 23

2.5. Kvalitativno zoniranje vinograda i selektivna berba ---------- 34

2.5.1. Relevantnost vegetacijskih indeksa za kvalitativno zoniranje ---------- 35

2.5.2. Selektivna berba ---------- 39

2.6. Ekonomski učinci precizne poljoprivrede u vinogradarstvu ---------- 42

2.6.1. Ekonomski učinci tehnologija za precizno vinogradarstvo ---------- 44

2.6.2. Ekonomske metode procjene investicije za precizno vinogradarstvo ---------- 48

2.6.3. Ekonomska opravdanost kvalitativnog zoniranja i selektivne berbe ---------- 54

3. MATERIJALI I METODE RADA ---------- 56

3.1. Lokacije pokusnih vinograda ---------- 56

3.2. Karakteristike vinogorja i klimatske značajke ---------- 57

3.2.1. Vinogorje Zelina ---------- 57

3.2.2. Vinogorje Plešivica-Okić ---------- 59

3.3. Karakteristike sorata vinove loze 'Kraljevina' i 'Pinot crni' (*Vitis vinifera* L.) ---------- 62

3.3.1. 'Kraljevina' (*Vitis vinifera* L.) ---------- 62

3.3.2. 'Pinot crni' (*Vitis vinifera* L.) ---------- 63

3.4. Provedba istraživanja ---------- 64

3.4.1. Prikupljanje podataka multispektralnom kamerom ---------- 67

3.4.2. Prikupljanje podataka ručnim uzorkovanjem ---------- 72

3.4.3. Prikupljanje podataka i metode za izračun ekonomske opravdanosti kvalitativnog zoniranja i selektivne berbe ---------- 74

3.4.4. Statistička obrada podataka ---------- 85

4. REZULTATI ISTRAŽIVANJA ---------- 87

4.1. 'Kraljevina' (*Vitis vinifera* L.) - lokacija KOS ---------- 89

4.1.1. Rezultati istraživanja u 2019. godini ---------- 89

4.1.2. Rezultati istraživanja u 2020. godini ---------- 98

4.2. 'Kraljevina' (*Vitis vinifera* L.) - lokacija PUHELEK- PUREK ---------- 107
4.2.1. Rezultati istraživanja u 2020. godini ---------- 107
4.3. 'Pinot crni' (*Vitis vinifera* L.) – lokacija TOMAC ---------- 116
4.3.1. Rezultati istraživanja u 2019. godini ---------- 116
4.3.2. Rezultati istraživanja u 2020. godini ---------- 125
4.4. 'Pinot crni' (*Vitis vinifera* L.) – lokacija ŠEMBER ---------- 134
4.4.1. Rezultati istraživanja u 2019. godini ---------- 134
4.4.2. Rezultati istraživanja u 2020. godini ---------- 143
4.5. Rezultati procjene ekonomske opravdanosti kvalitativnog zoniranja i selektivne berbe ---------- 152
4.5.1. Rezultati analize troškova kvalitativnog zoniranja i selektivne berbe ---------- 152
4.5.2. Rezultati analize tržišnih cijena grožđa i vina sorte 'Kraljevina' i 'Pinot crni' ---------- 155
4.5.3. Rezultati analize mogućih prihoda nakon selektivne berbe grožđa ---------- 160
4.5.4. Rezultati analize mogućih prihoda od proizvodnje vina na osnovu selektivne berbe grožđa ---------- 164
4.5.5. Rezultati analize financijskih kriterija i procjena opravdanosti ulaganja u kvalitativno zoniranje i selektivnu berbu ---------- 169
5. RASPRAVA ----------197
5.1. Primjena vegetacijskih indeksa za kvalitativno zoniranje vinograda ---------- 197
5.1.1. OSAVI ---------- 198
5.1.2. NDVI ---------- 199
5.1.3. NDRE ---------- 207
5.2. Ekonomska opravdanost kvalitativnog zoniranja i selektivne berbe ---------- 211
6. ZAKLJUČCI ----------216
7. POPIS LITERATURE ----------220
8. PRILOG ----------238

POPIS KRATICA

APRR	Agencija za plaćanja u poljoprivredi, ribarstvu i ruralnom razvoju
B	Blue
BAU	Business as Usual
CBA	Cost Benefit Analiza
CWSI	Crop Water Stress Index
DHMZ	Državni hidrometeorološki zavod
EC	Električna provodljivost
EMI	Elektromagnetska indukcija
EUROSTAT	European Statistical Office
EUSPA	European Union Agency for the Space Programme
FAB	Fotosintetski aktivna biomasa
FMIS	Farm Management Information System
G	Green
GCP	Ground Control Point
GIS	Geografski informacijski sustav
GM	Gross Margin
GNDVI	Green Normalised Difference Vegetative Index
GNSS	Global Navigation Satellite System
GPS	Global Positioning System
GS	Growth Stage
GVI	Green Vegetation Index
ha	Hektar
IRR	Internal Rate of Return
ISOBUS	ISO standard 11783
IT	Information Technology
J	Jug
JI	Jugoistok
JZ	Jugozapad
JRC	Joint Research Centre of the European Commission
KpR	Koeficijent potencijalne rodnosti
KrR	Koeficijent relativne rodnosti
L	Faktor prilagodbe tlu
LIDAR	Light Detection and Ranging
mIRR	Modified Internal Rate of Return
mm	Milimetar
N	Broj uzoraka
NaOH	Natrijev hidroksid
NDRE	Normalized Difference Red Edge Index
NDVI	Normalised Difference Vegetative Index
NIR	Near Infrared
nm	Nanometar
NPV	Net Present Value
OSAVI	Optimized Soil- Adjusted Vegetation Index
PCD	Plant Cell Density

R	Red
RE	Red Edge
ROI	Return On Investment
SAVI	Soil- Adjusted Vegetation Index
SFT	Smart Farming Technologies
SPSS	Statistical Package for the Social Sciences
UAV	Unmanned Aerial Vehicle
UGV	Unmanned Ground Vehicle
VRT	Variable Rate Technology
WSN	Wireless Sensor Network
°C	Stupanj Celzijusa
°Oe	Stupanj Oechslea

POPIS TABLICA

Tablica 1. Pregled pametnih tehnologija za upravljanje vinogradarskom proizvodnjom----8

Tablica 2. Najviše korišteni vegetacijski indeksi u vinogradarstvu ---------- 21

Tablica 3. Ekonomski učinak pametnih tehnologija za upravljanje vinogradarskom proizvodnjom ---------- 45

Tablica 4. Struktura troškova podatkovno intenzivnih tehnologija u preciznom vinogradarstvu s obzirom na način prikupljanja, obrade i analize podataka ---------- 49

Tablica 5. Opis lokacija pokusnih vinograda ---------- 56

Tablica 6. Broj ciljanih trsova po pokusnom vinogradu u 2019. i 2020. godini---------- 64

Tablica 7. Termini prikupljanja podataka multispektralnom kamerom u 2019. i 2020. godini---------- 68

Tablica 8. Termini prikupljanja podataka ručnim uzorkovanjem u 2019. i 2020. godini--- 73

Tablica 9. Metode financijskog odlučivanja---------- 78

Tablica 10. Rezultat klasterizacije kvalitativnih svojstava grožđa sorte 'Kraljevina' na ciljanim trsovima (n=12) u 2019. godini na lokaciji KOS ---------- 91

Tablica 11. Preklapanja kvalitativnih klasifikacijskih struktura dobivenih klasterizacijom i zoniranjem pomoću vegetacijskih indeksa na ciljanim trsovima (n=12) sorte 'Kraljevina' u 2019. godini na lokaciji KOS---------- 92

Tablica 12. Odabrani deskriptivni statistički pokazatelji na ciljanim trsovima (n=12) sorte 'Kraljevina' u 2019. godini na lokaciji KOS klasificirani u dvije zone bujnosti na temelju NDRE indeksa iz rujna ---------- 94

Tablica 13. Rezultat testiranja statističke značajnosti razlika između zone veće i manje bujnosti dobivenih na temelju NDRE indeksa iz rujna u prosječnim rezultatima na analiziranim varijablama sorte 'Kraljevina' u 2019. godini na lokaciji KOS ---------- 95

Tablica 14. Point biserijalni koeficijenti korelacije (r_{pb}) između vegetacijskog indeksa NDRE u terminu snimanja u rujnu i analiziranih varijabli na ciljanim trsovima (n=12) sorte 'Kraljevina' u 2019. godini na lokaciji KOS ---------- 96

Tablica 15. Koeficijenti rodnosti i Indeks Ravaz za zonu manje i zonu veće bujnosti na temelju najprediktivnijeg vegetacijskog indeksa NDRE u terminu snimanja u rujnu (15.9.) na ciljanim trsovima (n=12) sorte 'Kraljevina' u 2019. godini na lokaciji KOS---------- 97

Tablica 16. Rezultat klasterizacije kvalitativnih svojstava grožđa sorte 'Kraljevina' na ciljanim trsovima (n=14) u 2020. godini na lokaciji KOS ---------- 100

Tablica 17. Preklapanja kvalitativnih klasifikacijskih struktura dobivenih klasterizacijom i zoniranjem pomoću vegetacijskih indeksa na ciljanim trsovima (n=14) sorte 'Kraljevina' u 2020. godini na lokaciji KOS---------- 101

Tablica 18. Odabrani deskriptivni statistički pokazatelji na ciljanim trsovima (n=14) sorte 'Kraljevina' u 2020. godini na lokaciji KOS klasificirani u dvije zone bujnosti na temelju NDVI indeksa iz kolovoza ---------- 103

Tablica 19. Rezultat testiranja statističke značajnosti razlika između zone veće i manje bujnosti dobivenih na temelju NDVI indeksa iz kolovoza u prosječnim rezultatima na analiziranim varijablama sorte 'Kraljevina' u 2020. godini na lokaciji KOS ---------- 104

Tablica 20. Point biserijalni koeficijenti korelacije (r_{pb}) između vegetacijskog indeksa NDVI u terminu snimanja u kolovozu i analiziranih varijabli na ciljanim trsovima (n=14) sorte 'Kraljevina' u 2020. godini na lokaciji KOS ---------- 105

Tablica 21. Koeficijenti rodnosti i indeks ravaz za zonu manje i zonu veće bujnosti na temelju najprediktivnijeg vegetacijskog indeksa NDVI u terminu snimanja u kolovozu (21.8.) na ciljanim trsovima (n=14) sorte 'Kraljevina' u 2020. godini na lokaciji KOS ---- 106

Tablica 22. Rezultat klasterizacije kvalitativnih svojstava grožđa sorte 'Kraljevina' na ciljanim trsovima (n=36) u 2020. godini na lokaciji PUHELEK- PUREK---------- 109

Tablica 23. Preklapanja kvalitativnih klasifikacijskih struktura dobivenih klasterizacijom i zoniranjem pomoću vegetacijskih indeksa na ciljanim trsovima (n=36) sorte 'Kraljevina' u 2020. godini na lokaciji PUHELEK- PUREK ---------- 110

Tablica 24. Odabrani deskriptivni statistički pokazatelji na ciljanim trsovima (n=36) sorte 'Kraljevina' u 2020. godini na lokaciji PUHELEK- PUREK klasificirani u dvije zone bujnosti na temelju NDVI indeksa iz kolovoza---------- 112

Tablica 25. Rezultat testiranja statističke značajnosti razlika između zone veće i manje bujnosti dobivenih na temelju NDVI indeksa iz kolovoza u prosječnim rezultatima na analiziranim varijablama sorte 'Kraljevina' u 2020. godini na lokaciji PUHELEK- PUREK ---------- 113

Tablica 26. Point biserijalni koeficijenti korelacije (r_{pb}) između vegetacijskog indeksa NDVI u terminu snimanja u kolovozu i analiziranih varijabli na ciljanim trsovima (n=36) sorte 'Kraljevina' u 2020. godini na lokaciji PUHELEK- PUREK---------- 114

Tablica 27. Koeficijenti rodnosti i Indeks Ravaz za zonu manje i zonu veće bujnosti na temelju najprediktivnijeg vegetacijskog indeksa NDVI u terminu snimanja u kolovozu (21.8.) na ciljanim trsovima (n=36) sorte 'Kraljevina' u 2020. godini na lokaciji PUHELEK-PUREK ---------- 115

Tablica 28. Rezultat klasterizacije kvalitativnih svojstava grožđa sorte 'Pinot crni' na ciljanim trsovima (n=9) u 2019. godini na lokaciji TOMAC ---------- 118

Tablica 29. Preklapanja kvalitativnih klasifikacijskih struktura dobivenih klasterizacijom i zoniranjem pomoću vegetacijskih indeksa na ciljanim trsovima (n=9) sorte 'Pinot crni' u 2019. godini na lokaciji TOMAC ---------- 119

Tablica 30. Odabrani deskriptivni statistički pokazatelji na ciljanim trsovima (n=9) sorte 'Pinot crni' u 2019. godini na lokaciji TOMAC klasificirani u dvije zone bujnosti na temelju NDVI indeksa iz rujna ---------- 121

Tablica 31. Rezultat testiranja statističke značajnosti razlika između zone veće i manje bujnosti dobivenih na temelju NDVI indeksa iz rujna u prosječnim rezultatima na analiziranim varijablama sorte 'Pinot crni' u 2019. godini na lokaciji TOMAC---------- 122

Tablica 32. Point biserijalni koeficijenti korelacije (r_{pb}) između vegetacijskog indeksa NDVI u terminu snimanja u rujnu i analiziranih varijabli na ciljanim trsovima (n=9) sorte 'Pinot crni' u 2019. godini na lokaciji TOMAC---------- 123

Tablica 33. Koeficijenti rodnosti i Indeks Ravaz za zonu manje i zonu veće bujnosti na temelju najprediktivnijeg vegetacijskog indeksa NDVI u terminu snimanja u rujnu (4.9.) nNa ciljanim trsovima (n=9) sorte 'Pinot crni' u 2019. godini na lokaciji TOMAC --------- 124

Tablica 34. Rezultat klasterizacije kvalitativnih svojstava grožđa sorte 'Pinot crni' na ciljanim trsovima (n=13) u 2020. godini na lokaciji TOMAC---------- 127

Tablica 35. Preklapanja kvalitativnih klasifikacijskih struktura dobivenih klasterizacijom i zoniranjem pomoću vegetacijskih indeksa na ciljanim trsovima (n=13) sorte 'Pinot crni' u 2020. godini na lokaciji TOMAC ---------- 128

Tablica 36. Odabrani deskriptivni statistički pokazatelji na ciljanim trsovima (n=13) sorte 'Pinot crni' u 2020. godini na lokaciji TOMAC klasificirani u dvije zone bujnosti na temelju NDRE indeksa iz drugog termina snimanja u kolovozu ---------- 130

Tablica 37. Rezultat testiranja statističke značajnosti razlika između zone veće i manje bujnosti dobivenih na temelju NDRE indeksa iz drugog termina snimanja u kolovozu u prosječnim rezultatima na analiziranim varijablama sorte 'Pinot crni' u 2020. godini na lokaciji TOMAC ---------- 131

Tablica 38. Point biserijalni koeficijenti korelacije (r_{pb}) između vegetacijskog indeksa NDRE iz drugog termina snimanja u kolovozu i analiziranih varijabli na ciljanim trsovima (n=13) sorte 'Pinot crni' u 2020. godini na lokaciji TOMAC---------- 132

Tablica 39. Koeficijenti rodnosti za zonu manje i zonu veće bujnosti na temelju najprediktivnijeg vegetacijskog indeksa NDRE u drugom terminu snimanja u kolovozu (27.8.) na ciljanim trsovima (n=13) sorte 'Pinot crni' u 2020. godini na lokaciji TOMAC- 133

Tablica 40. Rezultat klasterizacije kvalitativnih svojstava grožđa sorte 'Pinot crni' na ciljanim trsovima (n=12) u 2019. godini na lokaciji ŠEMBER---------- 136

Tablica 41. Preklapanja kvalitativnih klasifikacijskih struktura dobivenih klasterizacijom i zoniranjem pomoću vegetacijskih indeksa na ciljanim trsovima (n=12) sorte 'Pinot crni' u 2019. godini na lokaciji ŠEMBER ---------- 137

Tablica 42. Odabrani deskriptivni statistički pokazatelji na ciljanim trsovima (n=12) sorte 'Pinot crni' u 2019. godini na lokaciji ŠEMBER klasificirani u dvije zone bujnosti na temelju NDRE indeksa iz kolovoza---------- 139

Tablica 43. Rezultat testiranja statističke značajnosti razlika između zone veće i manje bujnosti dobivenih na temelju NDRE indeksa iz kolovoza u prosječnim rezultatima na analiziranim varijablama sorte 'Pinot crni' u 2019. godini na lokaciji ŠEMBER---------- 140

Tablica 44. Point biserijalni koeficijenti korelacije (r_{pb}) između vegetacijskog indeksa NDRE u terminu snimanja u kolovozu i analiziranih varijabli na ciljanim trsovima (n=12) sorte 'Pinot crni' u 2019. godini na lokaciji ŠEMBER ---------- 141

Tablica 45. Koeficijenti rodnosti i Indeks Ravaz za zonu manje i zonu veće bujnosti na temelju najprediktivnijeg vegetacijskog indeksa NDRE u terminu snimanja u kolovozu (24.8.) na ciljanim trsovima (n=12) sorte 'Pinot crni' u 2019. godini na lokaciji ŠEMBER142

Tablica 46. Rezultat klasterizacije kvalitativnih svojstava grožđa sorte 'Pinot crni' na ciljanim trsovima (n=22) u 2020. godini na lokaciji ŠEMBER---------- 145

Tablica 47. Preklapanja kvalitativnih klasifikacijskih struktura dobivenih klasterizacijom i zoniranjem pomoću vegetacijskih indeksa na ciljanim trsovima (n=22) sorte 'Pinot crni' u 2020. godini na lokaciji ŠEMBER ---------- 146

Tablica 48. Odabrani deskriptivni statistički pokazatelji na ciljanim trsovima (n=22) sorte 'Pinot crni' u 2020. godini na lokaciji ŠEMBER klasificirani u dvije zone bujnosti na temelju NDVI indeksa iz srpnja---------- 148

Tablica 49. Rezultat testiranja statističke značajnosti razlika između zone veće i manje bujnosti dobivenih na temelju NDVI indeksa iz srpnja u prosječnim rezultatima na analiziranim varijablama sorte 'Pinot crni' u 2020. godini na lokaciji ŠEMBER---------- 149

Tablica 50. Point biserijalni koeficijenti korelacije (r_{pb}) između vegetacijskog indeksa NDVI u terminu snimanja u srpnju i analiziranih varijabli na ciljanim trsovima (n=22) sorte 'Pinot crni' u 2020. godini na lokaciji ŠEMBER---------- 150

Tablica 51. Koeficijenti rodnosti i Indeks Ravaz za zonu manje i zonu veće bujnosti na temelju najprediktivnijeg vegetacijskog indeksa NDVI u terminu snimanja u srpnju (30.7.), na ciljanim trsovima (n=22) sorte 'Pinot crni' u 2020. godini na lokaciji ŠEMBER -------- 151

Tablica 52. Fiksni troškovi kvalitativnog zoniranja- nabava opreme---------- 153

Tablica 53. Varijabilni troškovi kvalitativnog zoniranja 1 ha vinograda- utrošak vlastitog vremena ---------- 154

Tablica 54. Varijabilni troškovi kvalitativnog zoniranja- korištenje komercijalne usluge- 154

Tablica 55. Odabrani deskriptivni statistički pokazatelji prosječnih tržišnih cijena grožđa sorte 'Kraljevina' i sorte 'Pinot crni' u analiziranom desetogodišnjem periodu ---------- 156

Tablica 56. Tržišne maloprodajne cijene odabranih vina sorte 'Kraljevina' i 'Pinot crni' za sva četiri proizvođača ---------- 159

Tablica 57. Prosječna tržišna cijena vina sorte 'Kraljevina' i sorte 'Pinot crni' ostalih proizvođača iz vinogorja Zelina i podregije Plešivica ---------- 160

Tablica 58. Analiza mogućeg povećanja prihoda od proizvodnje grožđa sorte 'Kraljevina' na lokaciji KOS u 2019. i 2020. godini uz provedbu kvalitativnog zoniranja i selektivne berbe ---------- 161

Tablica 59. Analiza mogućeg povećanja prihoda od proizvodnje grožđa sorte 'Kraljevina' na lokaciji na lokaciji PUHELEK- PUREK u 2020. godini uz provedbu kvalitativnog zoniranja i selektivne berbe---------- 162

Tablica 60. Analiza mogućeg povećanja prihoda od proizvodnje grožđa sorte 'Pinot crni' na lokaciji TOMAC u 2019. i 2020. godini uz provedbu kvalitativnog zoniranja i selektivne berbe ---------- 162

Tablica 61. Analiza mogućeg povećanja prihoda od proizvodnje grožđa sorte 'Pinot crni' na lokaciji ŠEMBER u 2019. i 2020. godini uz provedbu kvalitativnog zoniranja i selektivne berbe ---------- 163

Tablica 62. Analiza mogućeg povećanja prihoda od proizvodnje vina sorte 'Kraljevina' na lokaciji KOS u 2019. i 2020. godini uz provedbu kvalitativnog zoniranja i selektivne berbe ---------- 165

Tablica 63. Analiza mogućeg povećanja prihoda od proizvodnje vina sorte 'Kraljevina' na lokaciji PUHELEK- PUREK u 2020. godini uz provedbu kvalitativnog zoniranja i selektivne berbe ---------- 166

Tablica 64. Analiza mogućeg povećanja prihoda od proizvodnje vina sorte 'Pinot crni' na lokaciji TOMAC u 2019. i 2020. godini uz provedbu kvalitativnog zoniranja i selektivne berbe ---------- 167

Tablica 65. Analiza mogućeg povećanja prihoda od proizvodnje vina sorte 'Pinot crni' na lokaciji ŠEMBER u 2019. i2020. godini uz provedbu kvalitativnog zoniranja i selektivne berbe ---------- 168

Tablica 66. Račun dobiti i gubitka za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Kraljevina' na lokaciji KOS (0,47 ha) u razdoblju od 2019.- 2023. godine za scenarije A i B---------- 172

Tablica 67. Izračun financijskih kriterija za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Kraljevina' na lokaciji KOS (0,47 ha) u razdoblju od 2019.- 2023. godine za scenarije A i B---------- 174

Tablica 68. Račun dobiti i gubitka za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Kraljevina' na lokaciji KOS (0,47 ha) u razdoblju od 2019.- 2028. godine za scenarij A---------- 177

Tablica 69. Izračun financijskih kriterija za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Kraljevina' na lokaciji KOS (0,47 ha) u razdoblju od 2019.- 2028. godine za scenarij A---------- 179

Tablica 70. Račun dobiti i gubitka za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Kraljevina' na lokaciji KOS (0,47 ha) u razdoblju od 2019.- 2028. godine za scenarij B---------- 181

Tablica 71. Izračun financijskih kriterija za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Kraljevina' na lokaciji KOS (0,47 ha) u u razdoblju od 2019.- 2028. godine za scenarij B---------- 183

Tablica 72. Račun dobiti i gubitka za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Kraljevina' na lokaciji PUHELEK- PUREK (0,93 ha) u razdoblju od 2020.- 2024. godine za scenarije A i B ---------- 185

Tablica 73. Izračun financijskih kriterija za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Kraljevina' na lokaciji PUHELEK- PUREK (0,93 ha) u razdoblju od 2020.- 2024. godine za scenarije A i B---------- 187

Tablica 74. Račun dobiti i gubitka za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Pinot crni' na lokaciji TOMAC (0,33 ha) u razdoblju od 2019.- 2023. godine za scenarije A i B---------- 189

Tablica 75. Izračun financijskih kriterija za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Pinot crni' na lokaciji TOMAC (0,33 ha) u razdoblju od 2019.- 2023. godine za scenarije A i B---------- 191

Tablica 76. Račun dobiti i gubitka za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Pinot crni' na lokaciji ŠEMBER (0,65 ha) u razdoblju od 2019.- 2023. godine za scenarije A i B---------- 193

Tablica 77. Izračun financijskih kriterija za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Pinot crni' na lokaciji ŠEMBER (0,65 ha) u razdoblju od 2019.- 2023. godine za scenarije A i B---------- 195

POPIS SLIKA

Slika 1. Ciklički proces preciznog vinogradarstva ---------- 7

Slika 2. Bespilotna letjelica s fiksnim krilima ---------- 16

Slika 3. Multirotor bespilotna letjelica (kvadkopter) ---------- 16

Slika 4. Elektromagnetski spektar ---------- 17

Slika 5. Krivulja spektralne refleksije za različite pokrove tla ---------- 22

Slika 6. Sigmoidna krivulja učenja i iskustva (S-krivulja) ---------- 52

Slika 7. Lokacija TOMAC s prikazom rasporeda 13 ciljanih trsova i površinom obuhvata 0,33 ha ---------- 65

Slika 8. Lokacija ŠEMBER s prikazom rasporeda 23 ciljana trsa i površinom obuhvata 0,65 ha ---------- 65

Slika 9. Lokacija KOS s prikazom rasporeda 14 ciljanih trsova i površinom obuhvata 0,47 ha ---------- 66

Slika 10. Lokacija PUHELEK- PUREK s prikazom rasporeda 36 ciljanih trsova i površinom obuhvata 0,93 ha ---------- 66

Slika 11. Bespilotna letjelica DJI Inspire 1 Pro opremljena Micasense RedEdge.MXTM multispektralnim senzorom ---------- 67

Slika 12. Spektralno područje senzora Micasense RedEdge.MXTM ---------- 68

Slika 13. Skraćeni prikaz obrade multispektralnih snimaka u ArcGIS programskom paketu ---------- 71

Slika 14. NDVI generirane karte bujnosti- lokacija KOS u 2019. godini ---------- 89

Slika 15. NDRE generirane karte bujnosti- lokacija KOS u 2019. godini ---------- 90

Slika 16. OSAVI generirane karte bujnosti- lokacija KOS u 2019. godini ---------- 90

Slika 17. Generirana karta dviju zona bujnosti sorte 'Kraljevina' u 2019. godini na temelju najprediktivnijeg vegetacijskog indeksa NDRE u terminu snimanja u rujnu (15.9.) na lokaciji KOS s prikazom klasifikacije ciljanih trsova po zonama ---------- 93

Slika 18. NDVI generirane karte bujnosti- lokacija KOS u 2020. godini ---------- 98

Slika 19. NDRE generirane karte bujnosti- lokacija KOS u 2020. godini ---------- 99

Slika 20. OSAVI generirane karte bujnosti- lokacija KOS u 2020. godini ---------- 99

Slika 21. Generirana karta dviju zona bujnosti sorte 'Kraljevina' u 2020. godini na temelju najprediktivnijeg vegetacijskog indeksa NDVI u terminu snimanja u kolovozu (21.8.) na lokaciji KOS s prikazom klasifikacije ciljanih trsova po zonama---------- 102

Slika 22. NDVI generirane karte bujnosti- lokacija PUHELEK- PUREK u 2020. godini - 107

Slika 23. NDRE generirane karte bujnosti- lokacija PUHELEK- PUREK u 2020. godini 108

Slika 24. OSAVI generirane karte bujnosti- lokacija PUHELEK- PUREK u 2020. godini 108

Slika 25. Generirana karta dviju zona bujnosti sorte 'Kraljevina' u 2020. godini na temelju najprediktivnijeg vegetacijskog indeksa NDVI u terminu snimanja u kolovozu (21.8.) na lokaciji PUHELEK- PUREK s prikazom klasifikacije ciljanih trsova po zonama ---------- 111

Slika 26. NDVI generirane karte bujnosti- lokacija TOMAC u 2019. godini ---------- 116

Slika 27. NDRE generirane karte bujnosti- lokacija TOMAC u 2019. godini---------- 117

Slika 28. OSAVI generirane karte bujnosti- lokacija TOMAC u 2019. godini ---------- 117

Slika 29. Generirana karta dviju zona bujnosti sorte 'Pinot crni' u 2019. godini na temelju najprediktivnijeg vegetacijskog indeksa NDVI u terminu snimanja u rujnu (4.9.) na lokaciji TOMAC s prikazom klasifikacije ciljanih trsova po zonama ---------- 120

Slika 30. NDVI generirane karte bujnosti- lokacija TOMAC u 2020. godini ---------- 125

Slika 31. NDRE generirane karte bujnosti- lokacija TOMAC u 2020. godini---------- 126

Slika 32. OSAVI generirane karte bujnosti- lokacija TOMAC u 2020. godini ---------- 126

Slika 33. Generirana karta dviju zona bujnosti sorte 'Pinot crni' u 2020. godini na temelju najprediktivnijeg vegetacijskog indeksa NDRE u drugom terminu snimanja u kolovozu (27.8.) na lokaciji TOMAC s prikazom klasifikacije ciljanih trsova po zonama---------- 129

Slika 34. NDVI generirane karte bujnosti- lokacija ŠEMBER u 2019. godini ---------- 134

Slika 35. NDRE generirane karte bujnosti- lokacija ŠEMBER u 2019. godini---------- 135

Slika 36. OSAVI generirane karte bujnosti- lokacija ŠEMBER u 2019. godini ---------- 135

Slika 37. Generirana karta dviju zona bujnosti sorte 'Pinot crni' u 2019. godini na temelju najprediktivnijeg vegetacijskog indeksa NDRE u terminu snimanja u kolovozu (24.8.) na lokaciji ŠEMBER s prikazom klasifikacije ciljanih trsova po zonama ---------- 138

Slika 38. NDVI generirane karte bujnosti- lokacija ŠEMBER u 2020. godini ---------- 143

Slika 39. NDRE generirane karte bujnosti- lokacija ŠEMBER u 2020. godini---------- 144

Slika 40. OSAVI generirane karte bujnosti- lokacija ŠEMBER u 2020. godini ---------- 144

Slika 41. Generirana karta dviju zona bujnosti sorte 'Pinot crni' u 2020. godini na temelju najprediktivnijeg vegetacijskog indeksa NDVI u terminu snimanja u srpnju (30.7.) na lokaciji ŠEMBER s prikazom klasifikacije ciljanih trsova po zonama ---------- 147

POPIS GRAFIKONA

Grafikon 1. Srednje mjesečne temperature zraka u vegetaciji (IV.- IX. mjeseca), Sv. Ivan Zelina, 2019. i 2020. godina ---------- 57

Grafikon 2. Količina mjesečnih oborina u vegetaciji (IV.- IX.), Sv. Ivan Zelina, 2019. i 2020. godina ---------- 58

Grafikon 3. Srednje mjesečne temperature zraka u vegetaciji (IV.-IX.), Goli Vrh, 2019. i 2020. godina---------- 60

Grafikon 4. Količina mjesečnih oborina u vegetaciji (IV.-IX.), Goli Vrh, 2019. i 2020. godina---------- 61

Grafikon 5. Prosječne tržišne cijene grožđa sorte 'Kraljevina' i sorte 'Pinot crni' u periodu 2011.- 2020. godine ---------- 157

Grafikon 6. Prosječne proizvođačke cijene vinskog grožđa u Republici Hrvatskoj u periodu 2011.- 2020. godine---------- 158

1. UVOD

Digitalizacija poljoprivrede u posljednjih tridesetak godina doprinosi brzom razvoju novih tehnologija za praćenje poljoprivredne proizvodnje, pa tako i vinogradarstva. Precizna poljoprivreda može se objasniti kao novi način upravljanja proizvodnjom koji omogućava donošenje odluka na temelju precizno prikupljenih podataka pomoću raznih alata/novih tehnologija. Precizno vinogradarstvo omogućava različito upravljanje proizvodnjom na različitim parcelama unutar vinograda uz pomoć novih tehnologija, koje omogućavaju prikupljanje i obradu podataka s visokim stupnjem točnosti na osnovu kojih se mogu donijeti kvalitetnije odluke pri upravljaju vinogradarskom proizvodnjom (Rendulić Jelušić i sur., 2020). Sve ovo, u konačnici, rezultira prilagođenom pristupu vinogradarskoj proizvodnji koja, uz pomoć novih tehnologija, omogućava učinkovitiju i kvalitetniju proizvodnju grožđa uz održivo korištenje proizvodnih resursa i vlastitog rada, dok istovremeno utječe na smanjenje troškova proizvodnje te minimiziranje negativnog utjecaja na okoliš (Fraigneau, 2009; Matese i Di Genaro, 2015; Barnard, 2018).

Dosadašnja praksa upravljanja vinogradima zasniva se na primjeni istih agrotehničkih i ampelotehničkih mjera na cijeloj površini vinograda. Takav uniforman pristup upravljanju vinogradima ima svoje opravdanje u jednostavnosti provedbe svih zahvata u vinogradu sve dok je vinogradar zadovoljan konačnom kvalitetom grožđa (Bramley, 2010; Maynard, 2015). Nadalje, uniforman pristup upravljanu vinogradima može se pripisati nedovoljnim poznavanjem razine same varijabilnosti kao i nemogućnosti prilagodbe upravljanja toj razini varijabilnosti (Steyn i sur., 2016). Identifikacija različitih kvalitativnih zona u vinogradu koje su posljedica varijabilnosti unutar vinograda, odnosno identifikacija „premium“ dijelova vinograda, može proizvođačima omogućiti ostvarenje većih prihoda iz vinogradarske i vinarske proizvodnje (Steyn i sur., 2016).

Kvalitativne zone u vinogradu moguće je identificirati primjenom vegetacijskih indeksa koji su široko rasprostranjeni u okviru aplikacija sustava za daljinsko praćenje. Daljinsko praćenje vinogradarske proizvodnje bespilotnom letjelicom spada u skupinu podatkovno intenzivnih tehnologija (Lambert i sur., 2004), relevantan je i cjenovno prihvatljiv izvor informacija za uočavanje varijabilnosti i provedbu kvalitativnog zoniranja na određenoj lokaciji uz pomoć vegetacijskih indeksa (Tisseyre i Taylor, 2005; Bonilla i sur., 2015; Gatti i sur., 2017; Matese i Di Genaro, 2018, Andújar i sur. 2019). Podatkovno intenzivne tehnologije zahtijevaju i dodatne vještine za djelotvornu upotrebu tehnologija, odnosno potrebna su dodatna specifična znanja i vještine kako bi se podaci učinkovito koristili te služili za kvalitativno zoniranje i selektivnu berbu.

Vegetacijski indeksi su prilično jednostavni i učinkoviti algoritmi za kvantitativnu i kvalitativnu procjenu vegetacijskog pokrova, bujnosti, dinamike rasta i mnogih drugih karakteristika vegetacije, a koriste se u praćenju stanja okoliša, očuvanju biološke raznolikosti, poljoprivredi, šumarstvu i drugim srodnih granama (Xue i Su, 2017). Danas ih je poznato više od 100, a njihova primjenjivost uvelike ovisi o njihovoj specifičnoj primjenjivosti i reprezentativnosti za područje istraživanja (Xue i Su, 2017). Vegetacijski indeksi usko su povezani s razinom reflektirajućeg zračenja u blisko infracrvenom (NIR) i crvenom spektru, prate fotosintetsku aktivnost biljke odnosno mjere fotosintetski aktivnu biomasu (FAB) i koriste se kao indikatori jačine i bujnosti vinove loze (Hall i sur., 2002). Dobro poznavanje spektralnih reakcija vegetacije osnova je za daljinsko praćenje različitih svojstava vegetacije (biomasa, zdravstveno stanje, sadržaj dušika i sl.) jer je dokazano kako su određeni vegetacijski indeksi vezani za određene karakteristike vegetacije. Svaki vegetacijski indeks ima svoju kombinaciju refleksije u različitim spektralnim kanalima kako bi otkrio pojedine karakteristike vegetacije i minimizirao utjecaj vanjskih faktora (npr. osvjetljenje, kalibracija senzora, atmosferski utjecaj, karakteristike tla) (Tsouros i sur., 2019). Vegetacijski indeksi koriste se za prostornu analizu razvoja vegetacije i mogu poslužiti kao pomoć pri odabiru načina upravljanja vinogradima (Costa i sur. 2019).

Neki od najviše korištenih vegetacijskih indeksa u vinogradarstvu su NDVI- Indeks normalizirane razlike (engl. *Normalised Difference Vegetative Index*), NDRE- Indeks normalizirane razlike crvenog ruba (engl. *Normalized Difference Red Edge Index*) te OSAVI- Optimizirani vegetacijski indeks prilagođen tlu (engl. *Optimized Soil- Adjusted Vegetation Index*). Zadnjih desetak godina provedena su mnoga istraživanja koja su, koristeći vegetacijske indekse (uglavnom NDVI), vrlo uspješno opisivala i povezivala rezultate spektralnih mjerenja s određenim karakteristikama vinove loze kao što su bujnost, prinos, kvalitativna svojstva grožđa, zdravstveno stanje i sl. Korištenjem vegetacijskih indeksa, kao alata za određivanje zona bujnosti unutar vinograda, može se na brži i precizniji način uočiti varijabilnost u vinogradu i s njom povezane vegetativne i kvalitativne karakteristike vinove loze i grožđa. O bujnosti i prinosu ovisi postizanje optimalne kakvoće grožđa za željena vina (Poni i sur., 2017). Određivanjem zona bujnosti indirektno se mogu odrediti i kvalitativne zone u vinogradu, čije je određivanje značajno za cjelokupno upravljanje i donošenje relevantnih odluka za vinogradsku proizvodnju kao što je selektivna berba na osnovu kvalitete grožđa. Selektivna berba odnosi se na razdvajanje grožđa u berbi prema različitim kriterijima prinosa i/ili kvalitete, s ciljem proizvodnje različitih proizvoda kako bi se na što bolji način iskoristile varijabilnosti uočene u vinogradu (Bramley, 2010). Selektivna berba može se promatrati iz agronomskog i ekonomskog aspekta, jer maksimizacija učinaka varijabilnosti u pojedinim dijelovima vinograda može biti i ekonomski učinkovita (Bramley i sur., 2003; Proffit i Malcom, 2005).

Iz aspekta proizvodnje vina, selektivna berba je zanimljiva prije svega zbog mogućnosti razdvajanja različitih klasa sirovine (grožđa) za proizvodnju različitih tipova vina od iste sorte grožđa i iz istog vinograda. Kod selektivne berbe važna je opravdanost i mora biti povezana s mogućnošću proizvodnje različitih tipova vina koja će imati svoje tržište.
Dosadašnja istraživanja obuhvatila su pojedinačne segmente svih navedenih postupaka, a ovim istraživanjem željela se utvrditi povezanost zona bujnosti s kvalitativnim svojstvima grožđa i sastavnicama prinosa pri čemu su zone bujnosti određene na osnovu tri različita vegetacijska indeksa (NDVI, NDRE i OSAVI), a snimke napravljene bespilotnom letjelicom opremljenom multispektralnom kamerom u tri različita termina snimanja. Osim toga, u dosadašnjim istraživanjima ekonomski aspekt opravdanosti takvih postupaka u vinogradarskoj proizvodnji na površinama do 1ha, slabije je istražen te je u ovom istraživanju napravljena detaljna analiza ekonomske opravdanosti investicije u nove tehnologije, provedbu kvalitativnog zoniranja i selektivne berbe putem relevantnih ekonomskih i financijskih metoda. Istraživanje je provedeno na četiri lokacije na području Zagrebačke županije i dvije sorte vinove loze- 'Kraljevina' i 'Pinot crni', na vinogradarskim površinama veličine do 1 ha.

1.1. Hipoteze i ciljevi istraživanja

Hipoteze:
1. Postoji razlika u povezanosti vegetacijskih indeksa (NDVI, NDRE, OSAVI) i bujnosti kod dviju istraživanih sorata u različitim fenofazama razvoja vinove loze
2. Postoji povezanost zona različite bujnosti sa sastavnicama prinosa i kvalitativnim svojstvima grožđa
3. Ekonomski je opravdana primjena vegetacijskih indeksa za kvalitativno zoniranje vinograda i selektivnu berbu grožđa na vinogradarskim površinama do 1 ha

Ciljevi:
1. Utvrditi povezanost vegetacijskih indeksa (NDVI, NDRE, OSAVI) i bujnosti kod dviju istraživanih sorata u različitim fenofazama razvoja vinove loze
2. Utvrditi povezanost zona različite bujnosti sa sastavnicama prinosa i kvalitativnim svojstvima grožđa
3. Utvrditi ekonomsku opravdanost primjene vegetacijskih indeksa za kvalitativno zoniranje vinograda i selektivnu berbu grožđa na vinogradarskim površinama do 1 ha

2. PREGLED RELEVANTNE LITERATURE

2.1. Varijabilnost unutar vinograda

Vinogradarska proizvodnja, u svojoj osnovi, teži ka proizvodnji što kvalitetnije sirovine za proizvodnju vina te je cilj postizanje stabilnog prinosa i kvalitete što, u konačnici, može rezultirati nižim prinosima od maksimalno mogućih. Iz tog razloga, upravljanje vinogradarskom proizvodnjom zahtijeva stalno praćenje karakteristika vinograda i uočavanje varijabilnosti koje utječu na kvalitetu grožđa. Izvor varijabilnosti može biti prirodan (npr. tlo i topografija), kontroliran (npr. gnojidba), izvan mogućnosti kontrole (npr. količina oborina) ili je varijabilnost rezultat interakcije sva tri izvora (Hatfield, 2000). Neovisno o izvoru varijabilnosti, praćenje i upravljanje varijabilnošću provodi se s ciljem razumijevanja kako varijabilnost može pomoći proizvođačima u postizanju što veće učinkovitosti i ekonomičnosti vinogradarske proizvodnje (Bramley, 2010; Martínez-Casasnovas i sur., 2012).

Varijabilnost unutar vinograda, kao pojava, dobro je poznata svim vinogradarima. Iskustveno, vinogradari dobro poznaju dijelove vinograda gdje je kvaliteta grožđa „bolja“, a gdje mogu očekivati grožđe lošije kvalitete s obzirom na nagib terena, ekspoziciju, sastav tla, mikroklimu i sl. (Smart, 1985; Johnson i sur., 2001; Bonilla i sur., 2015).

Prema Maletić i sur. (2008) bujnost trsa i mladica može biti rezultat obilježja sorte, iako je najčešće posljedica okolinskih uvjeta i tehnoloških zahvata, no u istim uvjetima daju se uočiti izražene sortne razlike, a bujnost kao sortno svojstvo ima i praktično značenje jer mnoge tehnološke mjere ovise upravo o bujnosti (podloga, sklop, sustav uzgoja, mjere zelenog reza, opterećenje i sl.). Isti autori navode kako je generativni potencijal nasljedna sklonost neke sorte ka postizanju određene razine rodnosti i promatra se kao biološko, a ne kao gospodarsko svojstvo. Rodnost je vrlo važno gospodarsko obilježje sorte. Izražava se prinosom grožđa po jedinici površine (obično u tonama po hektaru), a na prinose utječu generativni potencijal sorte te okolišni uvjeti i primijenjena tehnologija (Maletić i sur., 2015). Postizanje ravnoteže između vegetativnog i generativnog potencijala (bujnosti i rodnosti) jedan je od najvažnijih ciljeva u proizvodnji grožđa (Maletić i sur., 2008).

Iz navedenog, vegetativni potencijal i generativni potencijal su genetska obilježja sorte vinove loze, a bujnost i prinos su genetski uvjetovane uz utjecaj okolišnih uvjeta te potrebnih korekcija sukladno zahtjevima za proizvodnju vina određene kakvoće.

Iako genetski uvjetovani, uz iste okolišne čimbenike i istu tehnologiju proizvodnje grožđa, bujnost i prinos variraju unutar vinograda te se bujnost, kao svojstvena i relativno stabilna karakteristika vinove loze koja ima značajan utjecaj na prinos i kvalitetu grožđa, može

koristiti za praćenje varijabilnosti unutar vinograda i određivanje kvalitativnih zona u vinogradu (Johnson i sur., 2001; Hall i sur., 2002; Proffit i Malcom, 2005; Bramley i Hamilton, 2004; Arnó i sur., 2009; Bramley, 2010; Martínez-Casasnovas i sur., 2012, Santos i sur., 2012; Filippetti i sur., 2013; Bonilla i sur., 2015; Gatti i sur., 2017; Ferrer i sur., 2020). Prema Steyn i sur. (2016) prostorna varijabilnost bujnosti unutar vinograda javlja se i ako su svi trsovi jednako stari, iste sorte i istog klona te jednako tretirani u vinogradarskoj proizvodnji. Autori dalje navode kako varijabilnost unutar vinograda ne utječe samo na prinos, već i na kvalitativne karakteristike grožđa i vina. Padua i sur. (2019) smatraju da je bujnost mjera brzine rasta tijekom određenog vremenskog razdoblja (npr. sezona vegetacije) i da na taj način objedinjuje utjecaj okolišnih čimbenika i plodnosti tla te omogućuje uspostavu homogenih zona u vinogradu.

Prema Maletić i sur. (2015) kakvoća neke sorte (ili krajnjeg proizvoda – vina) rezultat je međusobnog djelovanja nekoliko čimbenika: kvalitativnog potencijala sorte (koji je određen genetički – najvažniji parametri kakvoće su šećeri, kiseline, tvari mirisa i boje te druge organske i mineralne tvari), ekoloških čimbenika položaja, vremenskih prilika kroz godinu, tehnologije proizvodnje grožđa i vinifikacije.

Dosadašnja praksa upravljanja vinogradima zasniva se na primjeni istih agrotehničkih i ampelotehničkih mjera na cijeloj površini vinograda. Takav uniforman pristup upravljanju vinogradima ima svoje opravdanje u jednostavnosti provedbe svih zahvata u vinogradu dok god je vinogradar zadovoljan konačnom kvalitetom grožđa (Bramley, 2010; Maynard, 2015). Nadalje, uniforman pristup upravljanu vinogradima može se pripisati nedovoljnim poznavanjem razine same varijabilnosti kao i nemogućnosti prilagodbe upravljanja toj razini varijabilnosti (Steyn i sur., 2016). No, u trenutku kada su zahtjevi tržišta vina sve veći glede posebnosti i kvalitete vina, a zahtjevi vinogradara sve veći za smanjenjem potrošnje inputa u vinogradarskoj proizvodnji s ciljem smanjenja troškova i zaštite okoliša, upravljanje varijabilnošću postaje ključan faktor pri promjeni načina upravljanja vinogradarskom proizvodnjom (Bramley, 2010; Maynard, 2015; Kernecker i sur., 2018.). Identifikacija različitih kvalitativnih zona u vinogradu koje su posljedica varijabilnosti unutar vinograda, odnosno identifikacija „premium“ dijelova vinograda, može proizvođačima omogućiti ostvarenje većih prihoda iz vinogradarske i vinarske proizvodnje (Steyn i sur., 2016). Nastavno na to, Bramley (2010) hipotetski predstavlja osnovne postulate upravljanja vinogradarskom proizvodnjom i pita se: prije promjene načina upravljanja vinogradarskom proizvodnjom, nekoliko ključnih faktora treba biti preispitano- je li utjecaj varijabilnosti unutar vinograda dovoljno izražen da bi se mogli koristiti različiti načini upravljanja vinogradom?; je li prostorna varijabilnost unutar vinograda sezonski stabilan parametar?; mogu li se identificirati uzroci varijabilnosti i može li se njima upravljati? Ako su ova pitanja pozitivno odgovorena, koji način upravljanja bi se trebao koristiti kao

odgovor na varijabilnost vinograda, odnosno, je li naše vinogradarsko znanje dovoljno za potporu odlučivanju o novom načinu upravljanja proizvodnjom i ako nije, kako se mogu steći ta specifična znanja? I konačno, ako su znanje i alati dostupni, hoće li novi način upravljanja vinogradarskom proizvodnjom biti ekonomski učinkovit?

Praktičan i moderan odgovor na ova pitanja jest precizno vinogradarstvo, koje se oslanjana prikupljanje, obradu i evaluaciju podataka te implementaciju odgovarajućih načina upravljanja vinogradom (Steyn i sur., 2016).

Praćenje i upravljanje varijabilnošću jedan je od glavnih ciljeva preciznog vinogradarstva koje omogućava upravljanje proizvodnjom prilagođeno specifičnostima pojedinih parcela uz korištenje novih tehnologija, koje omogućavaju prikupljanje i obradu podataka s visokim stupnjem točnosti na osnovu kojih se mogu donijeti kvalitetnije odluke pri upravljaju vinogradarskom proizvodnjom (Rendulić Jelušić i sur., 2020).

2.2. Precizno vinogradarstvo

Precizno vinogradarstvo može se definirati kao skup alata i mjera kojima se optimizira vinogradarska proizvodnja, povećava prinos i kvaliteta grožđa uz učinkovito i održivo korištenje proizvodnih resursa i inputa kao što su tlo, gnojiva, zaštitna sredstva, voda i energija, a s ciljem smanjenja troškova proizvodnje i vlastitog rada te minimiziranja negativnog utjecaja na okoliš (Fragineau, 2009; Matese i Di Genaro, 2015; Barnard, 2018).

Prema Bramley (2010) temeljni cilj preciznog vinogradarstva je korištenje detaljnih informacija o svojstvenim biofizičkim značajkama i učincima vinograda koje su osnova za upravljanje vinogradarskom proizvodnjom i donošenje relevantnih odluka. Obrazloženje ovog pristupa, kako navodi Bramley (2010) je da upotrebom prikupljenih informacija i podataka svaka odluka o načinu upravljanja vinogradarskom proizvodnjom ima snažnije uporište, a prikupljeni podaci stvaraju preduvjete za ostvarenje željenog učinka u proizvodnji. Sustav cikličkog prikupljanja podataka koji se odnose na upravljanje proizvodnjom i procjenu učinka donesenih odluka, kao i prikupljanje podataka za buduće odluke, bit su preciznog vinogradarstva. Podaci se spremaju u baze podataka te čine vrijedan resurs za buduće odluke o upravljanu proizvodnjom (Balafoutis i sur., 2017).

Ciklički proces preciznog vinogradarstva (Bramley, 2001) sastoji se od tri glavna koraka (slika 1): 1. opservacija i prikupljanje podataka; 2. Analiza, evaluacija i interpretacija podataka i 3. Implementacija plana upravljanja vinogradom (Proffit i sur., 2006). U prvom koraku cilj je prikupiti što više korisnih podataka o samom vinogradu koristeći različite tehnologije i alate za prikupljanje podataka. U drugom koraku, prikupljeni podaci se

analiziraju, evaluiraju i interpretiraju uz pomoć različitih programskih paketa kako bi podaci bili korisni i upotrebljivi za treći korak, a to je primjena, odnosno, implementacija različitih planova upravljanja dijelovima vinograda, kao npr. selektivna berba ili ciljana gnojidba i zaštita vinograda.

Nadalje, ponavljanje ovog procesa kroz godine može omogućiti kontinuirano praćenje stanja, ali i odgovora vinove loze na primijenjene specifične načine upravljanja. To omogućava vinogradaru procjenu učinkovitosti u prethodnim godinama, ali i daje smjernice za unaprjeđenje proizvodnje u idućim godinama (Rey Caramés, 2015).

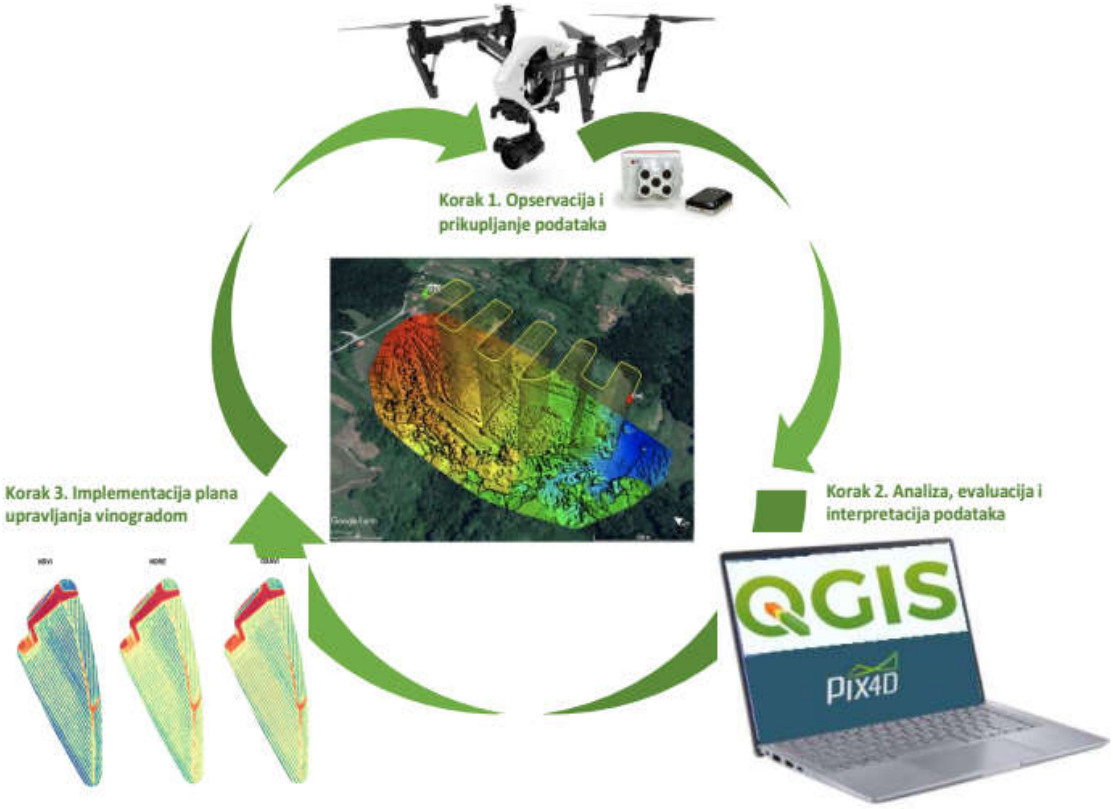

Slika 1. Ciklički proces preciznog vinogradarstva (prerađeno prema Proffit i sur. 2006)

2.2.1. Alati i tehnologije za precizno vinogradarstvo

Za primjenu cjelokupnog sustava preciznog vinogradarstva potrebno je korištenje različitih pametnih tehnologija za upravljanje proizvodnjom (engl. *smart farming technologies (SFTs)*) koje se odnose na pristupačne, pouzdane i dostupne tehnologije (Balafoutis i sur., 2017) koje su razvijene za potrebe preciznog vinogradarstva ili su prilagođene za primjenu u vinogradarstvu.

Postoje različiti tipovi pametnih tehnologija koji pokrivaju različite potrebe upravljanja vinogradarskom proizvodnjom. Prema Balafoutis (2017) tipovi pametnih tehnologija za upravljanje proizvodnjom dijele se na:

a) Tehnologije za prikupljanje podataka
b) Tehnologije za analizu i evaluaciju podataka
c) Tehnologije za preciznu provedbu i primjenu agrotehničkih i ampelotehničkih mjera

Sve tri navedene skupine tehnologija međusobno su ovisne, razvijaju se i prilagođavaju različitim potrebama u proizvodnji. Razvoj pametnih tehnologija izrazito je brz te su one iz godine u godinu jednostavnije za primjenu, pružaju točnije informacije i omogućavaju kontrolu i upravljanje gotovo svim proizvodnim procesima. Pregled pametnih tehnologija za upravljanje proizvodnjom naveden je u tablici 1.

Tablica 1. Pregled pametnih tehnologija za upravljanje vinogradarskom proizvodnjom (prerađeno prema Balafoutis i sur., 2017)

Tehnologija	**Glavna namjena**	**Sustav**
Tehnologije za prikupljanje podataka	Geoprostorna pokrivenost i pozicioniranje	Globalni navigacijski satelitski sustavi (GNSS)- GPS, GLONASS, GALILEO, BeiDou, QZSS, NavIc (EUSPA, 2020)
	Tehnologije mapiranja	Visinsko mapiranje Mapiranje svojstava tla Mapiranje prinosa
	Prikupljanje podataka o okolišnim uvjetima	RGB kamere LIDAR senzori Multispektralne kamere Hiperspektralne kamere Termalne kamere Senzori za praćenje stanja tla
	Strojevi i oprema	Senzori za mjerenje putne brzine Traktori sa ISOBUS sustavima Bespilotne letjelice Autonomna vozila i strojevi
Tehnologije za analizu i evaluaciju podataka	Analiza i korištenje prikupljenih podataka	Zoniranje proizvodnih površina Sustav potpore odlučivanju Upravljački informacijski sustavi Programski paketi za upravljanje proizvodnjom

Tehnologije za preciznu provedbu i primjenu agrotehničkih i ampelotehničkih mjera	Tehnologija promjenjive količine inputa (engl. VRT- *variable rate technology*)	Promjenjiva količina gnojiva Promjenjiva količina zaštitnih sredstva Precizno navodnjavanje i plan navodnjavanja Precizno mehaničko uništavanje korova
	Tehnologija automatskog navođenja	Sustavi automatskog navođenja i kontroliranog kretanja strojeva

Prema Griffinu i sur. (2004) tehnologije se mogu podijeliti na automatizirane tehnologije i podatkovno intenzivne tehnologije. Automatizirane tehnologije kao što su automatsko navođenje i kontrolirano kretanje strojeva imaju gotovo trenutni povrat uloženih sredstava i može ih lako koristiti većina korisnika. Podatkovne tehnologije, kao što su mapiranje prinosa, mapiranje i praćenje stanja tla te prikupljanje podataka o okolišnim uvjetima, zahtijevaju dodatne vještine za djelotvornu upotrebu tehnologija. Stoga, puno je teže procijeniti razdoblje povrata ulaganja za podatkovno intenzivne tehnologije i dodatne koristi poput poboljšanog razumijevanja čimbenika koji uzrokuju varijabilnost prinosa nego za automatizirane tehnologije koje olakšavaju i smanjuju količinu rada te ubrzavaju sam proces proizvodnje.

Prema Tisseyre i Taylor (2005); Fragineau (2009); Matese i Di Genaro (2015) te Ozdemir i sur. (2017) sustavi i tehnologije za P mogu se podijeliti u nekoliko kategorija:

a) Geoprostorne tehnologije
b) Praćenje stanja lisne mase i jačine trsa (engl. *canopy and vigour monitoring system*)
    - Sustav daljinskog praćenja (engl. *remote sensing system*)
    - Zemaljski sustav praćenja (engl. *ground-based monitoring system*)
c) Praćenje stanja tla
d) Bežična senzorska mreža (engl. *wireless sensor network (WSN)*)
e) Praćenje prinosa i kvalitete
f) Tehnologija promjenjive količine (engl. *VRT- variable rate technology*) i primijenjena robotika (engl. *farmbots, agbots*)
g) Programski paketi i/ili aplikacije

Geoprostorne tehnologije baziraju se na većem broju satelita raspoređenih u orbiti zemlje. Prema podacima Europske agencije za Globalne navigacijske satelitske sustave (EUSPA, 2020) aktivno je šest navigacijskih satelitskih sustava koji konstantno nastoje poboljšati kvalitetu usluga koje pružaju s ciljem povećanja učinkovitosti i povećanja interoperabilnosti sustava. GPS (SAD), GALILEO (Europa), GLONASS (Ruska Federacija), BeiDou (Narodna Republika Kina), QZSS (Japan) i NavIC (Indija) su aktivni

globalni i lokalni svemirski satelitski navigacijski sustavi koji korisnicima pružaju vrlo precizne 3D položaje te brze i pravovremene informacije. Njihova točnost lociranja je 1-10 metara, dok uz zemaljske referentne stanice postižu centimetarsku točnost lociranja, što je vrlo bitno kod korištenja u preciznoj poljoprivredi i vinogradarstvu za npr. mapiranje vinograda, preciznu primjenu gnojiva i zaštitnih sredstava i sl. (Tisseyre i Taylor, 2005; Krstić, 2012; Matese i Di Genaro, 2015).

Praćenje stanja lisne mase i bujnosti trsa u preciznom vinogradarstvu smatra se vrlo važnim jer omogućava prikupljanje podataka visoke prostorne i vremenske razlučivosti u gotovo realnom vremenu u toku vegetacijske sezone te mogu služiti kao alat za donošenje odluka o potrebnim agrotehničkim i ampelotehničkim zahvatima, ali i prikazati karte pojedinih zona u vinogradu koje se razlikuju po promatranim parametrima (Tisseyre i Taylor, 2005). Sustavom daljinskog praćenja moguće je u vrlo kratkom roku dobiti informacije koje mogu upućivati na stanje, veličinu i jačinu trsova u vinogradu te je na taj način moguće detektirati određenu varijabilnost u vinogradu. Primjena daljinskog praćenja u vinogradarstvu zasniva se na korištenju satelitskih snimaka i bespilotnih letjelica, koji se razlikuju po razlučivosti i kakvoći snimke, ali i po cijeni koštanja (Matese i Di Genaro, 2015; Barnard 2018). Korištenje bespilotnih letjelica – dronova koji su opremljeni različitim kamerama i senzorima postaje sve više korištena tehnologija u preciznom vinogradarstvu. Njihova prednost je u visokoj spektralnoj rezoluciji snimanja kao i mogućnosti planiranja pravovremenog snimanja vinograda. Njima se mogu snimati i vinogradi manjih površina (1-10 ha), što za satelitske snimke nije isplativo (min 50 ha) (Matese i Di Genaro, 2015). Zemaljski sustavi praćenja koriste se kao potpora ili korektiv daljinskom praćenju, odnosno senzori koji se mogu montirati na postojeću opremu za obradu vinograda te tijekom ostalih aktivnosti u vinogradu (zaštita vinograda, malčiranje i sl.) mogu prikupljati potrebne podatke o stanju trsa (količina biomase, visina trsa, fotosintetska aktivnost) (Tisseyre i Taylor, 2005).

Senzorsko praćenje stanja tla važno je pri praćenju varijabilnosti različitih svojstava tla (tekstura, dubina, vlažnost, sadržaj organske tvari, pH, dušik, fosfor, električna provodljivost i sl.). Za praćenje stanja tla koriste se senzori koji rade po dobro utvrđenim geofizičkim metodama, a najviše se koriste senzori koji svoj rad baziraju na elektromagnetskim svojstvima tla (Tisseyre i Taylor, 2005; Matese i Di Genaro, 2015). Senzori koji se koriste su senzor elektromagnetske indukcije- EMI (mjeri električnu provodljivost tla), a drugi je senzor električnog otpora (mjeri otpor kroz razliku potencijala između elektroda) (Fraigneau, 2009). Poznavanje prostorne varijabilnosti karakteristika tla unutar vinograda omogućava bolje razumijevanje fiziološkog stanja i reakcija vinove loze kao i identificiranje uzroka koji utječu na varijabilnost u prinosu i/ili kvaliteti. Tla s visokom električnom provodljivošću pokazala su visoku dostupnost hranjivih tvari, veće dubine i

veći sadržaj gline, a posljedično i visoku sposobnost zadržavanja vode, što uvelike utječe na vegetativni rast i bujnost trsa (Bonilla i sur., 2014). Praćenje svih meteoroloških parametara važnih za vinogradarsku proizvodnju temelj je za ispravno donošenje odluka pri provedbi pojedinih agrotehničkih i ampelotehničkih zahvata u vinogradu. S ciljem što preciznijeg kontinuiranog prikupljanja podataka postavljaju se solarne meteorološke postaje na mikrolokacijama unutar samih vinograda. Mikroklimatski podaci daju precizniju sintezu okolišnih podataka unutar vinograda za vrijeme vegetacijske sezone nego podaci s udaljenih meteoroloških postaja, što omogućava bolje razumijevanje varijabilnosti i upravljanje vinogradarskom proizvodnjom te primjenu preciznog vinogradarstva (Matese i sur., 2012; Matese i sur., 2014).

Bežična senzorska mreža predstavlja jednostavan i brz način praćenja određenih parametara u vinogradu u stvarnom vremenu. Postoji veliki broj senzora koji se mogu međusobno umrežiti i pratiti željene parametre kao što su vlaga tla, vlaga lisne površine, temperatura grozda i sl. dok se kao najvažnije ipak smatra praćenje meteoroloških podataka u samom vinogradu uz postavljanje odgovarajućih mikro meteoroloških postaja (Matese i Di Genaro, 2015; Ozdemir i sur., 2017).

Stvaranje mape prinosa i kvalitete grožđa unutar vinograda se može smatrati osnovnom značajkom za daljnji razvoj preciznog vinogradarstva (Ozdemir i sur., 2017). Komercijalni sustavi na tržištu kao što su npr. HarvestMaster Sensor System HM570 (Juniper Systems Inc., Logan, UT, USA), Canlink Grape Yield Monitor 3000GRM (Farmscan, Bentley, WA, Australia), i Advanced Technology and Viticulture (ATV) (Advanced Technology Viticulture, Joslin, SA, Australia)) rade na principu senzorskog praćenja prinosa mjerenjem mase grozda, a mogu se postaviti na ostalu opremu (berače, traktore i sl.). Također, postoje i „ručni“ senzori (Spectron (Pellenc SA, Pertuis Cedex, France)) koji rade na principu spektrofotometrije, a mogu mjeriti parametre u dozrijevanju grožđa kao što su količina šećera i kiselina, sadržaj antocijana i vode (Matese i Di Genaro, 2015).

Tehnologija promjenjive količine (engl. *Variable Rate Technology*- VRT) ima za cilj optimizaciju proizvodnje uz ispravno upravljanje inputima u vinogradarstvu kao što su gnojiva, zaštitna sredstva i sl. VRT tehnologija koristi softver koji može kombinirati podatke o položaju, dobivene pomoću GPS modula, sa senzorski generiranim kartama za svaku specifičnu operaciju. Ključni čimbenici potencijala VRT-a su zasnovani na razvoju inovativnih tehnologija praćenja vegetacije i visoko učinkovitih sustava atomizacije, a sve s izravnim utjecajem na troškove, kvalitetu i održivost okoliša (Tisseyre i Taylor, 2005; Arnó i sur., 2009; Matese i Di Genaro, 2015). Primijenjena robotika u intenzivnoj je fazi izrade i prilagodbe te početka primjene različitih strojeva/rješenja koji služe kao potpora odlučivanju u kvalitetnom upravljanju vinogradima. Dobar primjer je VineRobot, projekt Televitis grupe i Sveučilišta La Rioja (Španjolska). VineRobot je poljoprivredni robot

(bespilotno terensko vozilo (UGV)), opremljen s nekoliko neinvazivnih senzorskih tehnologija za praćenje prinosa grožđa, vegetativnog rasta, vodnog stresa i sastava grožđa, kako bi se optimiziralo upravljanje vinogradima i poboljšao kvalitativni sastav grožđa i kvaliteta vina (Tardáguila i sur., 2017). Osim toga postoje i VINBOT projekt, Wall-Ye robot, VineGuard, Vitirover i slični, a svi svoj rad baziraju na optičkom praćenju stanja vinograda, predviđanju količine prinosa, potrebama za zaštitom vinograda i sl. (Matese i Di Genaro, 2015).

Programski paketi i aplikacije koriste se za prikupljanje, organizaciju, obradu i jednostavniji prikaz podataka. Danas je na tržištu dostupan veliki broj programskih rješenja za upravljanje vinogradarskom proizvodnjom, neki su specifični za pojedine primjene, dok postoje i rješenja za cjelokupno upravljane određenom proizvodnjom (Balafoutis i sur., 2017), odnosno FMIS (engl. *Farm Management Information System*) kao npr. Agrivi (www.agrivi.com). Ono što je kod programskih sustava uočeno kao problem jest količina vremena koju vinogradar mora izdvojiti za unos svih potrebnih podataka koje bi sustav trebao obraditi, ali i nedovoljna informatička pismenost poljoprivrednika općenito za korištenje naprednijih aplikacija (Balafoutis i sur., 2017; Kernecker i sur., 2018).

Iz svega navedenog, može se zaključiti kako su profesionalnim vinogradarima dostupni različiti alati i tehnologije koje pružaju niz prostornih informacija iz kojih se mogu generirati različite namjenske karte o različitim vegetacijskim pokazateljima stanja vinograda, ali i stanja tla, a sve s ciljem uočavanja i upravljanja varijabilnostima te donošenja odgovarajućih odluka o proizvodnji temeljenih na prikupljenim podacima. Podatkovno utemeljeno donošenje odluka u proizvodnji može povećati ekonomičnost vinogradarske proizvodnje, kao i primjena određenih i prilagođenih tehnologija preciznog vinogradarstva (Proffit i sur., 2006; Arnó i sur., 2009; Maynard, 2015).

2.2.2. Prednosti i korištenje alata i tehnologija za precizno vinogradarstvo

Tehnologije i sustavi preciznog vinogradarstva počeli su se razvijati i koristiti već 90.- tih godina prošlog stoljeća, ali njihovo usvajanje i primjena od strane vinogradara je spora, uzimajući u obzir brzinu razvoja samih tehnologija. Smatra se kako je pozitivan stav prema novim tehnologijama jedan od važnijih čimbenika usvajanja istih. Prema Falaki i sur. (2008) citirano u Allahyari i sur. (2016) stav se može promatrati kao spremnost pojedinca da se s dozom uzbuđenja suočava s pojavama, problemima, stvarima i događajima, što je posljedica prošlosti svakog pojedinca i njegovih različitih životnih iskustava. Stav može biti pozitivan ili negativan, može se mijenjati, a bazira se na odluci

pojedinca, koju on donosi na temelju iskustva i učenja. Kako određeni faktori utječu na donošenje odluka, ovisi kako su ti faktori percipirani od strane proizvođača (Kernecker i sur., 2018). Na stav prema korištenju i usvajanju novih tehnologija i inovacija utječe više čimbenika, a važno je sagledati sociološki aspekt tj. karakteristike vinogradara (dob, edukacija, iskustvo), karakteristike vinograda/gospodarstva (površina, broj parcela, sorte, financijski status) (Tey i Brindal, 2012; Kernecker i sur., 2018), korištenje ostalih IT tehnologija i kompjutersku pismenost, informiranost o novim tehnologijama i njihovim karakteristikama (Tey i Brindal, 2012; Barnes i sur., 2019), regionalne i okolišne karakteristike (Adrian i sur., 2005; Kernecker i sur., 2018; Tey i Brindal, 2012; Barnes i sur., 2019) te ekonomsku analizu isplativosti primjene novih tehnologija (Adrian i sur., 2005; Tey i Brindal, 2012; Aubert i sur., 2012; Allahyari i sur., 2016; Kernecker i sur.,2018; Barnes i sur. 2019) koja je prema većem broju istraživanja glavni faktor koji utječe na sklonost korištenja novih tehnologija zajedno s mogućnostima sufinanciranja takvih aktivnosti i opreme. Osim toga, svi prethodno navedeni autori kroz svoja istraživanja navode kako vrlo snažan utjecaj na prihvaćanje novih tehnologija imaju i karakteristike novih tehnologija te njihov pravilan i prilagođen izbor, njihova jednostavnost primjene, lakoća korištenja i osigurana podrška, mogućnost isprobavanja novih tehnologija te vidljivost i brzina učinaka primjene novih tehnologija. Upravo je nedostatak praktičnih tehnoloških istraživanja, ali i nedostatak ekonomskih istraživanja razlog vrlo sporog prihvaćanja i korištenja novih tehnologija među vinogradarima.

Alati i tehnologije preciznog vinogradarstva koriste se u vodećim svjetskim vinogradarskim zemljama. Sukladno tome, većina istraživanja se i provodi u tim zemljama zbog važnosti vinogradarske proizvodnje i njenog utjecaja na gospodarstvo, turizam, ali i zaštitu okoliša i održivi razvoj. Praćenje varijabilnosti unutar vinograda jedna je od najviše istraživanih tema u Australiji, ali i Francuskoj, Španjolskoj, Čileu, Novom Zelandu, Kanadi i Sjedinjenim Američkim Državama (Bramley, 2010). Praćenje varijabilnosti odnosi se na praćenje bujnosti vinove loze, prinosa, kemijskog sastava grožđa, karakteristika tla i vodnog statusa vinograda ili međusobnih kombinacija navedenih karakteristika (Rey Caramés, 2015; Santesteban, 2019), dok se sami alati i tehnologije razvijaju u svim smjerovima: od razvoja novih senzora i njihove procjene za korištenje u vinogradarstvu, preko razvoja programskih paketa za obradu i prezentaciju podataka pa sve do razvoja novih metoda za detekciju ekscesnih stanja u vinogradu i njihovog ciljanog tretiranja (Rey Caramés, 2015; Sassu i sur., 2021). Prikupljanje podataka i određivanje različitih zona upravljanja potom se koristi za primjenu preciznog vinogradarstva i različito upravljanje pojedinim dijelovima vinograda kroz precizno navodnjavanje, gnojidbu i ciljanu primjenu ampelotehničkih zahvata (Santesteban, 2019).

2.3. Daljinsko praćenje vinove loze

Daljinsko praćenje u poljoprivredi i vinogradarstvu istražuje se i koristi već gotovo 50 godina te su satelitske i zračne snimke bile osnova preciznog vinogradarstva i koristile su se za praćenje rasta i bujnosti u određenim stadijima razvoja vinove loze. Satelitske snimke često nisu najbolji izbor i njihovo korištenje može imati ograničenja vezane uz nedovoljnu rezoluciju potrebnih snimaka, moguće zasjenjivanja oblacima te nemogućnost određivanja potrebnog perioda snimanja za precizno vinogradarstvo (Ananstasiou i sur., 2018; Sassu i sur., 2019; Tsouros i sur., 2019). No, ubrzanim razvojem satelita i povećanjem rezolucije kao i broja snimaka, ova tehnologija mogla bi biti vrlo iskoristiva i za precizno vinogradarstvo što su svojim istraživanjima potvrdili Kandylakis i Karantzalos (2016) koji su svoje rezultate opisali obećavajućima uz češća praćenja i analize snimaka tijekom dozrijevanja grožđa. Novije istraživanje koje su proveli Di Gennaro i sur. (2019). potvrdilo je učinkovitost satelitskih snimaka sa satelita Sentinel-2 za vinograde koji su formirani u uzgojnim oblicima tipa zavjesa ili pergola jer se umanjuje međuredni utjecaj tla i zasjenjivanje. Osim toga, mnogi satelitski programi (kao što su Landsat, Modis, Aste, SPOT, Sentinel-1, Sentinel-2 i dr.) u današnje vrijeme omogućavaju besplatno korištenje snimaka i satelitskih podataka s ciljem njihove šire upotrebe baš u poljoprivrednim aplikacijama (Khaliq i sur. 2019). Radočaj i sur. (2020) u svom su preglednom radu analizirali dostupnost besplatnih satelitskih snimaka i GIS programskog paketa za potrebe daljinskog praćenja te zaključuju kako je trenutno najpogodniji satelitski program za daljinsko praćenje vegetacije Sentinel-2 zbog visoke prostorne i vremenske rezolucije. Ono što smatraju trenutnim nedostatkom su ekspertna znanja u obradi podatka GIS programskim paketom. Nadalje, smatraju kako bi se problem satelitskih snimaka vezan uz zasjenjivanje i nedovoljnu vremensku pokrivenost uspješno riješio kombinirajući daljinsko praćenje bespilotnim letjelicama i podatke satelitskih misija. Pojavom bespilotnih letjelica, korištenje različitih zrakoplova i zračnih snimanja postalo je neisplativo u ekonomskom smislu iako je njihova spektralna rezolucija i mogućnost korištenja i iskoristivosti u preciznom vinogradarstvu veća nego za satelitske snimke (Rey Caramés, 2015; Tsouros i sur., 2019). Daljinsko praćenje vinogradarske proizvodnje bespilotnom letjelicom, koje spada u skupinu podatkovno intenzivnih tehnologija (Lambert i sur., 2004), relevantan je i cjenovno prihvatljiv izvor informacija za uočavanje varijabilnosti i provedbu kvalitativnog zoniranja na određenoj lokaciji uz pomoć vegetacijskih indeksa (Tisseyre i Taylor, 2005; Bonilla i sur., 2015; Gatti i sur., 2017; Matese i Di Genaro, 2018, Andújar i sur. 2019). Izbor načina daljinskog praćenja vinove loze, zapravo je kompromis, koji ovisi o ciljevima

praćenja varijabilnosti, dostupnosti ljudskih resursa te ekonomskih mogućnosti krajnjeg korisnika (Di Gennaro i sur., 2019).

2.3.1. Daljinsko praćenje vinove loze bespilotnim letjelicama

Bespilotne letjelice (engl. *unmanned aerial vehicles (UAV))* postale su važne za praćenje poljoprivredne i vinogradarske proizvodnje zbog svoje fleksibilnosti i učinkovitosti u različitim okruženjima i načinima korištenja. Provedeno je mnogo istraživanja vezanih uz mogućnosti bespilotnih letjelica pa su tako korištene za procjenu prinosa i kvalitete grožđa, vodnog stresa, fotosintetske aktivnosti, pojave bolesti, štetnika i korova, ali i za detekciju trsova koji nedostaju u vinogradu, procjenu visine trsova u vinogradu, štete nastale od poplave i suše i sl. (Anastasiou i sur., 2018; Di Gennaro i sur., 2019; Pichon i sur., 2019; Tsouros i sur., 2019). Bespilotne letjelice su najviše korišteni alati u smislu preciznosti, fleksibilnosti i niskih operativnih troškova, a mogu pokriti velika područja puno brže nego istraživanja na tlu te su u tom smislu puno efikasnije i brže u detekciji određenih problema (Zhang i Kovacs, 2012; Tsouros i sur., 2019; Sassu i sur., 2021).

Sassu i sur. (2021) su u svom preglednom radu opisali način korištenja bespilotnih letjelica sukladno primarnim namjenama upotrebe u vinogradarstvu. Izdvojili su pet osnovnih namjena za koje se koriste bespilotne letjelice u vinogradarstvu:

1. Segmentacija (odvajanje) redova unutar vinograda i prikupljanje informacija o svojstvima trsa
2. Daljinska analiza vinograda za praćenje varijabilnosti
3. Procjena površine koju zauzimaju redovi i volumena lisne mase
4. Otkrivanje zdravstvenog stanja i ekscesnih površina u vinogradu
5. Precizno tretiranje vinograda zaštitnim sredstvima

Nastavno na ove namjene, Jones i Grant (2016) još navode i ciljano navodnjavanje koje je posebno važno u vinogradarstvu jer optimizira i prinos i kakvoću grožđa.

Svaka od ovih namjena ima uporište u ciljanom pristupu upravljanju vinogradarskom proizvodnjom kroz cijelu vegetacijsku sezonu i prikupljanje informacija koje čine okosnicu alata za potpore odlučivanju u upravljanju proizvodnjom i vinogradarima i poljoprivrednim savjetnicima (Pichon i sur., 2019).

Bespilotna letjelica je sustav koji čine letjelica, njezin teret i stanica ili sustav za upravljanje na zemlji. Sama letjelica sastoji se od okvira, pogonskog sustava, računala za kontrolu leta, preciznog sustava navigacije i sustava za izbjegavanje sudara u zraku (engl. *sense and avoid system*) (Šmejkal, 2018). Najčešći tipovi bespilotnih letjelica koji se

koriste u poljoprivredi su bespilotne letjelice s fiksnim krilima (slika 2) i multirotor bespilotne letjelice (s rotirajućim krilima) (slika 3) (Padua i sur., 2017). Obje vrste letjelica imaju svoje prednosti i nedostatke koji se očituju u stabilnosti, trajanju leta, jednostavnosti upravljanja, operabilnosti i ekonomičnosti za potrebe u vinogradarstvu. Multirotor bespilotne letjelice jednostavne su za uzlijetanje i slijetanje te ne trebaju za to veće površine kao što je slučaj s bespilotnim letjelicama s fiksnim krilima, no njihova letna izdržljivost je manja te je tako smanjena i površina koju mogu analizirati u toku jednog preleta. Multirotor bespilotne letjelice jednostavnije su za upravljanje i ne zahtijevaju posebne pilotske vještine za upravljanje, mogu vertikalno uzletjeti i sletjeti te lebdjeti i manje su bučne (Jones i Grant, 2016; Balafoutis i sur., 2017; Padua i sur., 2017; Kanič, 2018; Tsouros i sur., 2019; Sassu i sur., 2021). Tsouros i sur. (2019) u svom preglednom radu navode kako je u 72% istraživanja u poljoprivredi korištena multirotor bespilotna letjelica koja može imati četiri ili više rotora (kvadkopter, heksakopter, oktokopter, itd.).

Slika 2. Bespilotna letjelica s fiksnim krilima (*izvor: www.sensefly.com*)

Slika 3. Multirotor bespilotna letjelica (kvadkopter)

2.3.2. Senzori za daljinsko praćenje vinove loze bespilotnim letjelicama

Bespilotne letjelice opremljene su različitim senzorima i tako postaju snažan alat za daljinsko praćenje različitih karakteristika vegetacije. Uloga senzora je prikupljanje različitih informacija u visokoj prostornoj i vremenskoj rezoluciji koje, daljnjom obradom, omogućavaju praćenje biomase, zdravstvenog stanja vegetacije, vlažnosti tla i ostalih važnih karakteristika u različitim stadijima razvoja biljaka (Tsouros i sur., 2019). Pomoću senzora moguće je bolje razumjeti i prostornu i vremensku varijabilnost na parceli jer omogućavaju prikupljanje i obradu velikih količina podataka istovremeno (Padua i sur., 2019), dok senzori moraju biti lagani, mali i trošiti malo energije za svoj rad, a istovremeno snimati snimke visoke rezolucije (Tsouros i sur., 2019). Senzori koji se koriste rade na principu refleksne spektroskopije, optičke tehnike koja se temelji na mjerenju refleksije elektromagnetskog zračenja na različitim valnim duljinama (slika 4), u vidljivom spektru (400–700 nm), blisko infracrvenom (NIR 700–1300 nm) i toplinsko infracrvenom (7500–15000 nm) (Matese i Di Genaro, 2015).

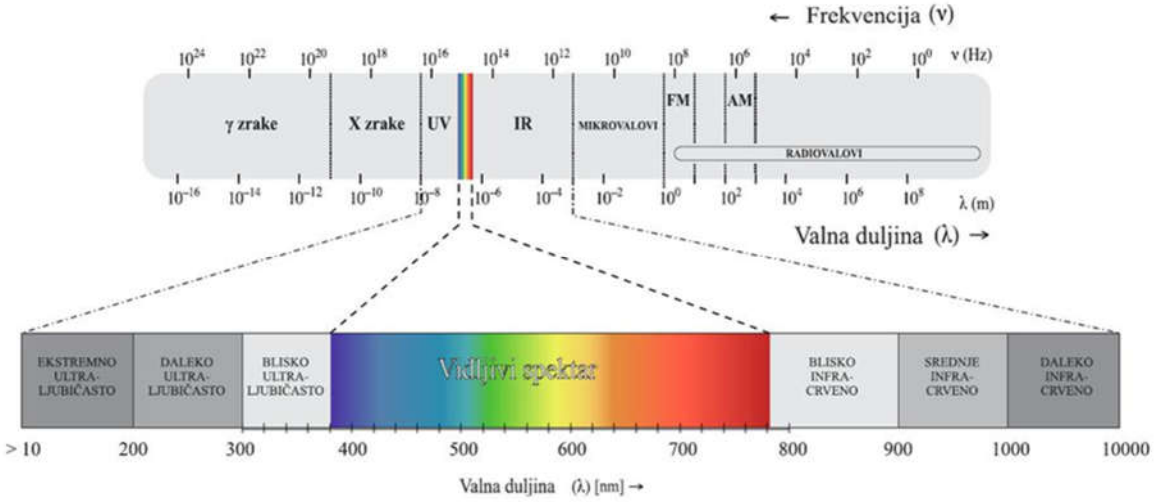

Slika 4. Elektromagnetski spektar (Patrun, 2019)

Najviše korišteni senzori u poljoprivredi pa tako i u vinogradarstvu mogu se podijeliti u četiri grupe prema Tsouros i sur. (2019):

1. RGB senzori (senzori vidljivog dijela spektra)
2. Multispektralni senzori
3. Hiperspektralni senzori
4. Termalni infracrveni senzori

Navedene grupe senzora spadaju u pasivnu grupu senzora koji se koriste za detekciju prirodnih emisija sa Zemljine površine i atmosfere (samo primaju energiju) dok aktivni senzori (LiDAR i RADAR) prenose vlastite impulse zračenja iz svog izvora energije te

potom detektiraju dolazno reflektirano zračenje (šalju i primaju energiju) te su zbog toga manje osjetljivi na vremenske uvjete (Balafoutis i sur., 2017; Padua i sur., 2017).

RGB senzori na bespilotnim letjelicama mogu snimiti površinu iz zračne perspektive, a koriste valne duljine vidljivog dijela spektra (400-700 nm). Ove snimke koriste se za izradu ortofoto snimaka vinograda te je moguće uočiti više karakteristika vegetacije nego s tla. Koriste se i za izradu 3D digitalnog modela reljefa iz kojeg je moguće izračunati visinu biljke, broj biljaka na površini i volumen krošnje s visokom točnošću (Padua i sur., 2017; Andújar i sur., 2019; Tanda i Chiarabini, 2019; Tsouros i sur., 2019). Pri valnim duljinama vidljivog dijela spektra refleksija biljaka je mala zbog apsorpcije svjetlosti od strane fotosintetskih pigmenata (uglavnom klorofila i karotenoida) (Tanda i Chiarabini, 2019). Fotosintetski aktivne biljke, pa tako i vinova loza, ne reflektiraju veću količinu svjetlosti u crvenom i plavom dijelu spektra jer se stvorena energija koristi za procese fotosinteze, dok se nešto više svjetlosti reflektira u zelenom dijelu spektra zahvaljujući fotosintetskim pigmentima te su ljudskom oku takve biljke (listovi) vidljive u zelenoj boji (Hall i sur., 2002).

Multispektralni i hiperspektralni senzori mogu prikupljati informacije o biljnoj apsorpciji i refleksiji svjetlosti u više valnih duljina. Multispektralni senzori prikupljaju informacije u manjem broju spektralnih kanala (od 2-12) dok hiperspektralni senzori prikupljaju informacije iz nekoliko stotina ili tisuća spektralnih kanala, ali u užim rasponima valnih duljina (Hall i sur., 2002; Tanda i Chiarabini, 2019; Tsouros i sur., 2019). Posebno je važan blisko infracrveni spektar (700-1300 nm), nevidljiv ljudskom oku, a u tom dijelu spektra biljke pokazuju visoke reflektivne vrijednosti (više od 65%) (Hall i sur., 2002). Refleksija je vrlo visoka za valnu duljinu od 800 nm (NIR), a što je biljka aktivnija, to će biti veća refleksija i na taj način moguće je razlikovati zone vitalnosti unutar vinograda. Refleksija tla bez pokrova puno je manja nego refleksija vinove loze pri istim valnim duljinama te snimanja s NIR valnim pojasom mogu pomoći u razlikovanju vinove loze od tla (Fraigneau, 2009) te za procjenu vitalnosti vinove loze u određenom vinogradu, kao i za uočavanje razlika unutar samog vinograda (Ozdemir i sur., 2017). Pri valnim duljinama crvenog ruba (engl. *red-edge*) od 680-750 nm, biljke pokazuju najveću refleksiju iz crvenog prema blisko infracrvenom dijelu spektra te je od posebne važnosti razlika između visoke refleksije u blisko infracrvenom spektru i niske refleksije u crvenom spektru koja može biti povezana s vegetativnim stanjem biljke (Tanda i Chiarabini, 2019).

Multispektralni senzori više su korišteni od hiperspektralnih senzora za daljinska praćenja u vinogradarstvu jer su financijski povoljniji, no sve složenija istraživanja i dublje analize zahtijevaju korištenje hiperspektralnih senzora koji pokazuju visok potencijal i budućnost u daljinskim praćenjima vinove loze (Tsouros i sur., 2019.). U istraživanju Zovko i sur. (2019) prikazali su uspješan način korištenja hiperspektralnih senzora za određivanje

vodnog stresa vinove loze uslijed suše na krškim tlima Dalmacije, a autori su identificirali i valne duljine relevantne za određivanje vodnog stresa uslijed suše. To istraživanje doprinosi i mogućnostima razvoja namjenskih senzora za detekciju vodnog stresa. Također, Vanegas i sur. (2018) su primjenom hiperspektralnih senzora pokazali da se trsna uš (filoksera) vinove loze može otkriti prije nego što bude vidljiva vizualnim pregledom, a identificirali su i srednje spektralne potpise za različite razine zaraženosti sorte 'Chardonnay' u dva različita termina, što je bilo preduvjet za generiranje novih vegetacijskih indeksa koji će pokazati zarazu trsnom uši.

Termalni infracrveni senzori prikupljaju informacije o temperaturi i generiraju slike bazirane na temperaturnim podacima. Termalne kamere opažaju zračenje u infracrvenom pojasu elektromagnetskog spektra (900-15000 nm) te se najčešće koriste za vrlo specifične aplikacije (npr. upravljanje navodnjavanjem) (Tsouros i sur., 2019). Povećanjem temperature lista može se detektirati vodni stres uslijed suše zbog specifičnih reakcija biljaka- dolazi do zatvaranja puči, što istovremeno smanjuje transpiraciju i prekida učinak hlađenja biljke (Matese i Di Genaro, 2015). Mjerenje temperature listova i grozdova može biti indikator provodljivosti puči i transpiracije, a bilo kakva promjena u provodljivosti puči utječe i na proces fotosinteze te na taj način i na bujnost vinove loze i razvoj grozdova (Jones i Grant, 2016). Tanda i Chiarabini (2019) u svom su istraživanju, provedenom u Burgenlandu (Austrija), koristili termografske senzore kao dopunu multispektralnim senzorima te na taj način prikupili dodatne informacije o postojanju i razini vodnog stresa vinove loze.

Rad senzora vezan je uz fotosintetsku aktivnost biljke te se promjene povezane s ishranjenošću biljaka, zdravstvenim stanjem i bujnosti mogu detektirati s multispektralnim i hiperspektralnim senzorima. Refleksija lista uvjetovana je različitim faktorima u određenim specifičnim dijelovima spektra: u vidljivom spektru fotosintetskim pigmentima (klorofili i karotenoidi), u blisko infracrvenom strukturom lišća (veličina i rasprostranjenost lisne mase); a u infracrvenom prisutnošću vode i biokemijskih tvari, kao što su lignin, celuloza, škrob, proteini i dušik (Matese i Di Genaro, 2015; Rey Caramés, 2015).

Sustavima za daljinsko praćenje i korištenjem specijaliziranih senzora prikupljaju se podaci o određenom vinogradu. Sama obrada podataka još nije standardizirana odnosno nisu uspostavljene standardizirani protokoli i tehnike analize i vizualizacije potrebnih informacija (Tsouros i sur., 2019). Također, prosječan poljoprivrednik ili vinogradar teško će moći interpretirati velike količine prikupljenih podataka te je potrebno stvoriti izravne i korisne informacije za krajnju upotrebu (Xue i Su, 2017; Padua i sur., 2019), po mogućnosti integrirane u programske pakete za potporu odlučivanju (Jones i Grant, 2016). Isto tako, Pichon i sur. (2019) proveli su istraživanje vezano uz korisnost i dodanu vrijednost relevantnih informacija dobivenih putem daljinskog praćenja bespilotnim

letjelicama za poljoprivredne savjetnike i vinogradare te su zaključili kako su ove informacije bile korisnije poljoprivrednim savjetnicima i kako je potrebno napraviti jednostavnije preglednike koji će biti prilagođeni krajnjim korisnicima, njihovim znanjima i vještinama i omogućavati bolje korisničko iskustvo pri analizi podataka.
Razvijeni su brojni programski sustavi za obradu podataka (software-i) koji omogućavaju bržu i točniju obradu podataka prikupljenih različitim senzorima. Prema Tsouros i sur. (2019) najviše korišteni programski alati za obradu snimaka su Adobe Photoshop, Agisoft Photoscan, QGIS, MATLAB i Pix4D, koji je ujedno i najviše korišten programski paket zbog široke palete mogućnosti pri obradi i vizualizaciji podataka. Obrada podataka prikupljenih različitim senzorima može se obrađivati tehnikom fotogrametrije (izrada 3D digitalnih modela reljefa i ortofoto snimaka), metodom strojnog učenja (modeli regresije i klasifikacijski modeli) te izračunima vegetacijskih indeksa, koja je i najviše korištena metoda u preciznoj poljoprivredi.

2.4. Vegetacijski indeksi

Vegetacijski indeksi su široko rasprostranjeni u okviru aplikacija sustava za daljinsko praćenje. To su prilično jednostavni i učinkoviti algoritmi za kvantitativnu i kvalitativnu procjenu vegetacijskog pokrova, bujnosti, dinamike rasta i mnogih drugih karakteristika vegetacije, a koriste se u praćenju stanja okoliša, očuvanju biološke raznolikosti, poljoprivredi, šumarstvu i drugim srodnih granama (Xue i Su, 2017). Danas je poznato više od 100 vegetacijskih indeksa, a njihova primjenjivost uvelike ovisi o njihovoj specifičnoj primjenjivosti i reprezentativnosti za područje istraživanja (Xue i Su, 2017). Vegetacijski indeksi usko su povezani s razinom reflektirajućeg zračenja u blisko infracrvenom (NIR) i crvenom spektru, prate fotosintetsku aktivnost biljke odnosno mjere fotosintetski aktivnu biomasu (FAB) i koriste se kao indikatori jačine i bujnosti vinove loze (Hall i sur., 2002). Prema Tsouros i sur. (2019) vegetacijski indeksi baziraju se na apsorpciji elektromagnetskog zračenja u vegetacijskom pokrovu te su matematičke transformacije apsorpcije i raspršenja u različitim spektralnim kanalima elektromagnetskog spektra. Dobro poznavanje spektralnih reakcija vegetacije, osnova je za daljinsko praćenje različitih svojstava vegetacije (biomasa, zdravstveno stanje, sadržaj dušika i sl.) jer je dokazano kako su određeni vegetacijski indeksi vezani za određene karakteristike vegetacije. Svaki vegetacijski indeks ima svoju kombinaciju refleksije u različitim spektralnim kanalima kako bi otkrio pojedine karakteristike vegetacije i minimizirao utjecaj vanjskih faktora (npr. osvjetljenje, kalibracija senzora, atmosferski utjecaj, karakteristike tla) (Tsouros i sur., 2019). Vegetacijski indeksi koriste se za

prostornu analizu razvoja vegetacije i mogu poslužiti kao pomoć pri odabiru načina upravljanja vinogradima (Costa i sur., 2019).

Neki od najviše korištenih vegetacijskih indeksa u vinogradarstvu, zajedno sa svojim matematičkim izrazima, navedeni su u tablici 2.

Tablica 2. Najviše korišteni vegetacijski indeksi u vinogradarstvu

Naziv vegetacijskog indeksa	Kratica	Matematički izraz	Referenca
Indeks normalizirane razlike (engl. *Normalised Difference Vegetative Index*)	**NDVI**	$\boldsymbol{NDVI = \frac{NIR - R}{NIR + R}}$	Rouse i sur. (1973)
Indeks normalizirane razlike crvenog ruba (engl. *Normalized Difference Red Edge Index*)	**NDRE**	$\boldsymbol{NDRE = \frac{NIR - RE}{NIR + RE}}$	Buschmann i Nagel (1993)
Zeleni vegetacijski indeks normalizirane razlike (engl. Green Normalised Difference Vegetative Index)	**GNDVI**	$\boldsymbol{GNDVI = \frac{NIR - G}{NIR + G}}$	Gitelson i sur. (1996)
Vegetacijski indeks prilagođen tlu (engl. *Soil-Adjusted Vegetation Index*)	**SAVI**	$\boldsymbol{SAVI = \frac{NIR - R}{NIR + R + L} x(1 + L)}$	Huete (1988)
Optimizirani vegetacijski indeks prilagođen tlu (engl. *Optimized Soil-Adjusted Vegetation Index*)	**OSAVI**	$\boldsymbol{OSAVI = \frac{(NIR - R)}{NIR + R + 0.16}}$	Rondeaux i sur. (1996)
Indeks vodnog stresa (engl. *Crop Water Stress Index*)	**CWSI**	$\boldsymbol{CWSI = \frac{T_{CANOPY} - T_{NWS}}{T_{DRY} - T_{NWS}}}$	Idso i sur. (1981)

Najpoznatiji i najviše korišten vegetacijski indeks za određivanje regionalnih i globalnih karakteristika vegetacije i praćenje rasta i bujnosti je NDVI (Xue i Su, 2017). Njegov izračun bazira se na mjerenjima refleksije u crvenom (R) i blisko infracrvenom (NIR) dijelu elektromagnetskog spektra, izražava se kao broj između -1 i +1 te će bujnija vegetacija imati vrijednosti bliže 1, a manje bujna bliže nula, a negativne vrijednosti indeksa se gotovo nikada ne pojavljuju na lokalitetima pokrivenim vegetacijom (Hall i sur. 2002).

Prema Jorge i sur. (2019) unatoč mnogim prednostima, NDVI nije uvijek najtočniji indeks za otkrivanje anomalija u vegetaciji, posebno ako su dostupni detaljni podaci za crveni (R) i blisko infracrveni spektar (NIR). Kao što je prikazano na slici 5, postoje nagle promjene

između crvene (R) i blisko infracrvene (NIR) razine refleksije koje su vidljive u crvenom rubnom pojasu (RED EDGE- RE). Ova zona je vrlo osjetljiva na promjene u vegetaciji jer čini granicu apsorpcije svjetlosti putem klorofila u crvenom dijelu spektra (R) (680 nm) i raspršivanja u blisko infracrvenom dijelu spektra (NIR) (730-740 nm) zbog same strukture lista.

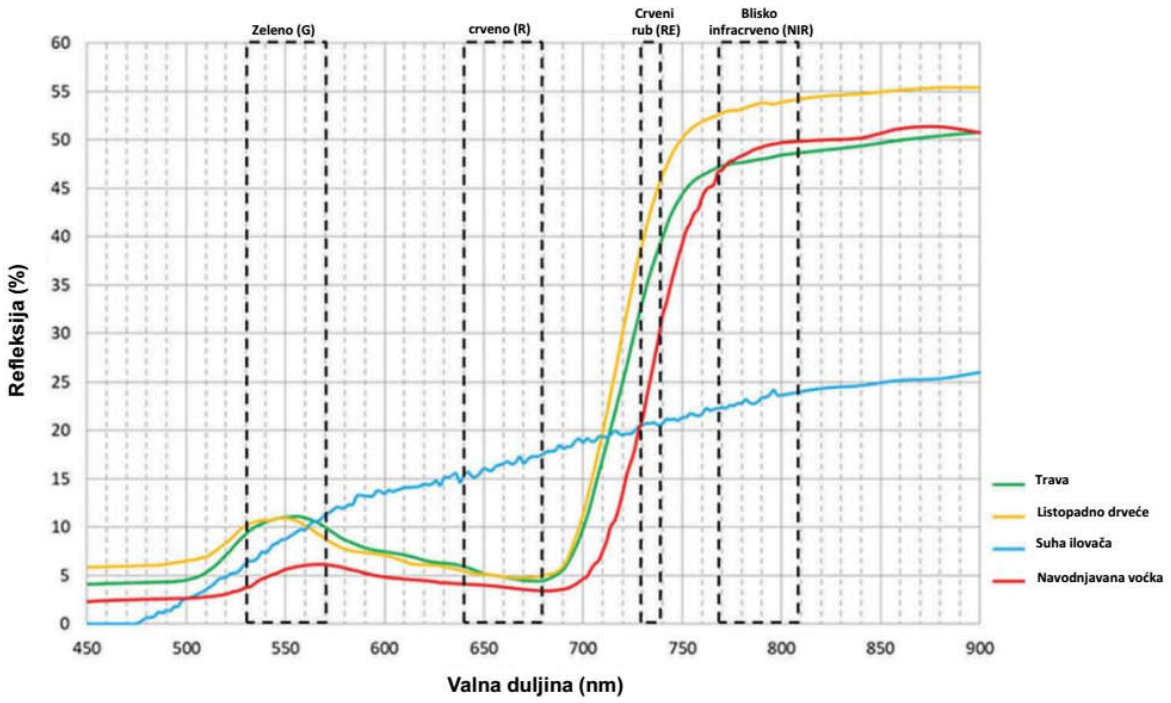

Slika 5. Krivulja spektralne refleksije za različite pokrove tla
(prerađeno prema Jorge i sur., 2019)

Zbog svega navedenog, konstruiran je NDRE indeks, vrlo sličan NDVI, ali se za izračun koriste mjerenja refleksije u rubnom crvenom dijelu (RE) i blisko infracrvenom (NIR) dijelu elektromagnetskog spektra. NDRE ima smanjen efekt zasićenja zbog manje apsorpcije svjetlosti putem klorofila u rubnom crvenom dijelu spektra (RE) (Vicente i sur., 2017).

GNDVI se bazira se na mjerenjima refleksije u zelenom (G) i blisko infracrvenom (NIR) dijelu elektromagnetskog spektra, više je osjetljiv na koncentraciju klorofila u listu te njegove vrijednosti idu od 0-1 (Candiago i sur., 2015).

Sljedeća dva indeksa su vegetacijski indeksi prilagođeni tlu, jer se smatra da su osnovni vegetacijski indeksi (npr. NDVI) osjetljivi na pozadinske i atmosferske faktore kao što su boja i svjetlina tla, zasjenjivanje oblacima, sjene lisne mase. Istraživanja su pokazala da, kada se poveća svjetlina pozadine, NDVI se također sustavno povećava (Xue i Su, 2017.) te su razvijeni SAVI i OSAVI.

SAVI u svom izračunu koristi i faktor prilagodbe tlu (L) koji je prvotnom u istraživanju Huete i sur. (1988) imao optimalnu vrijednost L=0,5 za smanjenje utjecaja tla pri izračunu osnovnih vegetacijskih indeksa (NDVI). Faktor prilagodbe tlu (L) se mijenja sukladno gustoći vegetacije te tako Heute i sur. (1988) za daljnja istraživanja predlažu korištenje L=1 za nisku gustoću vegetacije, L=0.5 za srednju gustoću vegetacije i L=0.25 za visoku gustoću vegetacije (kada je L=0, SAVI=NDVI). Nadalje, istraživanjima se utvrdilo da je faktor prilagodbe tlu (L) vrlo bitan za smanjenje utjecaja refleksije tla, te je Rondeaux i sur. (1996) predložio optimizirani SAVI tj. OSAVI gdje je faktor prilagodbe tlu L=0.16 prikazan kao optimalni faktor prilagodbe tlu u uvjetima umjerene klime za poljoprivredne kulture i travnjake. Uz ovaj faktor prilagodbe tlu (L=0.16) OSAVI vrlo uspješno eliminira utjecaj tla na analizu vegetacije te se koristi za određivanje sadržaja dušika i klorofila u listu te procjene količine nadzemnog pokrova (Xue i Su, 2017).

Svi dosad opisani indeksi koriste podatke iz svega tri kanala elektromagnetskog spektra koje je moguće snimiti daljinskim praćenjem (sateliti, multispektralni ili hiperspektralni senzori). Indeks vodnog stresa, CWSI moguće je izračunati tek nakon korištenja termalnih infracrvenih senzora koji prikupljaju informacije o temperaturi i generiraju slike bazirane na temperaturnim podacima. CWSI koristi se za praćenje vodnog stresa te se bazira na različitim temperaturama listova vinove loze koja je dobro opskrbljena vodom i vinove loze koja pati od suše (Xue i Su, 2017) zbog ranije opisanih specifičnih reakcija biljaka na nedostatak dostupne vode.

Kao najprikladniji za praćenje bujnosti i varijabilnosti vinograda pokazali su se NDVI, NDRE i OSAVI.

2.4.1. Vegetacijski indeksi za praćenje bujnosti i varijabilnosti vinove loze

Praćenje varijabilnosti unutar vinograda osnova je za uspostavu preciznog vinogradarstva i primjenu ciljanog upravljanja vinogradom, prilagođenog specifičnostima unutar vinograda (engl. *site-specific management*). Zadnjih desetak godina provedena su mnoga istraživanja koja su, koristeći vegetacijske indekse (uglavnom NDVI), vrlo uspješno opisivala i povezivala rezultate spektralnih mjerenja s određenim karakteristikama vinove loze kao što su bujnost, prinos, kvalitativna svojstva grožđa, zdravstveno stanje i sl. U nastavku slijedi kronološki pregled takvih istraživanja.

Johnson i sur. (2001) u svom istraživanju, provedenim u Kaliforniji (Napa Valley) 1997. godine, koristili su zračne snimke multispektralnom kamerom (spektralne rezolucije 2m/piksel) kako bi dobili NDVI i odredili zone upravljanja u vinogradu veličine 3 ha. Osim toga, mjerili su i postotak fotosintetski aktivnog sunčevog zračenja, vodni potencijal lista,

sadržaj klorofila u listu, kvalitativne parametre grožđa kao što su sadržaj šećera, kiselina, pH i jabučne kiseline te količinu i masu orezane rozgve. Zoniranjem vinograda u tri proizvodne zone prema bujnosti (visoka, srednja i niska) na osnovu NDVI, proveli su selektivnu berbu grožđa iz sve tri zone i odvojeno vinificirali svako vino, koje je kasnije i organoleptički ocijenjeno. Rezultati istraživanja pokazali su jasnu diferencijaciju između zona niske i visoke bujnosti s obzirom na biomasu-bujnost, vodni stres vinove loze koji je pozitivno korelirao s kvalitetom grožđa i negativno s bujnošću, i što je najvažnije, na istraživane karakteristike grožđa i vina gdje je grožđe iz zone veće bujnosti imalo niži sadržaj šećera i više količine ukupnih kiselina uz viši pH. Zona srednje bujnosti pokazala je dvojake rezultate te sugeriraju ili prilagođavanje granica te zone ili inkorporiranje u postojeće dvije zone. Selektivna berba prema definiranim zonama, omogućila je proizvodnju različitih vina, od kojih jedno u najvišoj kategoriji kakvoće („reserve“), što do tada nije bilo moguće uz uniforman tretman vinograda pri berbi.

Lamb i sur. (2004) proveli su opsežno dvogodišnje istraživanje (1999-2001) u Connawarra regiji u južnoj Australiji u vinogradu sorte 'Cabernet sauvignon' površine 7,3 ha. Koristeći zračne multispektralne snimke prostorne rezolucije 60 cm, za određivanje korelacije NDVI i sadržaja antocijana i ukupnih fenola, zaključili su kako postoji jasna negativna korelacija između NDVI i sadržaja antocijana i ukupnih fenola, a najveća je u fenofazi šare grožđa. Također, zaključili su i kako veličina bobice korelira s NDVI, odnosno, veće količine fotosintetski aktivne biomase (FAB) kod bujnijih trsova uzrokovale su i veće bobice. Nastavno na to, na tim trsovima potvrđena je negativna korelacija između NDVI i sadržaja antocijana i ukupnih fenola.

Martínez-Casasnovas i sur. (2012) proveli su istraživanje 2005. godine u Španjolskoj u vinogradu sorata 'Cabernet sauvignon' (5 ha) i 'Syrah' (2,35 ha). Korištene su multispektralne satelitske snimke spektralne rezolucije 2,8 m za vrednovanje NDVI indeksa pri diferencijaciji različitih zona upravljanja vinogradom s ciljem selektivne berbe. Osim NDVI i satelitskih snimki koristili su senzore za praćenje prinosa i kvalitete, postavljenje na berače grožđa te su vršili mjerenja bujnosti, prinosa i kvalitativnih svojstava grožđa na ciljanim trsovima. Statističkom obradom svih podataka, zaključili su kako je NDVI u fenofazi šare bolje korelirao s kvalitativnim svojstvima grožđa, nego mape prinosa dobivene senzorima za praćenje prinosa i kvalitete, postavljenim na beračima grožđa te su zone definirane uz pomoć NDVI ekonomično rješenje za diferencijaciju dviju zona upravljanja vinogradom s ciljem selektivne berbe.

Fiorillo i sur. (2012.) također su provodili istraživanje u vinogradu sorte 'Sangiovese' u Toskani (Italija) na površini od 1,9 ha u trajanju od 4 godine (2007-2010). Njihov cilj bio je utvrditi povezanost između NDVI vrijednosti u različitim fenofazama i kvalitativnih svojstava grožđa u dva različita termina berbe. Ovo istraživanje je pokazalo kako su podaci prikupljani zračnim snimanjima (NDVI) relevantni za karakterizaciju prostorne varijabilnosti fotosintetski aktivne biomase (FAB) trsa na razini vinograda. Kako NDVI i kemijski parametri kakvoće grožđa nisu direktno povezani, već NDVI govori o strukturnim i biokemijskim parametrima trsa, razlike u fotosintetski aktivnoj biomasi (FAB) (mjerenoj putem NDVI) bile su povezane s razlikama u mjerenim svojstvima ubranog grožđa, što dovodi do zaključka kako su zračne snimke (NDVI) korisne za razlikovanje klasa grožđa u tehnološkoj berbi, dok su lošiji rezultati povezanosti bili uočeni pri kasnoj berbi. Nastavno na to, različite zone bujnosti u vinogradu pokazale su različit način dozrijevanja grožđa u periodu između tehnološke i kasne berbe te na taj način utjecale i na stupanj korelacije između kakvoće grožđa i NDVI mjerenja.

Filippetti i sur. (2013) proveli su dvogodišnje istraživanje (2008-2009) u Toskani (Italija) u vinogradu sorte 'Sangiovese' gdje su na osnovu zračnih snimki napravili NDVI mape od kojih su za daljnje istraživanje odvojili dvije zone- zonu veće bujnosti i zonu manje bujnosti na ukupnoj površini 0,32 ha. Proveli su mjerenja bujnosti i određivanja kvalitativnih svojstava grožđa na ciljanim trsovima, uz analizu tla i analize vina nakon selektivne berbe. Zaključili su kako su trsovi iz veće zone bujnosti imali veću lisnu površinu i prinos, dok je grožđe imalo manje koncentracije šećera i antocijana nego grožđe s trsova iz zone manje bujnosti. Također, uzrok varijabilnosti u bujnosti povezali su s plodnošću tla i sposobnosti zadržavanja vode u tlu. Vina dobivena iz zona manje bujnosti pokazala su veću kvalitetu na senzorskim testovima i kemijskim analizama. Na ovaj način potvrdili su NDVI za određivanje zona veće i manje bujnosti kao i moguće korištenje pri diferencijaciji dviju zona upravljanja vinogradom s ciljem provođenja različitih načina obrade tla i ampelotehničkih zahvata u različitim zonama bujnosti u vinogradu.

Santesteban i sur. (2013) proveli su dvogodišnje istraživanje (2007-2008) u Navarri (Španjolska) u vinogradu sorte 'Tempranillo' na površini od 90 ha, koji je podijeljen u 27 proizvodnih polja. Njihov cilj bio je analizirati je li moguće definirati različite zone upravljanja na razini cijelog vinograda i analizirati prostornu varijabilnost na dvije razine: (i) mikro razina (unutar proizvodnog polja) i (ii) mezo razina (cijeli vinograd, koji obuhvaća sva proizvodna polja). Koristili su multispektralne zračne snimke rezolucije 30 cm, snimljene u fenofazi šare svake godine kako bi dobili vrijednosti NDVI indeksa na svim proizvodnim poljima. Osim toga, mjerili su i električnu provodljivost tla (ECa) i nadmorsku

visinu putem digitalnog modela reljefa. Na 64 ciljana trsa prikupljali su kvantitativne i kvalitativne podatke o trsu i grožđu. Zaključili su da su informacije prikupljene zračnim snimanjem u visokoj rezoluciji relevantne, i s agronomskog i s enološkog aspekta, za definiranje različitih zona upravljanja na razini cijelog vinograda. U ovom istraživanju zone s višim NDVI, nižim ECa i većom nadmorskom visinom imale su veću bujnost, veličinu bobica i prinos što istraživači pripisuju boljoj opskrbljenosti trsa vodom i hranjivima. Direktnu povezanost kvalitativnih svojstava grožđa sa zonama nisu pronašli te smatraju kako kvaliteta grožđa u sušnim predjelima, kao što je Navarra, ovisi o više drugih čimbenika (npr. prinos) koji ovim istraživanjem nisu bili obuhvaćeni. Utjecaj nadmorske visine na rast i razvoj vinove loze nije bio primijećen na razini cijelog vinograda, sve do zoniranja vinograda, što se može iskoristiti i za primjenu različitih ampelotehničkih mjera i različite razine navodnjavanja u proizvodnim poljima, što može utjecati na produktivnost cijelog vinograda. Zaključno, predložili su i selektivnu berbu po proizvodnim poljima i diferencijaciju dva ili tri različita tipa vina iz jednog vinograda.

Urretavizcaya i sur. (2014) proveli su dvogodišnje istraživanje (2010-2011) u Lezi (Španjolska) u vinogradu sorte 'Tempranillo' na površini od 4,2 ha. Cilj ovog istraživanja bio je procijeniti je li rano uzimanje uzoraka grožđa važan alat za definiranje različitih zona unutar vinograda. Koristili su satelitske snimke (QuickBird) u fenofazi šare u godini koja je prethodila istraživanju i naredne dvije godine, kako bi dobili vrijednosti NDVI indeksa i odredili zone bujnosti. Mreža od 60 ciljanih trsova određena je unaprijed na temelju NDVI iz 2009. godine. Uzorci 300 bobica sa svih 60 trsova uzeti su u dva termina- u fenofazi šare i u berbi te su provedene osnovne kvantitativne i kvalitativne analize grožđa. Rezultati dobiveni u fenofazi šare, korišteni su za određivanje dviju zona- standardne i „top“ zone, za proizvodnju različitih tipova vina prema zahtjevima vinarije, s tim da se u okviru „top“ zone minimizira unutarnja varijabilnost. Zone određene u fenofazi šare pokazale su veću proizvodnu relevantnost, ali i veću mogućnost utjecaja na dozrijevanje grožđa sve do berbe (npr. prorjeđivanje grozdova). Zoniranje samo s NDVI pokazalo je manje jasnu razliku među zonama, no s obzirom na veliku količinu ručnog rada i laboratorijskih mjerenja u ovom istraživanju upitno je koliko bi zoniranje na ovaj način bilo ekonomično za proizvođače vina.

Bonilla i sur. (2015) proveli su trogodišnje istraživanje (2010-2012)) u Laguardii (Španjolska) u vinogradu sorte 'Tempranillo' na površini od 1,2 ha. Cilj istraživanja bio je utvrditi iskoristivost daljinskog praćenja za procjenu prostorne varijabilnosti vinograda i povezanost s kvalitativnim svojstvima grožđa na ciljanim trsovima kako bi se definirale različite zone upravljanja unutar vinograda. Na 42 ciljana trsa, koja su odabrana slučajnim

odabirom na temelju zapažanja, provedene su kvantitativne i kvalitativne analize trsa i grožđa u tri različita termina (u fenofazi šare, neposredno prije berbe i nakon opadanja lista), sve tri godine, osim u 2012. godini kada je odabrano dodatnih 12 ciljanih trsova. Korištene su multispektralne zračne snimke spektralne rezolucije 0,5 m kako bi dobili vrijednosti NDVI indeksa i odredili tri različite zone bujnosti unutar vinograda. Rezultati istraživanja pokazali su kako je NDVI dobar indikator bujnosti vinove loze te su svi kvantitativni pokazatelji bujnosti pokazali statistički značajnu razliku između zona. Također, utvrđeno je kako je prostorna varijabilnost unutra vinograda stabilna kroz godine, čak i u različitim klimatskim uvjetima (zadnja godina istraživanja bila je ekstremno sušna). Kvalitativna svojstva grožđa imala su čak i neke neočekivane rezultate (npr. veće količine antocijana u zoni velike bujnosti), no većina ih je bila povezana s varijabilnosti NDVI (pH, sadržaj šećera). Kao važan zaključak navode i da zoniranje u tri zone bujnosti nije statistički opravdano te se u praksi za selektivnu berbu i različito upravljanje unutar vinograda preporučuje određivanju dviju zona bujnosti na temelju NDVI, koji je isplativ, lak i objektivan način za prikupljanje prostornih informacija u vinogradu.

Candiago i sur. (2015) proveli su 2014. godine evaluaciju multispektralnih snimaka bespilotnom letjelicom i vegetacijskih indeksa (NDVI, GNDVI i SAVI) u Sorrivoli (Italija) u vinogradu sorte 'Cabernet sauvignon' na površini od 0,7 ha bez mjerenja na tlu te zaključili kako su podaci i informacije dobiveni na ovaj način dobri za opise stanja u kojima se trsovi nalaze. Moguće je vidjeti ekscesna područja u vinogradu te na taj način pomoći proizvođaču u donošenju odluka o upravljanju proizvodnjom. Smatraju kako su multispektralne snimke bespilotnom letjelicom brz, pouzdan i ekonomičan način procjene stanja usjeva i kako mogu u potpunosti zamijeniti osobne obilaske vinograda, iako su im informacije proizvođača bile potrebne za validaciju snimaka dobivenih multispektralnim kamerama.

Ortega-Blu i Molina-Roco (2016) proveli su jednogodišnje istraživanje (2004) u Casablanci i Maipo (Čile) u dva različita vinograda (sorte 'Cabernet sauvignon' i 'Chardonnay' na površini oko 2 ha). Cilj ovog istraživanja bio je (a) usporediti dva vegetacijska indeksa- NDVI iz zračnih snimanja i GVI (*Green Vegetation Index*) iz kalibriranih satelitskih snimki (QuickBird) kao osnove za definiranje različitih zona upravljanja unutar vinograda i (b) evaluirati korištenje senzora za električnu provodljivost tla za definiranje različitih zona upravljanja unutar vinograda. Spektralna rezolucija obaju snimki bila je približno ista- 2-2,4 m. Temeljem oba indeksa, definirane su tri zone bujnosti (velika, srednja i mala). Na 150 ciljanih trsova po ha proveli su kvantitativne i kvalitativne analize trsa i grožđa. Komercijalne zračne snimke NDVI i satelitske snimke GVI pokazale su sličnost u prikazu

prostorne varijabilnosti u vinogradu sorte 'Cabernet sauvignon', dok je vinogradu sorte 'Chardonnay' (koji je i manje varijabilan po svim ostalim pokazateljima) bolji indeks bio GVI. Također, GVI je bio i prediktivniji za tri zone bujnosti prema parametru prinosa. Električna provodljivost tla nije bila dobar prediktor različitih zona bujnosti. Zaključili su kao je u manje varijabilnim vinogradima teško opravdati tri zone bujnosti definirane kroz komercijalne NDVI snimke te kako su GVI snimke bolji alat za definiranje različitih zona upravljanja unutar vinograda i za prostornu i vremensku usporedbu varijabilnosti između vinograda i vegetacijskih sezona.

Ledderhof i sur. (2016) proveli su dvogodišnje istraživanje (2008-2009) u St. Davisu, Ontario (SAD) u četiri vinograda sorte 'Pinot crni' na površini od 0,41 ha, 0,66 ha, 0,79 ha i 0,99 ha. Cilj istraživanja bio je odrediti može li zračno snimanje multispektralnim kamerama razdvojiti kvalitativne zone unutar vinograda sorte 'Pinot crni' kako bi se definirala područja s najkvalitetnijim trsovima za proizvodnju vrhunskih vina. Osim toga, proveli su istraživanje s različitim rezolucijama snimaka, kako bi odredili onu idealnu za takvo istraživanje. Ukupno su izdvojili 317 ciljanih trsova nas svim lokacijama na kojima su provedena kvantitativna i kvalitativna mjerenja trsa i grožđa, te ukupno 66 ciljanih trsova na svim lokacijama za mjerenje vodnog statusa vinove loze. Multispektralna zračna snimanja proveli su četiri puta tijekom vegetacije u 2008. godini te tri puta u 2009. godini (u pravilu jednom mjesečno). Zaključili su kako su zračna snimanja uspješno detektirala varijabilnost unutar vinograda kroz NDVI u rezoluciji 3x3 piksela (≈1,15 x 1,15 m) na snimkama u kojima su maskirani pikseli koji ne pripadaju vinovoj lozi te kako su negativnu korelaciju s NDVI pokazali: sadržaj šećera, pH, antocijani, a pozitivnu: prinos, broj grozdova, masa grozda, masa bobice i vodni status. Ukupne kiseline imale su različite vrijednosti podataka, što autori pripisuju klimatskim uvjetima u vegetacijskim sezonama. Kao važan zaključak izdvajaju i činjenicu da nisu pronašli idealan termin zračnih snimanja koji bi najbolje predvidio bujnost i kvalitativna svojstva grožđa u berbi.

Gatti i sur. (2017) proveli su dvogodišnje istraživanje (2012-2013) u Ziano Piacentino (Italija) u vinogradu sorte 'Barbera' na površini od 0,64 ha. Cilj istraživanja je bio evaluirati NDVI zone bujnosti dobivene satelitskim snimkama (RapidEye, rezolucije 5 m) mjerenjem i analizom kvantitativnih i kvalitativnih svojstava vinove loze i grožđa te predložiti strategiju upravljanja vinogradom koja će biti najučinkovitija za proizvođača vina. Temeljem NDVI snimki, komercijalno snimljenih i obrađenih 2010. godine, odredili su tri različite zone bujnosti unutar vinograda- zonu veće, srednje i manje bujnosti i unutar svake 24 ciljana trsa na kojima su provedena sva mjerenja, uključujući i sadržaj osnovnih makroelemenata u listu (N, P, K, Mg, Ca, S, Fe, B). Zaključili su kako su satelitske snimke uspješno

detektirale varijabilnost unutar vinograda kroz NDVI zoniranje. Također, utvrdili su povezanost NDVI i zona bujnosti s vegetativnim svojstvima vinove loze, prinosom i kvalitativnim svojstvima grožđa. Nadalje, zona manje bujnosti pokazala se najboljom u balansu kvalitativnih svojstava grožđa za sortu Barbera, pri čemu su uz visoke koncentracije šećera zadržane i značajne količine kiselina. Smatraju kako ovo istraživanje ima visoku praktičnu vrijednost jer može dati izbor proizvođačima pri upravljanu vinogradom, na način da ili provode selektivnu berbu prema kvalitativnim zonama ili usmjeravaju agro i ampelotehničke mjere (prvenstveno gnojidbu) prema postizanju zone manje bujnosti u cijelom vinogradu, kako bi izbjegli nepotrebne troškove i doprinijeli održivoj vinogradarskoj proizvodnji.

Matese i sur. (2017) proveli su jednogodišnje istraživanje (2015) u Navarri (Španjolska) u vinogradu sorte 'Tempranillo' na površini od 7,5 ha. Cilj istraživanja bio je evaluirati i usporediti vegetacijske indekse (NDVI) za procjenu varijabilnosti vinograda u fenofazi šare, pri čemu su koristili satelitske snimke (Sentinel-2) i snimke bespilotnom letjelicom (filtrirane (samo redovi) i nefiltrirane NDVI snimke) rezolucije 5 cm, te ih usporediti s kvantitativnim i kvalitativnim svojstvima vinove loze. Nadalje, pomoću digitalnog modela reljefa, definirali su i opisne indekse lisne mase trsa (širinu, visinu i volumen). Na 92 ciljana mjesta označili su 10 trsova na kojima su provedena kvantitativna i kvalitativna mjerenja trsa i grožđa. Zaključili su kako su satelitske snimke i nefiltrirane NDVI snimke pokazale isti prostorni raspored varijabilnosti unutar vinograda, a filtrirane NDVI snimke imale su gotovo obrnuto raspoređene zone varijabilnosti. To objašnjavaju tako da na nefiltriranim snimkama i satelitskim snimkama (koje su lošije rezolucije) nije moguće odvojiti NDVI komponentu koja se odnosi na geometriju i količinu lisne mase trsa od stvarne, direktne spektralne NDVI komponente koja dolazi od refleksije lista, odnosno, filtrirane NDVI snimke pokazale su mogućnost detekcije ekscesnih područja u vinogradu uslijed vodnog stresa, a koji je utjecao i na kvalitativna svojstva grožđa (niži šećer).

Reynolds i sur. (2018) proveli su opsežno trogodišnje istraživanje (2015-2017) u Ontariju (Kanada) u ukupno 12 vinograda- 6 sorte 'Cabernet franc' i 6 sorte 'Rizling' površine 1-2 ha. Cilj istraživanja bio je ispitati korelacijske odnose između vegetacijskih indeksa (NDVI) i kvantitativnih i kvalitativnih svojstava vinove loze i grožđa. Za prikupljanje podataka i stvaranje karti varijabilnosti unutar vinograda korišteni su bespilotna letjelica i GreenSeeker senzor (Trimble Navigation, SAD) montiran na traktor. Obje platforme korištene su za dobivanje NDVI karti u vinogradima, a u svakom vinogradu odabrano je 80-100 ciljanih trsova za sve daljnje analize kvantitativnih i kvalitativnih svojstava vinove loze i grožđa. Osim toga, na bespilotnim letjelicama korištena je i termalna kamera, a u

vinogradima je mjerena vlažnost tla te vodni potencijal u listu vinove loze. Zaključili su kako su u većini vinograda UAV NDVI karte bile usporedive s GreenSeeker NDVI kartama. Općenito, postojale su dobre izravne prostorne korelacije između UAV i GreenSeeker NDVI karti u odnosu na vodni potencijal lista, vlagu tla, visinu vinove loze i sadržaj kiselina, a obrnute prostorne korelacije sa sadržajem šećera i pH. Bilo je i mnogo situacija u kojima su karte dobivene iz termalnih podataka bile obrnuto prostorno korelirane s NDVI. Zaključuju kako je snimanje bespilotnim letjelicama pogodno za dobivanje snimaka visoke rezolucije koje mogu odrediti prostornu varijabilnost mnogih svojstava vinove loze unutar vinograda kao što su: bujnost, vodni stres, status ishranjenosti, zdravstveno stanje, parametre prinosa i svojstva grožđa.

Padua i sur. (2019) proveli su jednogodišnje istraživanje (2018) u Villa Realu (Portugal) u vinogradu sorte 'Malvasia Fina' na površini od 0,3 ha. Cilj istraživanja bio je evaluirati NDVI karte bujnosti dobivene snimanjem bespilotnom letjelicom s multispektralnom, RGB i termalnom kamerom u različitim fenofazama razvoja vinove loze. Koristili su dva pristupa: (1) NDVI karte cijelog vinograda i (2) NDVI karte trsova vinove loze (automatski detektiranih unutar redova). Prostorne analize dobivenih karti bujnosti, temperature i visine vinove loze, napravljene su s ciljem povezivanja karti bujnosti s potencijalnim vodnim stresom i visinom vinove loze. Snimanja bespilotnom letjelicom napravljena su u pet različitih termina koji se poklapaju s fenofazama razvoja: cvatnja (svibanj i lipanj), razvoj bobice grozda (srpanj), šara (kolovoz) i berba (rujan). Karte bujnosti klasificirane su u tri zone bujnosti- zonu veće, srednje i manje bujnosti. Različiti rezultati dobiveni su za dva različita pristupa, kao i za dinamiku razvoja vinove loze tijekom vegetacijske sezone. Zaključili su kako su podaci dobiveni filtriranjem samo vinove loze pokazali veću korelaciju s ostalim mjerenim parametrima (vodni stres i visina vinove loze) te prikazali točnu raspodjelu varijabilnosti unutar vinograda. Zaključuju kako je metoda kreiranja NDVI karti bujnosti omogućila bolje razumijevanje varijabilnosti unutar vinograda, a i omogućava proizvođačima pravovremene reakcije na uočene probleme.

Ferrer i sur. (2020) proveli su trogodišnje istraživanje (2015-2017) u Canelonesu (Južni Urugvaj) u vinogradu sorte 'Tannat' površine 1,8 ha. Cilj istraživanja bio je detektirati varijabilnost unutar vinograda koristeći zračne snimke (rezolucije 0,2 m), a proveli su i mjerenja kvantitativnih i kvalitativnih svojstava vinove loze na 189 ciljanih trsova. Kreirali su NDVI mapu vinograda te odredili 3 različite zone bujnosti- zonu veće, srednje i manje bujnosti. Zaključili su kako su se tri određene zone bujnosti pokazale stabilnima kroz sve tri godine istraživanja, što smatraju da je povezano sa svojstvima tla, nagibom i dostatnom količinom vode. Također, NDVI pozitivno je korelirao s mjerenim parametrima

vegetativnog rasta i razvoja vinove loze, prinosom, veličinom bobice, ali i s količinom ukupnih kiselina. Negativna korelacija potvrđena je za pH, sadržaj šećera, sadržaj fenola i antocijana u bobicama. Smatraju kako NDVI može biti dobar alat za određivanje i kategoriziranje zona bujnosti s ciljem različitog upravljanja vinogradom i selektivne berbe za različite kategorije vina, ali i koristan alat za potporu odlučivanju o provedbi pojedinih agro i ampelotehničkih mjera u vinogradu.

Oldoni i sur. (2021) proveli su dvogodišnje istraživanje (2017-2018) u Sao Paolu (Brazil) u vinogradu sorte 'Chardonnay' površine 1,1 ha koji su podijelili na dva podjednaka područja za potrebe istraživanja. Cilj istraživanja bio je utvrditi može li se NDVI mapiranje nakon fenofaze šare koristiti za procjenu bujnosti vinove loze, kvalitativnih svojstava grožđa i vodni status u trenutku berbe. Korišten je ručni senzor (Crop Circle, Holland Scientific) za određivanje NDVI te su temeljem NDVI vrijednosti određene dvije zone bujnosti- zona veće i manje bujnosti. Na 12 ciljanih mjesta (po 6 u svakoj zoni bujnosti) prikupljali su kvantitativne i kvalitativne podatke o vinovoj lozi i grožđu. NDVI je pozitivno korelirao s prinosom, brojem i masom grozdova, no smatraju kako se zbog izrazito kišnih uvjeta 2017. godine NDVI nije mogao koristiti za praćenje dozrijevanja grožđa u vinogradu. No, kada su nakon fenofaze šare normalni klimatski uvjeti za to područje (mala količina oborina) NDVI mape su korisne za praćenje rasta i razvoja vinove loze, provedbu različitog upravljanja vinogradom i selektivnu berbu.

Pastonchi i sur. (2020) proveli su trogodišnje istraživanje (2017-2019) u Toskani (Italija) u vinogradu sorte 'Sangiovese'. Cilj istraživanja bio je evaluirati i usporediti satelitske snimke (Sentinel-2, rezolucije 10 m) i snimke multispektralnom kamerom s bespilotne letjelice u prikazu varijabilnosti vinograda putem NDVI, pri čemu su korištene nefiltrirane i filtrirane NDVI snimke rezolucije 3,5 cm. Također su rađena i mjerenja kvantitativnih i kvalitativnih svojstava vinove loze (prinos, ukupna suha tvar i masa orezane rozgve) na 54 ciljana trsa. Na osnovu satelitskih snimaka NDVI određene su tri zone bujnosti- zona veće, srednje i manje bujnosti, koje su potvrđene i multispektralnim NDVI snimkama. Evaluacijom tri različita seta podataka, zaključili su kako su bolju korelaciju imale satelitske snimke NDVI i nefiltrirani NDVI, no sva tri seta podataka uspješno su detektirala varijabilnost unutar vinograda i omogućavaju definiranje različitih zona bujnosti i zona upravljanja vinogradom, a smatraju kako satelitske snimke niže rezolucije ne mogu biti korištene za neke specifične aplikacije u vinogradu, već za dobivanje šire slike stanja.

Puno manje korišteni i istraživani vegetacijski indeksi za praćenje bujnosti i varijabilnosti u nasadima vinove loze su NDRE (Indeks normalizirane razlike crvenog ruba) i OSAVI

(Optimizirani vegetacijski indeks prilagođen tlu). No, razvojem multispektralnih i hiperspektralnih kamera, kao i sve boljim razumijevanjem spektralnog potpisa vinove loze i ovi indeksi dobivaju na važnosti pri praćenju varijabilnosti unutar vinograda.
Prema D`Urso i sur. (2018) NDRE indeks naglašava činjenicu da na refleksiju u crvenom dijelu spektra prije svega utječe prisutnost klorofila i manje količine biomase. NDVI ima linearno kretanje indeksa u ranim fazama rasta i razvoja biljaka kada je količina biomase ograničena, no kada je biljka u kasnijoj fazi rasta i razvoja, NDVI pokazuje zasićenje velikom količinom biomase. Suprotno tome, indeks NDRE ima linearni trend u svim fazama rasta i razvoja biljaka te je najbolji pokazatelj za prepoznavanje jačih i zdravijih biljaka od onih slabijih, čak i u kasnijim fazama rasta s većim količinama biomase. To se može uspješno iskoristiti u kasnijim fenofazama praćenja varijabilnosti i bujnosti vinove loze (npr. u fenofazi dozrijevanja grožđa). Slične zaključke navode i Viña i Gitelson (2005) koji, zbog gubitka osjetljivosti NDVI indeksa za procjenu bujnosti na usjevima umjerene do visoke biomase, predlažu korištenje NDRE indeksa za takve procjene.

Pourezza i sur. (2020) proveli su 2018. godine istraživanje vezano uz određivanje sadržaja dušika u vinogradu stolnog grožđa, u Selmi (Kalifornija) koristeći daljinska snimanja bespilotnom letjelicom i više vegetacijskih indeksa, istražujući kako će razlike u sadržaju dušika u vinovoj lozi biti detektirane putem različitih vegetacijskih indeksa. Zaključili su kako je, između ostalih vegetacijskih indeksa, NDRE pokazao najbolju povezanost sa sadržajem dušika, a najviše korišteni NDVI nije bio toliko dobar u detekciji sadržaja dušika. Na osnovu rezultata istraživanja, između 20 testiranih vegetacijskih indeksa, NDRE se pokazao kao najpouzdaniji u detekciji sadržaja dušika u listu u dvije fenofaze razvoja (cvatnja, berba).

Jorge i sur. (2019) koristili su NDRE indeks za detekciju nepravilnosti navodnjavanja u nasadima maslina i vinove loze te su zaključili kako je NDRE posebno koristan pri detekciji minimalnih promjena u vegetaciji, čak i kada vegetacija ne prekriva tlo u potpunosti.

Mnogi istraživači koristili su NDRE indeks na drugim kulturama, pa tako Boiarskii i Hasegawa (2019) u svom radu uspoređuju NDVI i NDRE pri otkrivanju razlika u vegetaciji i sadržaju klorofila na različitim kulturama s različitim razmakom sadnje i u različitim fazama razvoja. Zaključuju kako je NDRE moguće koristiti kao vrlo osjetljiv indeks za praćenje sadržaja klorofila, dok NDVI nije bio učinkovit u detekciji razlika u vegetaciji. Slične rezultate objavljuju i Carneiro i sur. (2019a) koji su ispitivali povezanost vegetacijskih indeksa i svojstava kikirikija u različitim fazama razvoja, te zaključili kako je

NDRE imao bolju povezanost s proizvodnim svojstvima kikirikija nego NDVI te ga preporučuju za prostorno i vremensko praćenje varijabilnosti svojstava kikirikija. Istraživanja na soji (Carneiro i sur., 2019b) pokazala su identične rezultate korištenja NDRE indeksa pri kreiranju karti prostorne varijabilnosti u usjevima soje. NDRE je, u trenutku kada ja biljka potpuno pokrila tlo, pokazao puno bolje korelacije između pokazatelja kvalitete nego NDVI. Također, istraživanja varijabilnosti na šećernoj repi (Vicente i sur., 2017) pokazala su kako je NDRE uspješno mapirao male i vrlo važne prostorne razlike u sadržaju klorofila unutar proizvodnih površina, za razliku od NDVI koji je prikazivao homogene zone sadržaja klorofila u različitim tretmanima navodnjavanja i gnojidbe. NDRE uspješno se koristi i za klasifikaciju vrste usjeva putem satelitskih snimaka, uz točnost višu od 60% (Üstüner i sur., 2014). NDRE indeks dobiven multispektralnim snimkama korišten je i za razvoj praktičnog sustava za potporu odlučivanju kojim su prostorne karakteristike polja i vrijednosti indeksa NDRE prevedeni u preporuku primjene dušika u nasadima kukuruza tijekom vegetacijske sezone u Nebraski (SAD) (Thompson i Puntel, 2020). Na ovaj način pokazana je i izuzetna praktična vrijednost korištenja vegetacijskih indeksa za preciznu poljoprivredu, povećanje učinkovitosti gnojidbe i minimiziranje negativnih utjecaja na okoliš.

Najmanje istražen i korišten vegetacijski indeks je OSAVI (Optimizirani vegetacijski indeks prilagođen tlu), no nekoliko istraživača koristilo ga je za procjenu vodnog stresa, sadržaja klorofila i količine zelene biomase.
Soubry i sur. (2016) proveli su 2015. godine istraživanje u vinogradu sorte 'Malagouzia' u regiji Epanoma (Grčka) s ciljem procjene vodnog stresa i zrelosti grožđa koristeći bespilotnu letjelicu opremljenu multispektralnom i RGB kamerom. Koristeći nekoliko vegetacijskih indeksa (NDVI, NDRE, GNDVI, OSAVI, TCARI/OSAVI) zaključili su kako je kombinirani indeks TCARI/OSAVI pokazao najbolju korelaciju sa svojstvima kakvoće (pH, BRIX) i vodnim stresom. Naime, kombinirani indeks pokazuje da je datum berbe bio optimalan i to jasno navodi usporedbom indeksa dva dana prije berbe, u kojem trenutku je bila izražena mogućnost vodnog stresa, a na sam dan berbe nisu bili vidljivi znakovi vodenog stresa. Za korelaciju rezultata uzorka grožđa i TCARI/OSAVI indeksa s obzirom na zrelost grožđa, detektirana je mala prosječna razlika u vrijednostima "manje zrelog" i "zrelog" grožđa, a i pH vrijednosti "manje zrelog" grožđa je bila nešto niža.

Prema izvješću Kidman i sur. (2017) u Coonawarra vinogradima, gdje su istraživali optimizaciju navodnjavanja za proizvodnju kvalitetnih vina, status ishranjenosti vinove loze dušikom prilično je dobro predviđen pomoću vegetacijskih indeksa (NDVI, MCARI, OSAVI) dobivenih snimanjem bespilotnom letjelicom uz pomoć multispektralne kamere.

OSAVI je snažno korelirao s indeksom sadržaja klorofila, kao i prinosom kod sorte 'Shiraz'. U vinogradu sorte 'Cabernet sauvignon' vrijednosti klorofila mjerene kroz OSAVI, pokazale su se među najvišim vrijednostima izmjerenim u regiji što potvrđuje važnost korištenja daljinskog istraživanja za procjenu dušika u vinovoj lozi. OSAVI indeks bio je posebno odabran za vegetaciju s niskim indeksom lisne površine (LAI) kao što je vinova loza. NDVI vrijednosti za ovaj vinograd nisu bile među najvišima u regiji, pa dovode u pitanje valjanost upotrebe NDVI za procjenu sadržaja dušika u vinovoj lozi. Ti odnosi mogu u budućnosti vinogradarima omogućiti ciljano upravljanje proizvodnjom i primjenu dušičnih gnojiva.

Prema preglednom radu Ihuoma i Madramootoo (2017) gdje su navedena najnovija dostignuća u praćenju vodnog stresa kod biljaka, vegetacijski indeksi (NDVI, OSAVI, TCARI/OSAVI) navedeni su kao korisni u praćenju promjena kod usjeva koje su uzrokovane vodnim stresom i to zahvaljujući pozitivnoj korelaciji sa zatvaranjem puči i vodnim potencijalom lista. Isto tako, autori navode kako su potrebna dodatna istraživanja osjetljivosti tih indeksa na razini lisne mase biljke, kako bi mogli biti korišteni za precizno navodnjavanje.

Fern i sur. (2018) koristili su vegetacijske indekse (NDVI i OSAVI) za procjenu vrste pokrova i količine zelene mase na pašnjacima u polusušnim područjima Texsasa (SAD). Zaključili su kako je OSAVI indeks, dobiven satelitskim snimkama (Landsat 8-OLI), najbolji za detekciju vrste pokrova i količine zelene mase jer je uspješno detektirao travnati i drvenasti pokrov, kao i tlo bez vegetacije (preciznost više od 95%) te je minimizirao utjecaj visoke razine varijabilnosti tla na analizu vegetacije.

2.5. Kvalitativno zoniranje vinograda i selektivna berba

Prema svim dosadašnjim istraživanjima, neupitno je postojanje varijabilnosti unutar vinograda koja je vezana uz različite faktore uzgoja vinove loze, od podneblja i terroira, sortnih obilježja pa sve do agrotehničkih i ampelotehničkih mjera kojima se osigurava stabilan prinos i ekonomična vinogradarska i vinarska proizvodnja.
Korištenjem vegetacijskih indeksa, dobivenih proksimalnim snimanjima ili daljinskim praćenjem, kao alata za određivanje zona bujnosti unutar vinograda, može se na brži i precizniji način uočiti varijabilnost u vinogradu i s njom povezane vegetativne i kvalitativne karakteristike vinove loze i grožđa. O bujnosti i prinosu ovisi postizanje optimalne kakvoće grožđa za željena vina (Poni i sur., 2017). Određivanjem zona bujnosti indirektno se mogu

odrediti i kvalitativne zone u vinogradu, čije je određivanje značajno za cjelokupno upravljanje i donošenje relevantnih odluka za vinogradarsku proizvodnju kao što su precizna tretiranja ili selektivna berba na osnovu kvalitete grožđa.

Sastavnice prinosa mogu se mjeriti kroz vegetativni i generativni potencijal vinove loze, te govore o bujnosti koja je rezultat okolinskih uvjeta i tehnoloških zahvata, ali i obilježje sorte (Maletić i sur., 2008). Najčešće se prate kroz mjerenja prinosa po trsu, broju grozdova po trsu, prosječne mase grozda, omjerom prinosa i mase orezane rozgve (Ravazov indeks (Ravaz, 1903)). Standardni i najčešće korišteni parametri za procjenu kakvoće grožđa i mošta su sadržaj šećera, ukupnih kiselina i pH vrijednost. Njihove pojedinačne vrijednosti, ali i međusobni omjeri važni su za praćenje dozrijevanja grožđa i određivanje optimalnog roka berbe sukladno zahtjevima proizvođača vina. Parametri kakvoće ovise o svim čimbenicima uzgoja vinove loze- tlu, klimi, podlozi, sorti, ampelotehničkim i agrotehničkim mjerama koji se provode u vinogradu (Maletić i sur., 2008). Sama kvaliteta grožđa ili „skala“ procjene kvalitete grožđa nije još utvrđena (Maynard, 2015) jer je vrlo teško utvrditi koja su to kvalitativna svojstva za procjenu kvalitete grožđa, odnosno, kvaliteta i njene sastavnice dio su subjektivne procjene proizvođača vina sukladno tipovima vina koja se žele proizvesti. U svom preglednom radu Poni i sur. (2017) navode kako je pronalazak zajedničke definicije „kvalitete" za vinsko grožđe težak zadatak jednostavno zato što je kvaliteta, koja ovisi o individualnom doživljaju vina, stilskim preferencijama, varijacijama berbe i brojnim drugim čimbenicima, izuzetno subjektivna. Na temelju „ciljanog“ tipa vina, „kvaliteta" grožđa često odražava sasvim različite „optimalne načine dozrijevanja grožđa“, a „kvaliteta“ može biti prisutna u svakoj kategoriji vina, od stolnih vina pa sve do vrhunskih vina. Stoga bi optimalna zrelost grožđa odgovarala izrazito različitom sastavu grožđa ovisno o tipu vina koje se želi proizvesti (npr. svježa bijela pjenušava vina u odnosu na odležana crna vina), a vremenska identifikacija optimalne zrelosti grožđa presudna je odluka. Isti autori navode kako je upotreba neinvazivnih metoda za procjenu i razumijevanje varijabilnosti unutar vinograda (npr. daljinsko praćenje putem vegetacijskih indeksa) put prema stvaranju željene kvalitete uz pomoć preciznog upravljanja vinogradarskom proizvodnjom.

2.5.1. Relevantnost vegetacijskih indeksa za kvalitativno zoniranje

Povezanost zona bujnosti sa sastavnicama prinosa i kvalitativnim svojstvima grožđa potvrđena je kroz mnoga dosadašnja istraživanja. Koristeći mjerenja sastavnica prinosa i kvalitativnih svojstava grožđa na ciljanim trsovima u samom eksperimentalnom nasadu, dosadašnja istraživanja imala su za cilj evaluirati vegetacijske indekse i njihovu

prediktivnu mogućnost za kvalitativno zoniranje vinograda na osnovu bujnosti vinove loze (Fiorillo i sur., 2012; Bonilla i sur., 2015; Ledderhof i sur., 2016; Gatti i sur., 2017; Ferrer i sur., 2020). Na taj način moguće je odrediti zone manje bujnosti i manjeg prinosa (engl. *low vigour and yield*), a više kvalitete grožđa te zone veće bujnosti i većeg prinosa (engl. *high vigour and yield*), a niže kvalitete grožđa (Bramley i Hamilton, 2004; Bramley i sur., 2011b; Bonilla i sur., 2015).

Već prije navedena istraživanja (opisana u poglavlju 2.4.1. Vegetacijski indeksi za praćenje bujnosti i varijabilnosti vinove loze) potvrdila su definirane zone bujnosti putem mjerenja na ciljanim trsovima, odnosno validirala su vegetacijske indekse kao indirektne prediktore sastavnica prinosa i kvalitativnih svojstava grožđa.

Tako je povezanost sastavnica prinosa sa zonama bujnosti potvrđena kod:

a) Prinos po trsu: Johnson i sur. (2001); Martínez-Casasnovas i sur. (2012); Fiorillo i sur. (2012); Filippetti i sur. (2013); Santesteban i sur. (2013); Urretavizcaya i sur. (2014); Bonilla i sur. (2015); Ortega-Blu i Molina-Roco (2016); Ledderhof i sur. (2016); Gatti i sur. (2017); Matese i sur. (2017); Pastonchi i sur. (2020); Ferrer i sur. (2020) i Oldoni i sur. (2021);
b) Broj grozdova po trsu: Martínez-Casasnovas i sur. (2012); Ledderhof i sur. (2016); Gatti i sur. (2017); Reynolds i sur. (2018) i Oldoni i sur. (2021);
c) Prosječna masa grozda: Bonilla i sur. (2015); Ledderhof i sur. (2016); Gatti i sur. (2017); Ferrer i sur. (2020) i Oldoni i sur. (2021);
d) Masa orezane rozgve: Johnson i sur. (2001); Bonilla i sur. (2015); Ortega-Blu i Molina-Roco (2016); Pastonchi i sur. (2020) i Ferrer i sur. (2020).

Kako navode istraživači, u različitim zonama bujnosti (uglavnom zone veće, srednje i manje bujnosti) određenih putem vegetacijskih indeksa (uglavnom NDVI), zone veće bujnosti imale su veći prinos po trsu, veći broj grozdova po trsu, veću prosječnu masu grožđa i veću masu orezane rozgve u odnosu na određene zone manje ili srednje bujnosti. U nekim slučajevima (Johnson i sur., 2001; Bonilla i sur., 2015.) zaključeno je kako zoniranje u tri zone bujnosti nije statistički opravdano te se u praksi za selektivnu berbu i različito upravljanje unutar vinograda preporučuje određivanje dviju zona bujnosti na temelju vegetacijskih indeksa.

Povezanost kvalitativnih svojstava sa zonama bujnosti potvrđena je u sljedećim istraživanjima:

a) Koncentracija šećera u grožđu: Johnson i sur. (2001); Filippetti i sur. (2013); Urretavizcaya i sur. (2014); Bonilla i sur. (2015); Ortega-Blu i Molina-Roco (2016);

Ledderhof i sur. (2016); Gatti i sur. (2017); Reynolds i sur. (2018); Ferrer i sur. (2020) i Oldoni i sur. (2021);

b) Koncentracija ukupnih kiselina: Johnson i sur. (2001); Martínez-Casasnovas i sur. (2012); Urretavizcaya i sur. (2014); Ortega-Blu i Molina-Roco (2016); Gatti i sur. (2017); Matese i sur. (2017); Reynolds i sur. (2018) i Ferrer i sur. (2020);

c) pH vrijednost: Johnson i sur. (2001); Fiorillo i sur. (2012); Urretavizcaya i sur. (2014); Bonilla i sur. (2015); Ortega-Blu i Molina-Roco (2016); Ledderhof i sur. (2016); Gatti i sur. (2017); Reynolds i sur. (2018) i Ferrer i sur. (2020).

Kako navode istraživači, u različitim zonama bujnosti (uglavnom zone veće, srednje i manje bujnosti) određenih putem vegetacijskih indeksa (uglavnom NDVI), zone veće bujnosti imale su manji sadržaj šećera u grožđu i veći sadržaj ukupnih kiselina u odnosu na određene zone manje ili srednje bujnosti, dok je pH vrijednost mošta pokazala različite korelacije, neovisne samo o količini ukupne kiseline, već i kiselinskom omjeru organskih kiselina mošta (većinom omjeru jabučne i vinske kiseline). Istraživanja autora Urretavizcaya i sur. (2014), Bonilla i sur. (2015), Ortega-Blu i Molina-Roco (2016), Reynolds i sur. (2018) i Ferrer i sur. (2020) potvrđuju korelaciju NDVI zona i pH na način da je u zonama manje bujnosti izmjeren viši pH koji odgovara nižim vrijednostima ukupnih kiselina i dobrom dozrijevanju grožđa. Autori Johnson i sur. (2001), Fiorillo i sur. (2012) i Gatti i sur. (2017), u svojim istraživanjima navode kako je izmjeren niži pH u zonama manje bujnosti, iako su ukupne kiseline imale niže vrijednosti u istim zonama. Naime, pH vrijednost označava realnu kiselost mošta, a visok sadržaj jabučne kiseline, koja kao slabija kiselina od vinske povisuje pH mošta, ukazuje na slabije dozrijevanje grožđa, posebno u uvjetima hladnijeg i kišovitijeg podneblja (Fiorillo i sur., 2012). Prema Johnson i sur. (2001) u zoni veće bujnosti pH je bio viši nego u zoni manje bujnosti zajedno s izrazito visokom koncentracijom jabučne kiseline koju autori pripisuju zasjenjenom grožđu i velikoj gustoći lisne mase u zoni veće bujnosti. Prema Gatti i sur. (2017) iako su ukupne kiseline bile više u zoni veće bujnosti, pH je bio najniži u zoni manje bujnosti. Uzrok niže pH vrijednosti u zoni manje bujnosti autori nalaze u višoj koncentraciji vinske kiseline jer je smanjenje koncentracije vinske kiseline brže proteklo u zoni veće bujnosti nego u zoni manje bujnosti.

Svi navedeni autori smatraju kako su vegetacijski indeksi dobri prediktori za kvalitativno zoniranje vinograda na osnovu bujnosti te kako je taj alat dobar za procjenu varijabilnosti unutar vinograda. Nadalje, kvalitativno zoniranje omogućava ciljano upravljanje proizvodnjom (engl. *site-specific management*) kao što su npr. navodnjavanje, gnojidba i zaštita vinograda te omogućava selektivnu berbu ovisno o kvaliteti grožđa i s tim povezano, proizvodnju različitih tipova vina kako bi se postigao veći profit u proizvodnji

grožđa i vina (Hall i sur., 2002; Proffit, 2005; Bramley i sur., 2011a; Bramley i sur., 2011b; Bonilla i sur., 2015; Gatti i sur., 2017; Ferrer i sur., 2020).

Kada se govori o kvalitativnom zoniranju važno je razmotriti i stabilnost varijabilnosti, odnosno, koliko su određena svojstva na osnovu kojih se vrši kvalitativno zoniranje stabilna tijekom vegetacijske sezone, ali i između dvije ili više vegetacijskih sezona (dvije ili više proizvodnih godina). Prostorna i vremenska stabilnost određenih faktora omogućavaju lakše planiranje upravljanja vinogradom, što je vrijedno i s praktične strane proizvodnje grožđa (Bramley i Hamilton, 2004; Tisseyre i sur., 2008; Bramley, 2010; Kazmierski i sur., 2011, Santesteban i sur., 2013). Bramley i Hamilton (2004) procijenili su prostornu varijabilnost u tri klimatski različite regije (Coonawarra, Clare Valley i Sunraysia, Australija) u vinogradima s tri različite sorte vinove loze ('Cabernet sauvignon', 'Merlot' i 'Ruby Cabernet'). Ova studija je pokazala da su u tri potpuno različita vinograda obrasci varijabilnosti unutar vinograda vremenski stabilni, u slučaju uniformnog upravljanja vinogradom. Odnosno, zona manje bujnosti i prinosa je sve tri godine bila zona manje bujnosti i prinosa, iako su prinosi između godina varirali ovisno o klimatskim uvjetima u vegetacijskoj sezoni. Tisseyre i sur. (2008) proveli su sedmogodišnje istraživanje s ciljem karakteriziranja vremenske stabilnosti varijabilnosti unutar vinograda za šest najčešće mjerenih svojstva vinove loze (šećer, pH, ukupna kiselost, prinos, masa orezane rozgve i veličina lisne mase). Utvrdili su kako sastavnice prinosa pokazuju stabilnu vremensku varijabilnost, dok se to nije moglo dokazati za mjerena kvalitativna svojstva. Ovaj rezultat može ukazivati na jaku vezu između sastavnica prinosa i karakteristika tla (teksture i dubine tla) te topografije, koji nisu podložni godišnjim promjenama. Suprotno tome, kvalitativna svojstva imaju veću prostornu varijabilnost unutar vinograda tijekom svih godina, što se pripisuje snažnoj interakciji između klimatskih uvjeta u vegetacijskoj sezoni i dostupnosti vode i hranjiva. Bramley (2010) navodi kako su uz nepobitne dokaze iz različitih vinograda iz cijelog svijeta, uz određene varijacije unutar vinograda, prinos i bujnost prostorno stabilni na razini vinograda. Kazmierski i sur. (2011) su proučavali vremensku stabilnost prostorne varijabilnosti NDVI indeksa unutar vinograda na dvije vremenske skale: tijekom i između vegetacijskih sezona. Cilj ove studije bio je dati odgovore na praktičnu uporabu NDVI, a posebno utvrditi je li moguće (a) unaprijed pomaknuti datum daljinskog praćenja kako bi se povećalo vrijeme potrebno za analizu i interpretaciju rezultata prije berbe i (b) provjeriti može li se snimka napravljena u jednoj godini koristiti se za upravljanje vinogradom u sljedećim godinama. Ova studija potvrdila je vremensku stabilnost prostorne varijabilnosti NDVI i tijekom i između vegetacijskih sezona. Nadalje, potvrdila je da je snimanje 15-20 dana prije šare imalo visoku korelaciju sa snimkama prije berbe. Godišnja stabilnost NDVI uzorka kroz desetogodišnje istraživanje, potvrđena je u periodu od 3-5 godina (ovisno o starosti vinograda) kroz

visoku korelaciju snimaka u vrijeme šare i to za vinograde u kojima nije bilo značajnijih agrotehničkih i ampelotehničkih zahvata, kao ni preciznog tretiranja u vrijeme istraživanja. Santeseban i sur. (2013) također su svojim istraživanjem potvrdili stabilnost prostorne varijabilnosti bujnosti procijenjene s NDVI, na razini 27 parcela jednog vinograda kao i na razini cijelog vinograda veličine 90 ha. Definirane zone bujnosti bile su signifikantne i prostorno organizirane na obje promatrane razine, a uz dodatna mjerenja na ciljanim trsovima i potvrđene kroz osnovne analize sastavnica prinosa i kvalitativnih svojstava. Takav zaključak donosi i Bramley (2005a) koji smatra da su obrasci varijabilnosti u kvalitativnim sastojcima grožđa i mošta isti kao i obrasci varijabilnosti u prinosu te se mogu koristiti za sve praktične svrhe, dok je cilj kvalitativnog zoniranja na osnovu vegetacijskih indeksa (ili senzora za praćenje bujnosti/prinosa) definiranje područja za selektivnu berbu.

2.5.2. Selektivna berba

Selektivna berba može se definirati kao razdvajanje grožđa u berbi prema različitim kriterijima prinosa i/ili kvalitete, s ciljem proizvodnje različitih proizvoda kako bi se na što bolji način iskoristile varijabilnosti uočene u vinogradu (Bramley, 2010). Selektivna berba može se promatrati iz agronomskog i ekonomskog aspekta, jer maksimizacija učinaka varijabilnosti u pojedinim dijelovima vinograda može biti i ekonomski učinkovita (Bramley i sur., 2003; Proffit i Malcom, 2005). Iz aspekta proizvodnje vina, selektivna berba je zanimljiva prije svega zbog mogućnosti razdvajanja različitih klasa sirovine (grožđa) za proizvodnju različitih tipova vina od iste sorte grožđa i iz istog vinograda. Takva selektivna berba može se odvijati ili isti dan ili u različitim terminima kako bi se još kvalitetnije iskoristile prednosti varijabilnosti (Bramley, 2005b). Nadalje, na razini npr. cijelog vinograda, moguće je odrediti iste ili slične zone na osnovu prinosa i/ili kvalitete s ciljem definiranja proizvodnih blokova za određene tipove vina (npr. rose i mlada vina, vina za dozrijevanje) (Santesteban i sur., 2013).

Može se reći kako selektivna berba nije novost u vinogradarskoj proizvodnji jer mnogi vinogradari provode selektivnu berbu za različite tipove vina, ali na osnovu iskustva, vizualne procjene nasada prije berbe ili uz nekoliko senzornih ili kemijskih analiza grožđa unutar vinograda prije berbe, odnosno bez pomoći novih tehnologija za preciznu procjenu varijabilnosti kao što su snimke daljinskog praćenja visoke rezolucije, vegetacijski indeksi ili određeni setovi podataka vezani uz varijabilnost vinograda (Bramley, 2010). Kod selektivne berbe važna je opravdanost, jer selektivna berba nije nužno strategija koja svima odgovara. Mora biti povezana s mogućnošću proizvodnje različitih tipova vina, koja će imati svoje tržište ili s većom slobodom proizvođača vina koji će moći različite

proizvode kupažirati do onog željenog. Također, važno je i da je vinarija bude prerađivački i proizvodno spremna i opremljena za dvije ili više berbi te više različitih proizvodnih procesa u trenutku vinifikacije, njege i dozrijevanja vina (Bramley, 2010).

Selektivna berba na osnovu podataka kvalitativnog zoniranja i tako dobivenih vina, nije previše istražena, a još manje na osnovu kvalitativnog zoniranja pomoću vegetacijskih indeksa. Nekoliko istraživača potvrdili su korist kvalitativnog zoniranja za selektivnu berbu putem razlika u kvaliteti vina ili razlika u senzornim svojstvima vina (Johnson i sur., 2001; Bramley i sur. 2011a; Bramley i sur., 2011b; Santos i sur., 2012). Prema istraživanju Johnsona i sur. (2001) vina dobivena iz zone manje i srednje bujnosti senzorno su ocijenjena kao vina vrhunske kakvoće, za razliku od vina visoke zone bujnosti koja su svrstana u kategoriju stolnih vina. Bramley i sur. (2011a) su koristeći daljinska praćenja bujnosti (Plant Cell Density- PCD Indeks), mape prinosa i električnu provodljivost tla, identificirali različite zone kvalitete u vinogradu sorte 'Cabernet sauvignon' u regiji Murray Valley (Australija). Nakon selektivne berbe, odvojeno su vinificirali vina iz dvije zone bujnosti i tri godine istraživanja. Prema senzornoj ocjeni vina su se značajno razlikovala u sve tri godine istraživanja te su vina iz zone veće bujnosti opisivana kao više voćna i herbalnog karaktera, dok su vina iz zone manje bujnosti opisana atributima bobičastog voća, pa sve do zrelog i prosušenog bobičastog voća. I kemijskom analizom vina pokazano je kako su vina bila različita u sadržaju hlapivih spojeva (ukupno 21), a 10 spojeva bilo je različito u sve tri istraživane godine. Zaključili su kako su vina iz manje zone bujnosti imala veće koncentracije većine hlapivih spojeva. U sličnom istraživanju, Bramley i sur. (2011b) proučavali su zone bujnosti u dva vinograda (glavni i sporedni proizvodni blok) sorte 'Cabernet sauvignon' u Murray Valley (Australija) i to na način da su u oba proizvodna bloka odredili zone manje i veće bujnosti, a selektivnu berbu proveli su na pokusnom i komercijalnom nivou prema određenim zonama iz oba proizvodna bloka. Rezultati su pokazali da se pokusna vina iz zone manje bujnosti nisu značajno razlikovala između proizvodnih blokova, a bila su značajno različita od vina iz zona veće bujnosti iz oba proizvodna bloka. Komercijalna vina (veće količine), napravljena od grožđa iz zona veće bujnosti iz oba proizvodna bloka, nisu se međusobno razlikovala. Autori zaključuju kako su oba proizvodna bloka vrlo slična i unutarnje varijabilnosti uzrokovane su istim faktorima te selektivna berba u različitim zonama bujnosti iz dva proizvodna bloka može zadovoljiti i veće proizvodne količine vina različitih kvalitativnih kategorija. Santos i sur. (2012) koristili su ručne senzore i multispektralne zračne snimke za procjenu varijabilnosti unutar vinograda te su izvršili strojno branje grožđa prema definiranim zonama, i to prema sadržaju antocijana u grožđu. Zaključili su kako je predviđanje kvalitativnih parametara rezultiralo uspješnom selektivnom berbom za najmanje dva tipa vina, iako im se kroz istraživanje nije uvijek pokazala negativna linearna korelacija između visokog prinosa i

visoke kakvoće, što pripisuju ostalim faktorima koji utječu na razvoj vinove loze i dozrijevanje grožđa.

Za potrebe potpore odlučivanju o provedbi selektivne berbe, isključivo strojne, konstruiran je Oportunitetni indeks (OI_{SV} – engl. *Opportunity indeks*) (Arnó i Martínez-Casasnovas, 2017) koji se sastoji od dvije faze: a) izrada NDVI mape vinograda i b) analiza NDVI mape vinograda. Pri analizi koriste se tri parametra koja će odrediti pogodnost nekog vinograda za provedbu selektivne berbe. To su: 1) postojanje prostorne varijabilnosti, 2) strukturirana prostorna varijabilnost koja omogućava optimizaciju rada strojnog berača te ako su zadovoljena navedena dva parametra, 3) minimalna površina na kojoj se nalazi visoko kvalitetno grožđe kako bi se postigao odgovarajući ekonomski učinak. Složene procedure izračuna ovog indeksa uključuju i pragove za svaki od parametara te ga to čini pogodnim samo za velike površine vinograda i velike vinarije koje mogu udovoljiti tim minimalnim pragovima (3 ha vinograda, pravilno postavljeni redovi vinograda, minimalna dužina reda od 50 m s visoko kvalitetnim grožđem i sl.).

2.6. Ekonomski učinci precizne poljoprivrede u vinogradarstvu

Svaki novi alat ili tehnologija u vinogradarskoj (poljoprivrednoj) proizvodnji mora biti proizvodno i ekonomski evaluirana kako bi ju proizvođači prihvatili i započeli korištenje u vlastitoj proizvodnji. Prema Shockley i sur. (2017) kada se procjenjuje ekonomičnost tehnologija za pametnu poljoprivredu (hardver, softver i usluge) rezultati su specifični za svako područje koliko je specifična i tehnologija koja se procjenjuje, odnosno, tehnologija koja je pogodna i profitabilna za jednog proizvođača ne mora biti pogodna i profitabilna za drugog proizvođača, pa čak ni za drugu parcelu u proizvodnji.

U Studiji izrađenoj za potrebe Europskog parlamenta (JRC, 2014) navedeno je kako ekonomska analiza precizne poljoprivrede mora uzeti u obzir ulaganje poljoprivrednika u potrebnu tehnologiju u odnosu na očekivane koristi. Glavni problem koji nastaje jest da agronomske učinke precizne poljoprivrede nije lako predvidjeti, stoga i analize ulaganja podliježu pretpostavkama. Shockley i sur. (2017) navode kako su proizvođačima uglavnom dostupne univerzalne i djelomično netočno izračunate ekonomske informacije iz sektora agrobiznisa. Stvarna profitabilnost se može jako razlikovati, jer ovisi o trošku i procijenjenoj koristi, kao agronomskom odgovoru na primijenjene metode precizne poljoprivrede (JRC, 2014). Nastavno na to, Godwin i sur. (2003) u svom istraživanju navode kako ekonomske koristi ostvarene preciznom poljoprivredom ovise o rasponu agronomskog odgovora biljke na korektivne ili varijabilne tretmane te na udio parcele koji će odgovoriti na tretmane.

Potencijalna profitabilnost precizne poljoprivrede može se procijeniti samo u odnosu na sustav u kojem se ne koriste alati i tehnologije precizne poljoprivrede, a koji služi kao referenca za procjenu potencijalne profitabilnosti precizne poljoprivrede za svaki određeni slučaj (JRC, 2014).

Navedena Studija (JRC, 2014) navodi i vrste troškova povezane s provedbom precizne poljoprivrede:

a) troškovi informacija, povezani s potrebnim ulaganjima u tehnologiju, uključujući naknade za najam određenog hardvera, strojeva i opreme;
b) troškovi koji uključuju obradu podataka, posebne naknade za licencu, softver i hardver, proizvode za analizu podataka;
c) troškovi edukacije, uglavnom zbog dodatnog vremena potrebnog poljoprivredniku za razvoj načina upravljanja, kalibraciju strojeva, kao i oportunitetni troškovi zbog neučinkovite upotrebe tehnologije za preciznu poljoprivredu;

dok su potencijalne koristi uglavnom usmjerene na poboljšanje prinosa usjeva, optimizaciju inputa i poboljšanje kvalitete rada i upravljanja proizvodnjom.

Osim navedenih troškova, za određivanje ekonomske koristi alata i tehnologija precizne poljoprivrede u obzir se moraju uzeti i interakcije između veličine parcele, prostorne varijabilnosti, prinosa i troška samih tehnologija koje se primjenjuju (Godwin i sur., 2003; Knight i sur., 2009).

Jedan od glavnih razloga slabijeg prihvaćanja ili nekorištenja novih tehnologija je nedostatak relevantnih istraživanja vezanih za ekonomsku korist preciznog vinogradarstva (Maynard, 2015). Vinogradari, kao i svi ostali donosioci odluka u bilo kojem sektoru poslovanja, moraju moći donijeti relevantnu odluku o korištenju novih tehnologija nakon analize troškova i koristi s ciljem stvaranja profitabilnije proizvodnje (Maynard, 2015). Adrian i sur. (2005) navode kako je ekonomska korist odlučujući faktor za korištenje alata precizne poljoprivrede. Rendulić Jelušić i sur. (2021) navode kako su gotovo svi ispitani profesionalni vinogradari Zagrebačke županije (91%, n=21) kao glavne razloge nekorištenja novih tehnologija za praćenje vinogradarske proizvodnje naveli nedostatak financijskih sredstava za potrebna ulaganja i nedovoljno relevantnih informacija o novim tehnologijama. Ispitani vinogradari smatraju kako su ulaganja u nove tehnologije iznimno visoka te kako njihovi godišnji prihodi ne bi mogli pokriti takvu razinu ulaganja. Sukladno dosadašnjim istraživanjima (Adrian i sur., 2005; Pierpaoli i sur., 2013; Kernecker i sur., 2018; Barnes i sur., 2019) visoki troškovi novih tehnologija u percepciji poljoprivrednika odlučujući su faktor za kreiranje pozitivnog stava prema korištenju novih tehnologija, a ekonomska korist glavni pokretač investicija u poljoprivrednoj proizvodnji.

Pregledom literature može se zaključiti kako je puno više istraživanja o profitabilnosti pri primjeni alata i tehnologija precizne poljoprivrede napravljeno za ratarske kulture i industrijsko bilje nego za vinogradarstvo, kao i za automatizirane tehnologije u odnosu na podatkovno intenzivne tehnologije (Lambert i Lowenberg-DeBoer, 2000; Schimmelpfennig, 2016; Dhoubhadel, 2020). Razlog za to nalazi se u činjenici da su prvi korisnici alata i tehnologija precizne poljoprivrede u ratarskoj proizvodnji nadmoćno iskoristili mapiranje prinosa i druge dostupne alate kako bi uspješno primjenjivali tehnologije promjenjivih količina inputa u proizvodnji (ponajviše dušičnih gnojiva) (Bramley, 2010) te je u tom smislu i fokus istraživanja profitabilnosti išao u tom smjeru. Suprotno tome, prvi korisnici alata i tehnologija preciznog vinogradarstva stavili su veći fokus na daljinsko praćenje vinogradarske proizvodnje s ciljem selektivne berbe zbog imperativa kvalitete grožđa koji pokreće vinsku industriju (Bramley, 2010) te je u tom smislu i fokus istraživanja uglavnom bio na praćenju povezanosti kvalitativnih svojstava i daljinskog praćenja, a tek u novije vrijeme i uz to vezane profitabilnosti.

2.6.1. Ekonomski učinci tehnologija za precizno vinogradarstvo

Pri korištenju, ali i procjeni ekonomske učinkovitosti tehnologija za precizno vinogradarstvo, važno je razlikovati podjelu tehnologija na automatizirane tehnologije i podatkovno intenzivne tehnologije (Lambert i sur., 2004) te pravilno vrednovati profitabilnost i koristi različitih alata i tehnologija (Shockley i sur., 2017). Kvalitativno zoniranje vinograda uz pomoć bespilotnih letjelica i odgovarajućih vegetacijskih indeksa može se opisati kao prikupljanje i obrada vrijednih podataka o vinogradu te pripada skupini podatkovno intenzivnih tehnologija za koje je puno teže procijeniti razdoblje povrata ulaganja i dodatne koristi, poput poboljšanog razumijevanja čimbenika koji uzrokuju varijabilnost prinosa, nego za automatizirane tehnologije, koje olakšavaju i smanjuju količinu rada te ubrzavaju sam proces proizvodnje (Griffin i sur., 2018). Nadalje, podatkovne tehnologije zahtijevaju i dodatne vještine i znanja za djelotvornu upotrebu u donošenju relevantnih odluka o upravljanju proizvodnjom te nisu prilagođene za jednostavno korištenje većine korisnika (Lambert i sur., 2004).

Prema Castle (2016) korištenjem podatkovno intenzivnih tehnologija nije moguće direktno povećanje profitabilnosti, već one osiguravaju informacije koje omogućavaju kvalitetnije i učinkovitije upravljanje proizvodnjom kroz primjenu drugih tehnologija. Dakle, nije jednostavno izolirati i mjeriti ekonomski učinak korištenja multispektralnih snimki, kvalitativnog zoniranja ili bilo kojeg drugog oblika prikupljanja podataka o vinogradu.

U tablici 3 prikazan je potencijalni direktni ili indirektni ekonomski učinak korištenja pametnih tehnologija za upravljanje vinogradarskom proizvodnjom uz procjenu razine potrebne investicije u pametne tehnologije te motiv vinogradara za korištenje određene pametne tehnologije. Potencijalna investicija podijeljena je na tri razine: nisku, srednju i visoku prema procjeni cijene koštanja određene pametne tehnologije za vinogradara, a motiv za korištenje odgovara razlogu za korištenje određene pametne tehnologije u vinogradarskoj proizvodnji (Balafoutis i sur., 2017).

Tablica 3. Ekonomski učinak pametnih tehnologija za upravljanje vinogradarskom proizvodnjom (prerađeno prema Balafoutis i sur., 2017)

Tehnologija	Glavna namjena	Sustav	Razina investicije	Motiv	Ekonomski učinak
Tehnologije za prikupljanje podataka	Geoprostorna pokrivenost i pozicioniranje	Globalni navigacijski satelitski sustavi (GNSS)- GPS, GLONASS, GALILEO, BeiDou, QZSS, NavIc (EUSPA, 2020)	Niska do srednja	Unaprjeđenje upravljanja informacijama o proizvodnji	Globalni navigacijski satelitski sustavi nemaju direktan ekonomski učinak, ali mnoge aplikacije u okviru preciznog vinogradarstva zahtijevaju korištenje GNSS, stoga su GNSS indirektno korisni.
	Tehnologije kartiranja	Visinsko kartiranje Kartiranje svojstava tla Kartiranje prinosa	Niska do srednja	Unaprjeđenje upravljanja informacijama o proizvodnji	Visinsko kartiranje, kartiranje svojstava tla i prinosa nemaju direktan ekonomski učinak, osim ako nisu korištene i stručno interpretirane u svrhu primjene tehnologije promjenjive količine inputa (engl. *VRT variable rate technology*).
	Prikupljanje podataka o okolišnim uvjetima	RGB kamere LIDAR senzori Multispektralne kamere Hiperspektralne kamere Termalne kamere Senzori za praćenje stanja tala	Niska do srednja (ovisno o uređaju)	Unaprjeđenje upravljanja informacijama o proizvodnji	Različite snimke nemaju direktan ekonomski učinak, no ako su korištene pri primjeni tehnologije promjenjive količine inputa (VRT), smanjenje količine inputa će se reflektirati na prihodu gospodarstva.
	Strojevi i oprema	Senzori za mjerenje putne brzine Traktori sa ISOBUS sustavima Bespilotne letjelice Autonomna vozila i strojevi	Srednja do visoka	Unaprjeđenje upravljanja informacijama o proizvodnji	Senzori za mjerenje putne brzine i traktori sa ISOBUS sustavima ne daju direktnu ekonomsku korist, no ako se koriste u kombinaciji s korištenjem tehnologije promjenjive količine inputa (VRT) mogu biti indirektno korisni za proizvođača. Bespilotne letjelice i autonomna vozila mogu osigurati direktnu ekonomsku korist za proizvođača zbog smanjenja/odsutnosti troškova rada i nižih troškova goriva u odnosu na uređaje koji se montiraju na traktore. Također, manja i lakša vozila mogu smanjiti trošak vezan uz zbijanje tla.

(nastavlja se)

Tehnologije za analizu i evaluaciju podataka	Analiza i korištenje prikupljenih podataka	Zoniranje proizvodnih površina Sustav potpore odlučivanju Upravljački informacijski sustavi Programski paketi za upravljanje proizvodnjom	Niska do srednja	Unaprjeđenje upravljanja informacijama o proizvodnji	Zoniranje proizvodnih površina ne donosi direktan ekonomski učinak, osim ako se ne koristi za optimizaciju upravljanja proizvodnjom. Različiti sustavi potpore odlučivanju kao i programski i informacijski sustavi donose smanjenje vremena potrebnog za donošenje relevantnijih odluka o proizvodnji, posebice ako su u sustave importirani podaci ostalih primijenjenih pametnih tehnologija za prikupljanje, analizu i evaluaciju podataka.
Tehnologije za preciznu provedbu i primjenu agrotehničkih i ampelotehničkih mjera	Tehnologija promjenjive količine inputa (VRT)	Promjenjiva količina gnojiva Promjenjiva količina zaštitnih sredstva Precizno navodnjavanje i plan navodnjavanja Precizno mehaničko uništavanje korova	Niska do visoka (ovisno o uređaju)	Operativna izvrsnost/unaprjeđenje upravljanja informacijama o proizvodnji	Tehnologije promjenjive količine inputa imaju direktan ekonomski učinak na proizvodnju jer se optimizacijom korištenja inputa teži postizanju operativne izvrsnosti koja donosi povećanje prihoda i smanjenje troškova proizvodnje.
	Tehnologija automatskog navođenja	Sustavi automatskog navođenja i kontroliranog kretanja strojeva	Niska	Operativna izvrsnost/unaprjeđenje upravljanja informacijama o proizvodnji	Sustavi automatskog navođenja i kontroliranog kretanja strojeva mogu imati direktan ekonomski učinak jer se korišteni inputi (gnojiva i zaštitna sredstva) primjenjuju ciljano i bez preklapanja što smanjuje utrošak inputa i direktno utječe na povećanje profita. Kontrolirano kretanje strojeva smanjuje ujedno i troškove vezane uz upotrebu strojeva (potrošnja goriva, utrošeno vrijeme).

Prema navodima u tablici 3 može se zaključiti kako tehnologije za prikupljanje podataka u vinogradu nemaju direktan ekonomski učinak na vinogradarsku proizvodnju, no omogućavaju interpretaciju podataka i izdavanje smjernica za daljnje upravljanje vinogradarskom proizvodnjom te služe kao podloge za korištenje automatiziranih tehnologija, posebice tehnologije promjenjive količine inputa.

Informacije i podaci u poljoprivredi, pa tako i u vinogradarstvu, oduvijek su služili za poboljšanje upravljanja proizvodnjom, razvoj novih tehnika i tehnologija, a njihova važnost je neupitna i u današnjem razvoju poljoprivrede i vinogradarstva. U današnje vrijeme, zahvaljujući naprednom tehnološkom razvoju, informacije i podaci postali su točniji, precizniji, lakše dostupni i manje skupi. Loewenberg- DeBoer i Boehlje (1996) navode kako informacija (podatak) ima svoje karakteristike koje joj određuju vrijednost, pa tako informacija mora biti dostupna na vrijeme, točna, objektivna, kompletna, razumljiva i pouzdana. Nadalje, navode kako su informacije i podaci strateški izvor kompetitivne prednosti za proizvođača, u smislu poboljšanja učinkovitosti i povećanja prihoda u odnosu na ostale proizvođače. Iako je ovo istraživanje provedeno prije dvadeset i pet godina, to nimalo ne umanjuje značaj zaključaka, pogotovo iz današnje perspektive kada su podaci osnova i podloga za brži i uspješniji daljnji razvoj vinogradarske proizvodnje.
Fulton i Port (2018) navode kako će daljnjim razvojem tehnika precizne poljoprivrede podaci postati „roba“ unutar poljoprivredne industrije, uspoređujući to s Google Earth-om u kojem su prostorni podaci postali „roba“ slična nafti, zlatu, kukuruzu i pšenici, a podaci se mogu koristi u različite svrhe, pa čak i za one za koje nikada nisu bili namijenjeni. Dalje navode kako je danas informacijska tehnologija evoluirala do te mjere da omogućuje bežično povezivanje i korištenje tehnologija u oblaku za komunikaciju s ljudima i opremom smještenom u proizvodnim poljima, a podaci se mogu prikupljati, pohranjivati i analizirati, što ih čini dragocjenim resursom i omogućava identifikaciju i kvantifikaciju ograničavajućih faktora produktivnosti. Upotreba i obrada podataka mora biti jednostavna, korisna i točna za proizvođača kako bi omogućila ispravno donošenje odluka o proizvodnji.
Prijašnjih godina izvori informacija o novim tehnološkim i proizvodnim dostignućima za poljoprivredne proizvođače, uglavnom su bili proizvođači i distributeri inputa i opreme, a manje javni sektor- savjetodavna služba i sl. (Loewenberg- DeBoer i Boehlje, 1996), no i taj segment doživljava određene promjene jer određeni podaci postaju javno dostupni i besplatni u formi javnih otvorenih podatka (npr. Open/Big Data). „Big data“ podaci nastaju kada poljoprivrednici, tvrtke i javne institucije kompiliraju setove različito prikupljenih podataka koji se mogu koristiti za relevantno donošenje odluka o proizvodnji (Fulton i Port, 2018). No i dalje će kvalitetni i upotrebljivi podaci za vlastitu proizvodnju biti teže javno dostupni te će proizvođači, koji žele koristiti relevantno podatkovno donošenje

odluka, koristiti alate i tehnologije preciznog vinogradarstva, a ti će se podaci u strukturi troška gospodarstva moći promatrati kao relevantan trošak proizvodnje.

2.6.2. Ekonomske metode procjene investicije za precizno vinogradarstvo

Pri primjeni podatkovno intenzivnih tehnologija vinogradari mogu očekivati sasvim nove troškove koji do sada nisu postojali u njihovoj strukturi troškova proizvodnje. Za većinu vinogradara to su novi, dodatni troškovi koji opterećuju proizvodnju, ali to je i ulaganje s ciljem povećanja profita i koristi od vlastite proizvodnje koje bi morale biti dovoljno velike da investicija bude isplativa i korisna. Knight i sur. (2009) navode kako potencijalne koristi podatkovno intenzivnih tehnologija moraju biti u ravnoteži s troškovima prikupljanja i korištenja informacija, što u nekim situacijama može zahtijevati određeno smanjenje varijabilnih troškova proizvodnje (npr. inputa) i povećanje fiksnih troškova proizvodnje (npr. troškova opreme). S tim u vezi, prema Grgić i sur. (2011) troškovi, koji su novčani izraz utroška elemenata radnog procesa, dijele se na fiksne i varijabilne troškove u odnosu na promjenu razine aktivnosti odnosno prema stupnju iskorištenosti kapaciteta. Fiksni troškovi su nepromjenjivi troškovi koji se ne mijenjaju prilikom promjene razine proizvodne aktivnosti te ne nastaju ovisno o količini proizvoda koja je u nekom razdoblju proizvedena, nego ovise o vremenu trajanja proizvodnje. Još se nazivaju i troškovi kapaciteta (nastaju bez obzira proizvodi li se ili ne). Varijabilni troškovi su promjenjivi troškovi koji se mijenjaju promjenom razine aktivnosti i nastaju ovisno o proizvodnji učinaka, a nazivaju se i troškovi proizvodnje.

Struktura troškova podatkovno intenzivnih tehnologija u preciznom vinogradarstvu razlikuje se ovisno o načinu prikupljanja, obrade i analize podataka. Vinogradari se mogu odlučiti na kupnju opreme i dodatne edukacije, ali mogu i koristiti usluge komercijalnih tvrtki koje pružaju usluge tog tipa (Swinton i Ahmad, 1996). U tablici 4 prikazana je razlika u strukturi troškova podatkovno intenzivnih tehnologija pri kupnji vlastite opreme i pri korištenju usluge prikupljanja, obrade i analize podataka od strane komercijalnih kompanija.

Tablica 4. Struktura troškova podatkovno intenzivnih tehnologija u preciznom vinogradarstvu s obzirom na način prikupljanja, obrade i analize podataka (prerađeno prema Swinton i Ahmad, 1996; Grgić i sur., 2011; Shockley i sur., 2017; Griffin i sur., 2018)

Način prikupljanja, obrade i analize podataka	**Fiksni troškovi**	**Varijabilni troškovi**
Kupnja vlastite opreme	Kupnja opreme- bespilotna letjelica Kupnja opreme- računalo Trošak amortizacije opreme Trošak instalacije opreme Trošak održavanja opreme Trošak godišnjih pretplata i licenci Trošak obuke i edukacije za korištenje opreme i analizu podataka	Trošak vlastitog rada Trošak selektivne berbe
Korištenje usluga komercijalnih kompanija		Trošak usluge- prikupljanje, obrada i analiza podataka Trošak selektivne berbe

Swinton i Ahmad (1996) u svom istraživanju navode kako je većina neočekivanih troškova povezana upravo s kupnjom i vlasništvom opreme (nekompatibilnost aplikacija i sustava, pouzdanost rada, povezivost, pogreške u rukovanju opremom, dodatne edukacije i potrebne vještine, slaba računalna oprema i sl.). Kada se koriste usluge „po mjeri“, gotovo svi troškovi su novčani, a sav rizik korištenja opreme i njenog održavanja prelazi na davatelja usluge. Autori zaključuju da u slučaju kada financijske koristi premašuju troškove korištenja usluge, usluga je isplativa.

U vrlo detaljnom istraživanju, iako na ratarskim kulturama i velikim površinama, Rataj i Galambošová (2011) navode kako najveći trošak informacija u preciznoj poljoprivredi nastaje u prvoj godini primjene novih tehnologija, kada je potrebno prikupiti, obraditi i analizirati podatke za sve površine na određenom gospodarstvu, a trošak se značajno smanjuje u sljedećim godinama korištenja novih tehnologija zbog mogućnosti korištenja podataka iz prethodnih godina koji su prostorno i vremenski stabilni.

Lambert i sur. (2004) navode kako je često oportunitetni trošak vremena za proizvođača vrlo velik te obeshrabruje proizvođače da sami prikupljaju, čuvaju, obrađuju, analiziraju i interpretiraju prikupljene podatke.

Sposobnost prikupljanja i kvantificiranja svih relevantnih troškova (direktnih i indirektnih) i koristi (direktnih i indirektnih) bitna je za utvrđivanje povrata na ulaganje svake pojedine nove tehnologije (Griffin i sur., 2018). Izbor odgovarajuće metode ekonomske procjene investicije u nove tehnologije od iznimne je važnosti za donošenje odluke o korištenju novih tehnologija (Shockley i sur., 2017).

Shockley i sur. (2017) dalje navode kako su financijska i ekonomska opravdanost dva različita koncepta. Novo ulaganje ekonomski je opravdano ako generira dovoljan prihod kako bi se zadovoljili dodatni novčani zahtjevi u životnom vijeku investicije. Novo ulaganje financijski je opravdano ako je korisnik sposoban osigurati novčani tok investicije s obzirom na financijsku strukturu investicije. Ulaganje može biti ekonomski opravdano, a financijski neopravdano. Na primjer, investicije koje zahtijevaju visoka početna ulaganja (sadnja vinograda, postavljanje sustava za navodnjavanje, kupnja nove opreme i sl.) bez generiranja prihoda u prvoj godini mogu biti financijski neopravdane za investitora zbog nepovoljnog novčanog toka, ali su ekonomski opravdane kroz duže vremensko razdoblje jer se u vijeku trajanja investicija uspješno otplatila, a investitor ostvario pozitivan financijski rezultat.

Do sada korištene ekonomske metode procjene uglavnom su bile bazirane na analizama troškova i koristi (engl. *cost-benefit analysis-CBA*) i kalkulacijama doprinosa pokriću (engl. *gross-margin analysis*), no dosadašnja istraživanja nisu obuhvatila cjelovitu analizu troškova koji obuhvaćaju operativne i režijske troškove te troškove kapitala (Maynard, 2015).

Prema Njavro (2008) kalkulacija doprinosa pokriću (gross margin analiza), kao razlika između ukupnih prihoda i ukupnih varijabilnih troškova, može se koristiti za usporedbu dviju različitih tehnologija proizvodnje, ali i za kalkulaciju povrata u nekoj novoj proizvodnji. Gross margin analiza je koristan i praktičan alat, ali ima slučajeva kada je neprikladan, a jedan od primjera je ocjena povrata investicije koja se odnosi na niz usluga u dužem vremenskom razdoblju.

Prema Maynard (2015) usvajanje inovacije, poput preciznog vinogradarstva u kontekstu proizvodnog sustava vinarije, može se smatrati odlukom koja se odnosi na minimalne prilagodbe u proizvodnom sustavu. Zbog toga je važno razmotriti i motivacijske pokretače za usvajanje inovacije. Zašto usvajati? Koji proizvodni problem rješava? Smanjuje li inovacija troškove proizvodnje, povećava li kvalitetu proizvoda, a time i njegovu cijenu, ili povećava prinos ili se inovacija odnosi na kombinacija sva tri ova pokretača? U osnovi

ekonomske analize nalazi se bruto marža (gross margin-GM) koja je u vinogradarskoj proizvodnji funkcija prinosa (P), cijene grožđa (C) i troškova proizvodnje grožđa (T). Prema tome, GM= P x C - T. Pojednostavljeno, svaki proizvođač želi maksimizirati vlastiti profit te će mu analize „s i bez“ usvajanja inovacije biti ključne u donošenju odluke.

U svom istraživanju je li precizna poljoprivreda pridonijela povećanju profita poljoprivrednih proizvođača iz Nebraske, Castle (2016) koristi analize „s i bez“ precizne poljoprivrede i „prije i poslije“ korištenja alata i tehnologija precizne poljoprivrede. Rezultati analize „s i bez“ pokazuju snažnu pozitivnu povezanost korištenja alata i tehnologija precizne poljoprivrede s povećanjem profitabilnosti. Ova međusobna povezanost izraženija je kod automatiziranih tehnologija nego kod podatkovno intenzivnih tehnologija, što autor objašnjava većim direktnim utjecajem automatiziranih tehnologija na samu proizvodnju, ali i nižim cijenama podatkovno intenzivnih tehnologija, a time i potrebnom nižom profitabilnošću da bi se one koristile. Zaključuje kako postoji snažna pozitivna povezanost dok kao nepoznanica ostaje da li korištenje alata i tehnologija precizne poljoprivrede povećava profitabilnost ili veća profitabilnost povećava korištenje alata i tehnologija precizne poljoprivrede. U analizi „prije i poslije“ korištenja alata i tehnologija precizne poljoprivrede autor nalazi pozitivnu povezanost korištenja alata i tehnologija precizne poljoprivrede s povećanjem profitabilnosti, ali ne na razini statističke značajnosti. Naglašava važnost utjecaja „učenja“ o korištenju alata u tehnologija kao i prikupljanja podataka u prvim godinama korištenja. Naime, u funkciji učenja i iskustva pojavljuje se sigmoidna (S) krivulja učenja (slika 6) kojoj početak označava vrijeme u kojem se osoba upoznaje s osnovnim značajkama novih tehnologija i polako napreduje u njihovom usvajanju i korištenju podataka i novih informacija za donošenje odluka o upravljanju proizvodnjom. Zatim slijedi period vrlo brzog napretka i iskorištavanja znanja sve do uspostave nove ravnoteže između stečenih znanja i iskustva. U početku primjene novih tehnologija profitabilnost može jako sporo rasti, čak i opadati sve do trenutka dok usvojena znanja ne počnu donositi rezultate koji se reflektiraju u povećanju profitabilnosti. Posebno se to očituje kod primjene podatkovno intenzivnih tehnologija koje zahtijevaju početna ulaganja, a ne mogu se očitovati u direktnom povećaju profitabilnosti proizvodnje. U trenutku kada proizvođači otkriju najbolji način korištenja tehnologija i kada imaju dovoljne količine prikupljenih podataka mogu očekivati brzi napredak u donošenju relevantnih odluka o upravljanju proizvodnjom i postizanje učinaka blizu maksimuma proizvodnje.

Slika 6. Sigmoidna krivulja učenja i iskustva (S-krivulja)
(prerađeno prema Castle, 2016)

Iz navedenog se može zaključiti kako je potrebno koristiti metode ekonomske procjene investicije koje obuhvaćaju duži vremenski period jer inovacije utječu na novčani tok kroz duže vremensko razdoblje, a troškovi i prihodi se različito generiraju kroz godine (Maynard, 2015).

Inkrementalna ili diferencijalna analiza, kao analiza razlike dobivena usporedbom relevantnih informacija za različite alternative u proizvodnji, također se može koristiti za procjenu učinaka pri promjeni financijskih podataka (troškova i/ili prihoda), pri čemu se u obzir uzimaju samo oni troškovi i/ili prihodi koji su relevantni za odlučivanje o investiciji. Ostali troškovi i/ili prihodi koji se ne mijenjaju izborom različitih alternativa nisu relevantni za inkrementalnu analizu (Grgić i sur., 2011). Ova analiza vodi do parcijalnog budžetiranja, no kako mnoge inovacije zahtijevaju ulaganja kroz više godina, tako parcijalno budžetiranje postaje kapitalno budžetiranje i takve analize zahtijevaju korištenje tehnika diskontiranja novčanih tokova kako bi se u obzir uzela vremenska vrijednost novca. Parcijalnim budžetiranjem potrebno je identificirati sve promjene koje se mogu dogoditi kao posljedica korištenja inovacija i novih tehnologija, a te promjene moraju dobiti svoju monetarnu (novčanu) vrijednost. Potrebni osnovni podaci i informacije, koje proizlaze iz promjena ako su nove tehnologije usvojene, uključuju: nove ili dodatne troškove koji se mogu pojaviti, troškove koji se mogu smanjiti ili izbjeći u odnosu na do sada korištene tehnologije (engl. *BAU- Business as Usual*), nove ili dodatne prihode koji su posljedica promjene tehnologije te prihod koji može biti izgubljen ili smanjen ako započne korištenje nove tehnologije (Maynard, 2015).
Većina dosad navedenih analiza dio su alata uz pomoć kojih se provodi analiza troškova i koristi (CBA). CBA alati koriste se za donošenje primarnih odluka o opravdanosti pojedinog ulaganja uz procijenjene ulazne vrijednosti (*ex ante* CBA) (Korunić, 2017). Pri izradi CBA postoji nekoliko koraka, a uglavnom započinje specificiranjem seta različitih

alternativnih projekata (npr. korištenje novih tehnologija) koji moraju biti evaluirani (Maynard, 2015), odnosno procjenom oportunitetnog troška ili fiktivnog dobitka/gubitka koji nastaje ulaganjem sredstava u jedan određeni, a ne drugi projekt (Korunić, 2017). Kod CBA važno je pravilno definirati referentno razdoblje odnosno broj godina za koje se priprema projekcija novčanih tokova projekta jer dužina vremenskog okvira analize direktno utječe na financijske indikatore. Važno je dobro procijeniti buduće troškove i koristi te primijeniti ispravnu diskontnu stopu za potrebe izračuna neto sadašnjih troškova i koristi projekta. Kod izračuna koristi projekta potrebno je što točnije monetizirati procijenjene izravne troškove i koristi koje projekt donosi društvu (socijalne, ekološke, zdravstvene i sl.). CBA koristi i inkrementalni pristup u kojem se uspoređuje *scenarij s projektom* u odnosu na *scenarij bez projekta* te izračunava financijske i ekonomske rezultate projekta uzimajući razliku između *scenarija s projektom* i *scenarija bez projekta* (Korunić, 2017). Analiza osjetljivosti mora biti provedena i to na glavne ulazne varijable koje mogu značajno utjecati na rezultate ocjene projekta (Maynard, 2015.).

Kao glavni nedostatak CBA i većine spomenutih analiza investicijskih projekta u preciznoj poljoprivredi prema dosadašnjim istraživanjima, Maynard (2015) navodi nekorištenje operativnih i režijskih troškova te troškova kapitala u analizama. Naime, u analizi novčanog toka CBA koriste se samo stvarni novčani primici i izdaci dok se ostale računovodstvene kategorije kao što su: amortizacija, ukalkulirani troškovi, potencijalne obveze i sl. ne smiju koristiti u analizi jer nisu stvarni novčani primici/izdaci (Korunić, 2017). Kao odgovor na navedene nedostatke Maynard (2015) u svom istraživanju razrađuje i opisuje *Levelized cost* pristup/model koji je do sada uglavnom korišten za procjenu investicija u energetskom sektoru. Model uključuje sve troškove nastale investicijom kroz čitavo vrijeme trajanja projekta, ali uključuje i interakcije pojedinih troškova te nastoji izolirati numeričku vrijednost za kvalitetu grožđa. Smatra kako se razlika u cijeni grožđa koja je procijenjena na osnovi troškova proizvodnje i one stvarne prodajne cijene koju je ostvario vinogradar, može označiti kao „premija kvalitete“. Monetizacijom kvalitete, iako je subjektivna mjera, u mjerljivi oblik (trošak po jedinici, npr. $/t) moguće je procijeniti koliko precizno vinogradarstvo može doprinijeti kvaliteti grožđa svakog pojedinog proizvođača na objektivan način.

Prema Griffin i sur. (2018), kada se alati precizne poljoprivrede procjenjuju kao investicija koriste se metode za analizu investicije koje uključuju financijske metode kao što su povrat na ulaganje (ROI), razdoblje povrata, čista sadašnja vrijednost (NPV) i interna stopa rentabilnosti (IRR). ROI, iako jednostavna metoda, ignorira vremensku vrijednost novca te se ne preporučuje za investicije vezane uz preciznu poljoprivredu. Isti autori navode kako su NPV i IRR odgovarajuće metode za procjenu investicije kao i za usporedbu investiranja u različite tehnologije. NPV određuje suvišak vrijednosti nastao

investiranjem u novu tehnologiju. Određuje razliku između tržišne vrijednosti investicije i troška te ako je NPV pozitivan investicija se može provesti jer se pretpostavlja da kapital nije ograničavajući. IRR uspoređuje proizvođačev trošak kapitala sa stopom povrata koja izjednačava neto novčani tok ulaganja s troškom ulaganja. Drugim riječima, IRR je diskontna stopa koja izjednačava NPV s nulom, odnosno to je prosječna godišnja stopa prinosa investicije. Ako je IRR za određenu tehnologiju koja se želi koristiti veća od cijene kapitala (npr. kamatne stope) onda je to dobra investicija. Kad se uspoređuju različite tehnologije precizne poljoprivrede, ona s najvećom IRR je najbolja investicija (sve dok je i dalje veća od cijene kapitala).

2.6.3. Ekonomska opravdanost kvalitativnog zoniranja i selektivne berbe

Vrlo je malo istraživanja u kojima su provedene analize ekonomske opravdanosti korištenja kvalitativnog zoniranja vinograda i selektivne berbe.

Nakon detektiranja različitih zona bujnosti zračnim snimkama u vinogradu sorte 'Cabernet sauvignon' na površini 8,8 ha uz regulaciju navodnjavanja sukladno potrebama određenih zona u vinogradu Proffit (2005) navodi uštede i pri provedbi određenih ampelotehničkih zahvata u vinogradu kojima se regulira bujnost vinograda pa je tako ušteda za strojnu defolijaciju bila 250$/ha, strojno vršikanje 140 $/ha te za ručno plijevljenje 300 $/ha. Također navodi i rezultate istraživanja u vinogradu sorte 'Shiraz' površine 8,3 ha u kojem je na osnovu definiranih zona bujnosti procijenjena ušteda pri ručnoj rezidbi bila cca 2.400,00 $ (11,6%), a svaki rezač orezao je podjednak broj trsova slične zahtjevnosti (bujnosti), što je osiguralo svim radnicima sličnu zaradu i veće zadovoljstvo.

Ekonomski aspekt selektivne berbe uglavnom je povezan s diferencijacijom u cijeni grožđa iz različitih kvalitativnih zona u vinogradu uz pretpostavku cjenovnih vrijednosti npr. grožđa ili budućeg vina. S tim u vezi, Bramley i sur. (2003) navode kako selektivna berba grožđa iz dvije zone može osigurati 101.610,00 $ veću bruto vrijednost proizvodnje grožđa na 3,3 ha površine vinograda, zbog mogućnosti proizvodnje dviju različitih kategorija vina sorte 'Cabernet sauvignon' koje mogu imati različitu prodajnu cijenu vezanu uz kakvoću vina. Bramley i sur. (2005b) navode ekonomske koristi u četiri različite studije slučaja u kojima je provedena selektivna berba, pri čemu su povećanja prihoda od proizvodnje grožđa sorte ‘Shiraz’ iznosila 3,2% (Padthayway, SA), 12,5% (Margaret River, WA), od sorte 'Rizling' 77,8% (Clare Valley), a od proizvodnje vina sorte 'Shiraz' 20,5% (Padthayway, SA) i vina sorte 'Cabernet sauvignon' 19,2 % (Margaret River, WA).

U svojim daljnjim istraživanjima Bramley i sur. (2011b) pokazuju kako je selektivna berba dobar pristup pri upravljanju vinogradima u različitim tipovima vinarija- od malih „butik“ vinarija, preko većih dobro opremljenih vinarija pa sve do velikih proizvođača vina

„premium“ kvalitete, uz prijelaz na „super premium“ vina, što može donijeti povećanje cijene za cca 5$ po butelji vina. Osim toga, selektivna berba može biti profitabilna i za proizvođače grožđa koji prodaju grožđe velikim vinarijama uz povećanje profita od cca 9% zbog razlike u otkupnoj cijeni grožđa više kvalitete.

Rousseau i sur. (2013) navode kako selektivna berba vodi prema segmentaciji različitih stilova vina u proizvodnji jer je moguće branje i prerada grožđa iste razine dozrelosti te sama prerada može biti bolje prilagođena kvaliteti grožđa. Isto tako, zone veće bujnosti moguće je brati kasnije kako bi grožđe doseglo bolju razinu dozrelosti, a time i kvalitete. Nadalje, autori navode kako se selektivnom berbom može povećati postotak „super premium“ vina, a time i prihod od same proizvodnje i to od 800 do 5.000 EUR/ha ovisno o prodajnim cijenama vina.

3. MATERIJALI I METODE RADA

3.1. Lokacije pokusnih vinograda

Istraživanje je provedeno tijekom 2019. i 2020. godine na području Zagrebačke županije u dva vinogorja – vinogorje Zelina i vinogorje Plešivica-Okić. U istraživanje su bile uključene dvije sorte vinove loze- 'Kraljevina' i 'Pinot crni' (*Vitis vinifera* L.) na četiri različite lokacije i četiri različite površine vinograda. U vinogorju Zelina istraživanje je provedeno u vinogradima sorte 'Kraljevina' u vlasništvu OPG Karlo Kos na površini 0,47 ha i OPG Puhelek- Purek na površini 0,93 ha. U vinogorju Plešivica-Okić istraživanje je provedeno u vinogradima sorte 'Pinot crni' u vlasništvu Vina Tomac na površini 0,33 ha i PG Šember na površini 0,65 ha. U tablici 5 navedeni su detaljni opisi lokacija vinograda u kojima je provedeno istraživanje.

Tablica 5. Opis lokacija pokusnih vinograda

Lokacija	**TOMAC**	**ŠEMBER**	**KOS**	**PUHELEK-PUREK**
Sorta vinove loze	'Pinot crni'	'Pinot crni'	'Kraljevina'	'Kraljevina'
Površina	0,33 ha	0,65 ha	0,47 ha	0,93 ha
Vinogorje/ Položaj	Plešivica- Okić/ Šipkovica	Plešivica- Okić/ Vučjak	Zelina/ Pisačićev breg	Zelina/ Pušćak
Nadmorska visina	301 m	269-306 m	193-221 m	291-337 m
Podloga	*Vitis berlandieri x Vitis riparia* SO4	*Vitis berlandieri x Vitis riparia* K5BB	*Vitis berlandieri x Vitis riparia* K5BB	*Vitis berlandieri x Vitis riparia* K5BB
Godina sadnje	1999	2005	2007 / 2015	1996 - 2015
Razmak sadnje	2,20 x 0,80 m	2,20 x 0,80 m	2,00 x 0,80 m	2,20 x 0,80 m
Uzgojni oblik	Jednokraki Guyot	Jednokraki Guyot	Jednokraki Guyot	Jednokraki Guyot
Smjer pružanja redova	JI	JZ	J, JZ	J, JZ
Tip tla[1]	Rendzina na laporu (flišu) ili mekim vapnencima	Rendzina na laporu (flišu) ili mekim vapnencima	Pseudoglej obronačni	Pseudoglej obronačni
Geografska lokacija vinograda	45° 42' 19,914" N 15° 38' 50,952" E	45° 42' 11,664" N 15° 39' 10,446" E	45° 55' 29,1" N 16° 11' 9,744" E	45° 57' 39,498" N 16° 13' 11,136" E

[1] Prema: Regionalizacija poljoprivredne proizvodnje u Zagrebačkoj županiji (Zagreb, 2004)

3.2. Karakteristike vinogorja i klimatske značajke

3.2.1. Vinogorje Zelina

Vinogorje Zelina dio je podregije Prigorje- Bilogora. Vinogorje Zelina smješteno je na istočnim obroncima Medvednice, pretežito južne i istočne ekspozicije, s različitim stupnjem nagiba. Uglavnom dominiraju visinske zaravni i blage padine za uzgoj loze. Najvažniji položaji su Sv. Ivan Zelina, Psarjevo, Biškupec, Drenova, Nespeš i dr. Nadmorska visina je od 150 do 400 m (Mirošević i sur., 2009), a od tipova tla prevladavaju lesivirana tla i pseudogleji (Maletić i sur., 2008). Vinogorje karakteriziraju uvjeti kontinentalne klime, sa srednjom godišnjom temperaturom zraka oko 10°C, prosječnom godišnjom količinom oborina od 800-1000 mm i prosječnom sumom sati sijanja sunca od 1892-1978 sati na godinu što omogućava pravilan tijek svih fenofaza razvoja vinove loze (Maletić i sur., 2008). Srednja godišnja temperatura u vegetaciji (IV.-IX.) je 17,8°C, a količina oborina u vegetaciji (IV.-IX.) je 485 mm (Mirošević i sur., 2009).

3.2.1.1. Klimatske značajke vinogorja Zelina u 2019. i 2020. godini

Meteorološki podaci za 2019. i 2020. godinu dobiveni su od Državnog hidrometeorološkog zavoda (DHMZ) s klimatološke postaje Sv. Ivan Zelina.

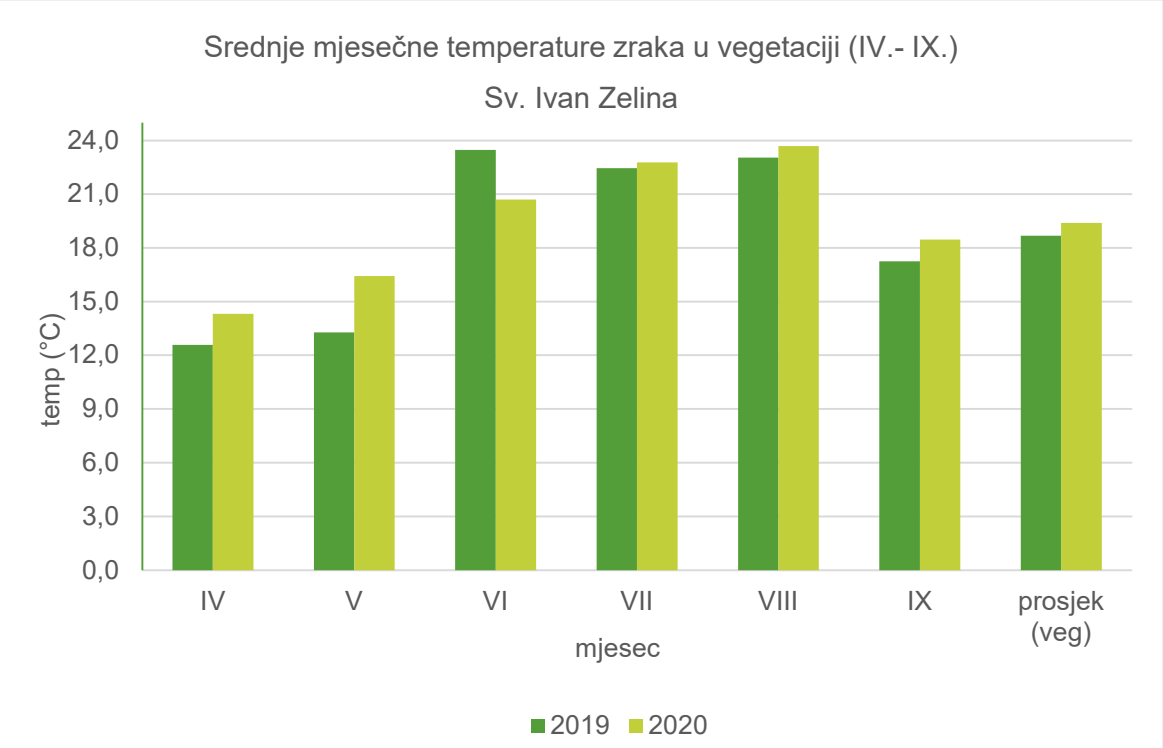

Grafikon 1. Srednje mjesečne temperature zraka u vegetaciji (IV.- IX. mjeseca), Sv. Ivan Zelina, 2019. i 2020. godina (izvor: DHMZ, 2021)

Iz grafikona 1 može se vidjeti da je u promatranom dvogodišnjem vegetacijskom razdoblju mjesec s najvišom srednjom mjesečnom temperaturom bio kolovoz 2020. godine s temperaturom od 23,7°C, dok je najhladniji mjesec bio travanj 2019. godine s prosječnom temperaturom od 12,6°C. Srednja temperatura u vegetaciji 2019. godine bila je 18,7°C, a 2020. godine 19,4°C. Prema Mirošević i sur. (2009) srednja godišnja temperatura u vegetaciji (IV.-IX.) je 17,8°C, iz čega se može zaključiti kako su obje vegetacijske godine bile toplije u odnosu na prosječne klimatske uvjete vinogorja. Iz grafikona 1 također je vidljivo da su srednje mjesečne temperature u vegetaciji u 2020. godine bile više u odnosu na 2019. godinu, uz iznimku za mjesec lipanj 2019. godine. Ovakav raspored srednjih mjesečnih temperatura u vegetaciji po mjesecima odrazio se i na prosječnu temperaturu u vegetaciji koja pokazuje da je 2020. godina bila za 0,7°C prosječno toplija u odnosu na 2019. godinu. Temeljem svega navedenog može se zaključiti da su klimatske prilike bile iznimno povoljne za uzgoj vinove loze i dozrijevanje grožđa u 2019. i 2020. godini. U obje promatrane godine u razdoblju cvatnje te rasta i razvoja bobica vladale su pogodne temperature za pravilno odvijanje svake fenofaze razvoja vinove loze.

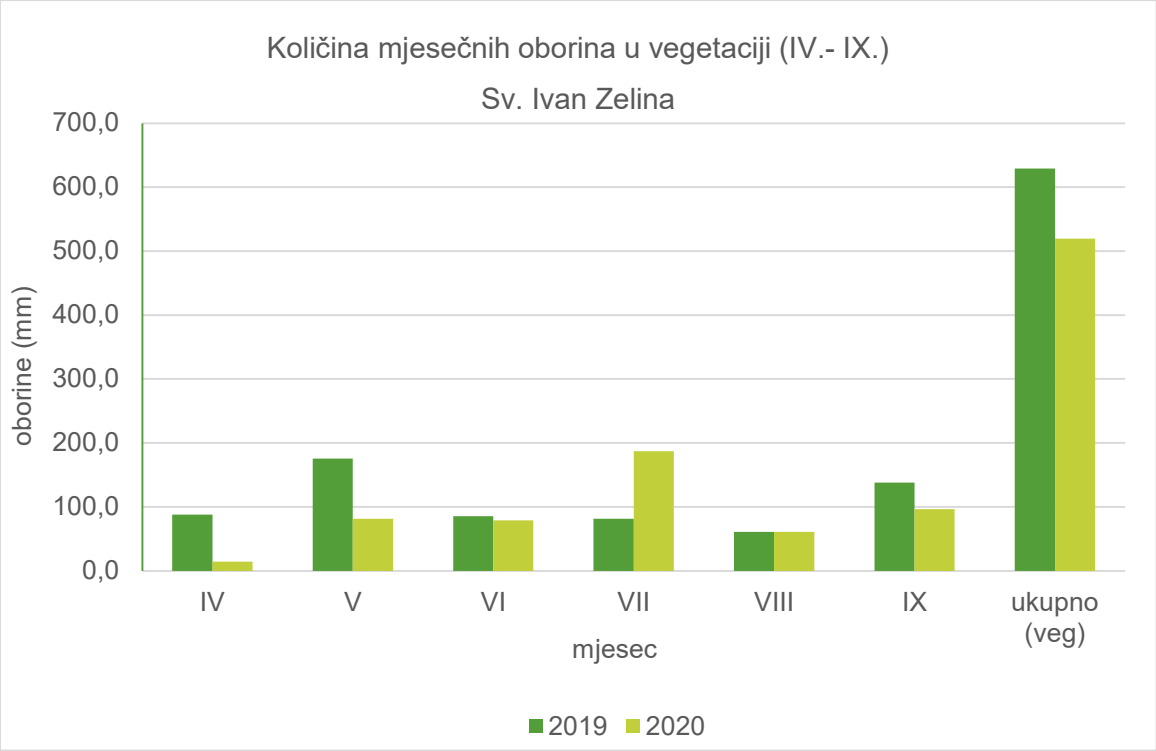

Grafikon 2. Količina mjesečnih oborina u vegetaciji (IV.- IX.), Sv. Ivan Zelina, 2019. i 2020. godina (izvor: DHMZ, 2021)

Iz grafikona 2 može se vidjeti da je ukupna količina oborina u vegetacijskom periodu 2019. godine iznosila je 629,30 mm, a 2020. godine 519,30 mm. Prema Mirošević i sur. (2009) količina oborina u vegetaciji (IV.-IX.) je 485 mm, iz čega se može zaključiti kako su

obje vegetacijske godine imale veće količine oborina u odnosu na prosječne klimatske uvjete vinogorja, a posebice 2019. godina kada je u vegetaciji palo 110 mm više oborina nego u 2020. godini. Međutim, raspored oborina tijekom vegetacije bio je različit te je vidljivo da je u 2019. godini najviše oborina palu svibnju (175,50 mm), a 2020. godine u srpnju (187,50 mm). Veća količina oborina u rujnu (137,80 mm) uzrokovala je nešto lošije zdravstveno stanje grožđa zbog prisutnosti gljivičnih bolesti, prvenstveno sive plijesni (*Botrytis cinerea*). Također, vidljivo je da je u 2020. godini bila povoljnija količina oborina u fenofazi rasta i razvoja bobica (srpanj) i dovoljna količina vode koja u ovoj fazi može biti ograničavajući faktor rasta bobice (Maletić i sur., 2008). Može se zaključiti kako su obje godine bile zadovoljavajuće za rast i razvoj vinove loze, uz posebnosti svake od njih vezane za raspored i količinu oborina.

3.2.2. Vinogorje Plešivica-Okić

Vinogorje Plešivica-Okić dio je podregije Plešivica. Razvijeno je na jugoistočnim obroncima Plešivice, a plešivički vinogradi stvaraju sliku karakterističnih „amfiteatara“, koji osiguravaju vinogradima povoljnu ekspoziciju. Većina vinograda nalazi se na tlima razvijenim na laporu koja su dosta sklona eroziji te na pseudoglejnim tlima (Maletić i sur., 2008).

Vinogorje karakteriziraju uvjeti kontinentalne klime, s prosječnom godišnjom temperaturom zraka od 10 do 11°C, prosječnom godišnjom količinom oborina od 1000-1100 mm (Maletić i sur., 2008) i prosječnom sumom sati sijanja sunca od 1868 sati (Mirošević i sur., 2009). Srednja godišnja temperatura u vegetaciji (IV.-IX.) je 17,7°C, a količina oborina u vegetaciji (IV.-IX.) je 591 mm (Mirošević i sur., 2009).

3.2.2.1. Klimatske značajke vinogorja Plešivica-Okić u 2019. i 2020. godini

Meteorološki podaci za 2019. i 2020. godinu dobiveni su od DHMZ s automatske klimatološke postaje Goli Vrh (Općina Klinča Sela).

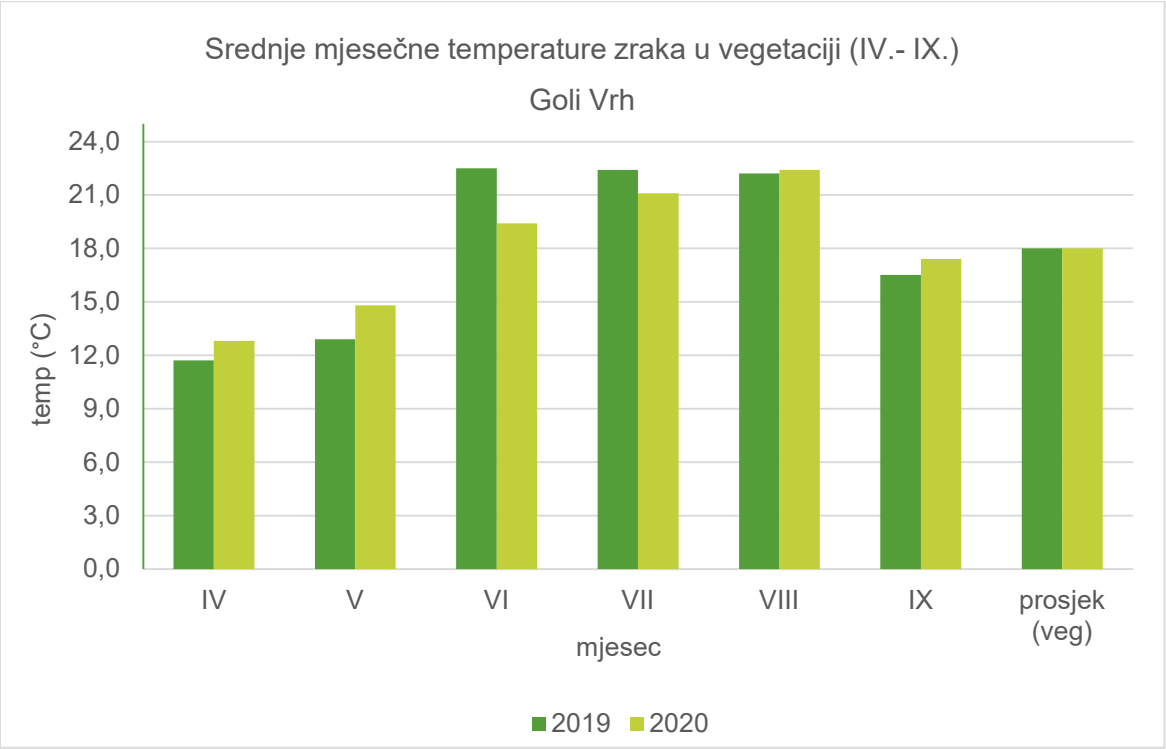

Grafikon 3. Srednje mjesečne temperature zraka u vegetaciji (IV.-IX.), Goli Vrh, 2019. i 2020. godina (izvor: DHMZ, 2021)

Iz grafikona 3 može se vidjeti da je u promatranom dvogodišnjem vegetacijskom razdoblju mjesec s najvišom srednjom mjesečnom temperaturom bio lipanj 2019. godine s temperaturom od 22,5°C, dok je najhladniji mjesec bio travanj 2019. godine s prosječnom temperaturom od 11,7°C. Srednja temperatura u vegetaciji i 2019. i 2020. godine bila je 18,0°C, Prema Mirošević i sur. (2009) srednja godišnja temperatura u vegetaciji (IV.-IX.) je 17,7°C, iz čega se može zaključiti kako su obje vegetacijske godine bile u skladu s prosječnim klimatskim uvjetima vinogorja te temperaturne prilike nisu odstupale od uobičajenih za ovo područje. 2020. godina imala je gotovo pravilan postepen rast temperatura tijekom vegetacije, dok je u 2019. godina izraženiji temperaturni skok između svibnja i lipnja, no bez negativnih utjecaja na rast i razvoj vinove loze. Temeljem navedenog može se zaključiti da su klimatske prilike bile iznimno povoljne za uzgoj vinove loze i dozrijevanje grožđa u 2019. i 2020. godini. U obje promatrane godine u razdoblju cvatnje te rasta i razvoja bobica vladale su pogodne temperature za pravilno odvijanje svake fenofaze razvoja vinove loze.

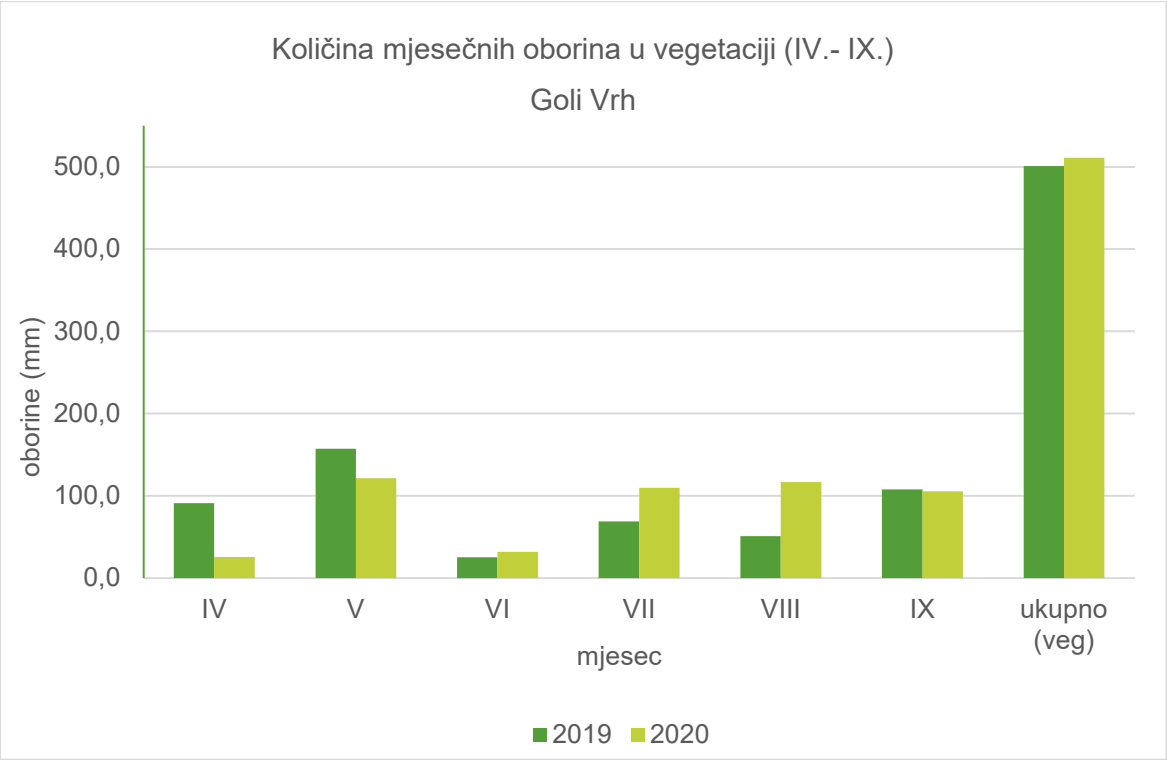

Grafikon 4. Količina mjesečnih oborina u vegetaciji (IV.-IX.), Goli Vrh, 2019. i 2020. godina (izvor: DHMZ, 2021)

Iz grafikona 4 može se vidjeti da je ukupna količina oborina u vegetacijskom periodu 2019. godine iznosila 500,8 mm, a 2020. godine 511 mm. Prema Mirošević i sur. (2009) količina oborina u vegetaciji (IV.-IX.) je 591 mm, iz čega se može zaključiti kako su obje vegetacijske godine imale nešto manje količine oborina u odnosu na prosječne klimatske uvjete vinogorja. Međutim, vidljivo je kako je obje godine u lipnju količina oborina bila niska (25,1 mm u 2019. i 31,9 mm u 2020. godini), posebice u odnosu na svibanj kada je količina oborina u obje godine bila dosta visoka (157,4 mm u 2019. i 121,4 mm u 2020. godini). Raspored oborina tijekom vegetacije bio je nešto povoljniji u 2020. godini, pogotovo u fenofazi rasta i razvoja bobice (srpanj 2020). Veće količine oborina u kolovozu 2020. godine uzrokovale su nešto lošije zdravstveno stanje grožđa zbog prisutnosti gljivičnih bolesti, prvenstveno sive plijesni (*Botrytis cinerea*). Može se zaključiti kako su obje godine bile zadovoljavajuće za rast i razvoj vinove loze te dobro dozrijevanje grožđa.

3.3. Karakteristike sorata vinove loze 'Kraljevina' i 'Pinot crni' (*Vitis vinifera* L.)

3.3.1. 'Kraljevina' (*Vitis vinifera* L.)

'Kraljevina', kao stara hrvatska autohtona sorta najviše se uzgaja u sjeverozapadnoj Hrvatskoj na području Prigorja i Plešivice. Sinonimi (ostala poznata imena) su: Kraljevina crvena, Imbrina, Rotter Portugieser, Königstraube, Brina, Moravina, Kralevina, Kralovina, Piros oporto, Porthogese rosso, Portugais rose, Portugais rouge, Piros leanyka, Rdeča kraljevina. Točno podrijetlo, tj. mjesto nastanka sorte nije utvrđeno, ali s obzirom na to da niti u dostupnim literaturnim izvorima iz povijesti niti danas sorta nije u uzgoju osim na području Hrvatske i manjim dijelom Slovenije, može se smatrati autohtonom sortom sjeverozapadne Hrvatske (Maletić i sur., 2015).
U Republici Hrvatskoj 'Kraljevina' se uzgaja na 189,52 ha, ukupno je zasađeno 1.259.900 trsova te spada među dvadeset vodećih sorata vinove loze (APRR, 2021.)

3.3.1.1. Ampelografske karakteristike, biološka i gospodarska svojstva

Vrh mladice je otvoren, gladak s prisutnim intenzivnim antocijanskim obojenjem. Boja mladih listova je brončano zelena, dok su odrasli listovi okrugli, najčešće trodijelni. Sinus peteljke je otvoren, s često prisutnim zupcem s jedne strane ili obiju strana. List je na licu gladak i sjajan, a glavne žile su zelene boje s tek ponekad antocijanskim obojenjem u peteljkinoj točki. Na naličju između glavnih žila list je gotovo potpuno gol. Cvijet je morfološki i funkcionalno hermafroditan. Zreli grozd je srednje dug do dug, ljevkastog ili konusnog oblika te srednje zbijen do zbijen. Zrele bobice su okrugle, zelenožute boje, koja na sunčanoj strani najčešće dobije ružičaste ili crvenkaste nijanse. Veličina grozda i izgled bobica variraju zbog visoke unutarsortne varijabilnosti, pa bobice mogu biti i potpuno crvene te posute točkama i pjegama različite veličine i intenziteta. Meso je srednje čvrsto i neutralnog mirisa (Maletić i sur., 2015).
'Kraljevina' s vegetacijom počinje srednje kasno, dozrijeva srednje kasno, tj. u III. razdoblju te je bujna do vrlo bujna sorta. Odlikuje se visokom i redovitom rodnošću te visokim prinosima po trsu i jedinici površine. U punoj zrelosti koncentracija šećera je niska do srednja, uz relativno visoku ukupnu kiselost, što daje prepoznatljivu svježinu vinima ove sorte.
Zbog visokih prinosa, često postiže nisku cijenu grožđa i vina, a pokazuje značajne razlike ovisno o položaju i tehnologiji proizvodnje. Često se izdvajaju tri „tipa“ sorte 'Kraljevina', odnosno klonske razlike unutar sorte koje se nerijetko označavaju različitim imenima:

„crvena“, „zelena“ i „mirisava“ ili „pikasta“. Te se razlike odnose na boju i izgled kožice, a o tome u pravilu ovisi i kvaliteta vina. Tako je najkvalitetnija „mirisava“ („pikasta“), ali i najmanje rodna. S druge je strane najrodnija „zelena“, ali jednako tako daje i najslabija vina. To je bio i razlog pokretanja projekta klonske selekcije sorte 'Kraljevina' prije dvadesetak godina, gdje je visoka unutarsortna raznolikost i dokazana, ali je također utvrđeno da su ove karakteristike u izravnoj vezi s tehnologijom uzgoja (Maletić i sur., 2015).

U 2002. godini dobila je oznaku kvalitete Zagrebačke županije te se proizvodi pod robnom markom „Kraljevina Zelina“, a 2003. godine započeo je projekt klonske selekcije sorte 'Kraljevina', čime je omogućena sadnja certificiranih bezvirusnih klonskih kandidata. Oba projekta doprinijela su očuvanju, popularizaciji i promociji ove vrijedne autohtone sorte.

3.3.2. 'Pinot crni' (*Vitis vinifera* L.)

'Pinot crni' je jedna od najstarijih, najpoznatijih i najkvalitetnijih sorata vinove loze za proizvodnju crnih vina. Sinonimi (ostala poznata imena) su Pinot ili Pineau noir, Franc Noirien i mnogi drugi u Francuskoj, Pinot nero, Burgunder ili Spätburgunder blauer, Black Burgundy, i dr. Potječe iz Francuske (Burgundija), rasprostranjen je u svim vinorodnim zemljama svijeta umjerene klime (Mirošević i Turković, 2003), a u Hrvatskoj se pretežno uzgaja u kontinentalnom dijelu te u Istri. U Republici Hrvatskoj sorta 'Pinot crni' se uzgaja na 183,33 ha, ukupno je zasađeno 982.252 trsa te spada među dvadeset vodećih sorata vinove loze (APRR, 2021.)

3.3.2.1. Ampelografske karakteristike, biološka i gospodarska svojstva

Vršci mladica malo su pahuljasti, bjelkasti, uspravni i kratki. Odrasli list je tamno zelene boje, okruglastog oblika, srednje velik, debeo, trodijelan do peterodijelan. U jesen pocrveni najprije na rubovima, i tim jače što je trs slabiji. Sinus peteljke je oblika „U“ ili lire. Naličje je golo ili s rijetkim paučinastim dlačicama u čupercima. Površina lista je neravna, hrapava ili mjehurasta, a zupci su nejednaki te mali i tupi. Zreli grozd je malen, gust, valjkast ili malo stožast, jednostavan. Zrele bobice su malene, tamne, ljubičasto modre, jako oprašene, okruglaste ili duguljaste. Kožica je srednje debela, a meso je sočno. Sok je neobojen karakterističnog sortnog okusa (Mirošević i Turković, 2003).

'Pinot crni' je u cvatnji dosta otporan, dok je slabije otporan na peronosporu. Dozrijeva u I. razdoblju, rodnost je mala, ali redovita uz izvrsnu kakvoću. Najbolje uspijeva na toplim brežuljkastim položajima, na jačim tlima s nešto vlage i može dati vina vrhunske kakvoće pogodna za duža čuvanja (Mirošević i Turković, 2003).

3.4. Provedba istraživanja

Prikupljanje i analize podataka izvršene su zasebno na sve četiri opisane lokacije. Ciljani trsovi su prije ručnih uzorkovanja i daljinskih snimanja odabrani slučajnim odabirom i fizički označeni s ciljem prostorne pokrivenosti ovisno o veličini parcele u svakom vinogradu (Bonilla i sur., 2015) te su georeferencirani GPS koordinatama uz provjeru lokacija u samom vinogradu. U drugoj godini istraživanja (2020) dodatno je uključeno ukupno 11 ciljanih trsova na tri lokacije kako bi se izvršila dodatna mjerenja na određenim dijelovima vinograda prema rezultatima mjerenja u 2019. godini (Bonilla i sur., 2015). U tablici 6 naveden je broj ciljanih trsova po lokaciji u 2019. i 2020. godini.

Tablica 6. Broj ciljanih trsova po pokusnom vinogradu u 2019. i 2020. godini

Lokacija		**TOMAC**	**ŠEMBER**	**KOS**	**PUHELEK-PUREK**
Vinogorje/ Položaj		Plešivica- Okić/ Šipkovica	Plešivica- Okić/ Vučjak	Zelina/ Pisačićev breg	Zelina/ Pušćak
Sorta vinove loze		'Pinot crni'	'Pinot crni'	'Kraljevina'	'Kraljevina'
Površina		0,33 ha	0,65 ha	0,47 ha	0,93 ha
Broj ciljanih trsova	2019	9	18	12	-
	2020	13 (+4)	23 (+5)	14 (+2)	36

U nastavku su nalaze slike svih lokacija s prikazanim prostornim rasporedom ciljanih trsova.

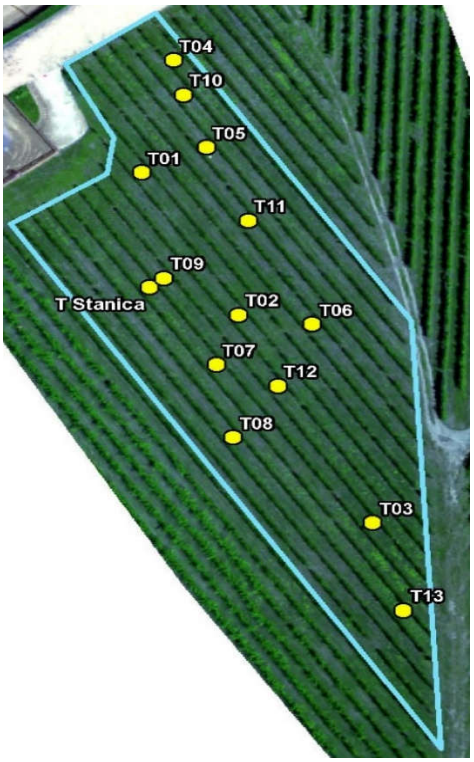

Slika 7. Lokacija TOMAC s prikazom rasporeda 13 ciljanih trsova i površinom obuhvata 0,33 ha (označeno plavom bojom)

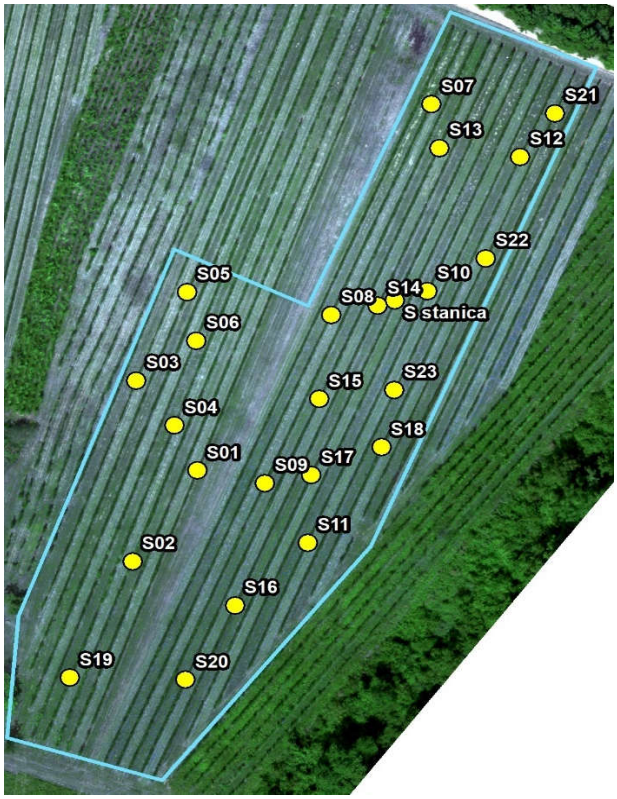

Slika 8. Lokacija ŠEMBER s prikazom rasporeda 23 ciljana trsa i površinom obuhvata 0,65 ha (označeno plavom bojom)

Slika 9. Lokacija KOS s prikazom rasporeda 14 ciljanih trsova i površinom obuhvata 0,47 ha (označeno plavom bojom)

Slika 10. Lokacija PUHELEK- PUREK s prikazom rasporeda 36 ciljanih trsova i ukupnom površinom obuhvata 0,93 ha (označeno plavom bojom)

3.4.1. Prikupljanje podataka multispektralnom kamerom

Za utvrđivanje mogućnosti primjene vegetacijskih indeksa NDVI, NDRE i OSAVI za zoniranje vinograda prema bujnosti vinove loze podaci su se prikupljali daljinskim snimanjima korištenjem bespilotne letjelice (slika 11) DJI Inspire 1 Pro opremljene Micasense RedEdge.MX™ multispektralnom kamerom (senzorom) koja je opremljena GPS uređajem, naprednim senzorom za detekciju intenziteta i kuta sunčevog svjetla te tzv. „global shutter“ digitalnim senzorima koji osiguravaju visoku kvalitetu fotografija snimanih s letjelice u pokretu. Multispektralni senzor Micasense RedEdge.MX™ (slika 12) pokriva 5 spektralnih područja: B (459-491 nm), G (547-573 nm), R (661-675 nm), RE (711-723 nm) i NIR (814-870 nm). Prije svakog snimanja napravljen je plan autonomnog leta kao i potrebne kalibracije uređaja, a planom snimanja definirano je preklapanje više od 80% između fotografija, kako bi se prikupio odgovarajući set podataka i postigla veća točnost pri procesu fotogrametrije, odnosno pri obradi snimaka.

Slika 11. Bespilotna letjelica DJI Inspire 1 Pro opremljena Micasense RedEdge.MXTM multispektralnim senzorom

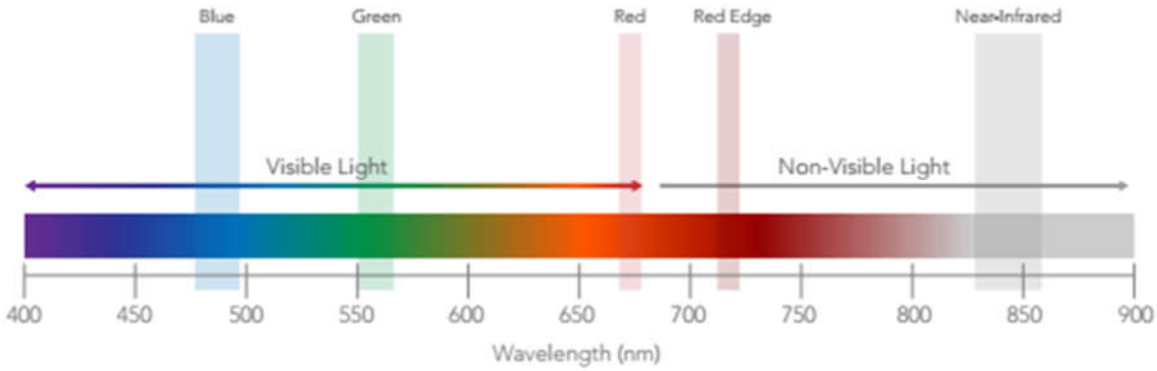

Slika 12. Spektralno područje senzora Micasense RedEdge.MXTM
(Izvor: https://micasense.com/rededge-mx/)

Daljinska snimanja provedena su tijekom dvije vegetacijske sezone (2019. i 2020. godina) na tri lokacije istraživanje (KOS, TOMAC, ŠEMBER) u tri različite fenofaze razvoja vinove loze: početak nakupljanja šećera, srednje vrijednosti šećera i tehnološka zrelost grožđa što odgovara fenofazama 34, 36 i 38 prema modificiranoj E-L skali za praćenje fenofaza vinove loze (Coombe, 1995), dok su na lokaciji PUHELEK- PUREK snimanja uspješno izvršena samo u 2020. godini u dvije različite fenofaze razvoja vinove loze: 36- srednje vrijednosti šećera i 38- tehnološka zrelost grožđa. Sva snimanja napravljena su u uvjetima povoljnih atmosferskih prilika (sunčan dan bez naoblake i vjetra) u periodu najboljeg dnevnog svjetla od 10-14 h te na visini od 70 m, dajući rezoluciju od 4,5-5 cm/pikselu. Kako bi se snimke iz različitih termina snimanja mogle međusobno uspoređivati, sve snimke georeferencirane su korištenjem GCP (engl. *Ground Control Points*) s GPS koordinatama očitanim korištenjem Huawei P30 Pro mobilnog uređaja koji podržava GNSS L5 signal visoke preciznosti i Position Estimator softvera. Termini prikupljanja podataka multispektralnom kamerom navedeni su u tablici 7.

Tablica 7. Termini prikupljanja podataka multispektralnom kamerom u 2019. i 2020. godini

Lokacija		**TOMAC**	**ŠEMBER**	**KOS**	**PUHELEK-PUREK**
2019. godina	Fenofaza 34	30.07.	30.07.	31.07.	-
	Fenofaza 36	25.08.	24.08.	26.08.	-
	Fenofaza 38	04.09.	04.09.	15.09.	-
2020. godina	Fenofaza 34	30.07.	30.07.	30.07.	-
	Fenofaza 36	21.08.	21.08.	21.08.	21.08.
	Fenofaza 38	27.08.	27.08.	10.09.	10.09.

Obrada prikupljenih multispektralnih snimaka najvažniji je proces pri izračunu vegetacijskih indeksa. Nakon svakog leta, snimke su učitane u aplikaciju ATLAS MicaSense (MicaSense, Seattle, Washington, https://micasense.com/atlas-flight/). Aplikacija koristi Pix4d programski paket (Pix4d, Lausanne, Švicarska, https://www.pix4d.com/) i odgovarajuće algoritme za povezivanje slika i stvaranje georeferenciranog višeslojnog orto-mozaika letenja za svaki termin snimanja u GeoTIFF formatu. GeoTIFF kalibrirane karte refleksije za svih pet spektralnih područja (B, G, R, RE, NIR) i svaki termin snimanja uvezene su i obrađene u ArcGIS programskom paketu (ESRI, 2012). Zbog tehničkih problema prilikom prikupljanja podataka multispektralnom kamerom i učitavanja snimaka te kreiranja GeoTIFF kalibriranih karti refleksije na lokaciji PUHELEK- PUREK nisu generirane karte refleksije u 2019. godini te u prvom terminu snimanja u 2020. godini (srpanj 2020. godine). Provedeno je ručno identificiranje osi redova na temelju RGB snimke visoke rezolucije, a korištenjem alata BUFFER (ArcGIS) određene su površine redova i to na udaljenosti 45 cm od osi redova na obje strane. Na taj način odvojeni su podaci vegetacije vinove loze od tla (Delenne i sur., 2010, Ledderhof i sur., 2015). Iako je metoda ručnog segmentiranja redova prilično dugotrajna, na manjim i nejednakim površinama vinograda koje su se koristile za ovo istraživanje, bila je zadovoljavajuća i svrhovita, u usporedbi s kompliciranijim algoritamskim automatskim metodama predloženim u dosadašnjim istraživanjima (Comba i sur., 2015; Nolan i sur., 2015; Primicerio i sur., 2015; Matese i sur., 2017; DeCastro i sur., 2018; Pauda i sur., 2019) za čiju primjenu su potrebna specifična znanja i vještine za obradu prostornih podataka, a mnoge metode su još uvijek u znanstveno- istraživačkoj fazi razvoja. U daljnjoj obradi snimaka korištene su karte refleksije na kojima su odvojeni podaci vegetacije vinove loze od tla i na koje je dodan sloj (oznaka) ciljanih trsova temeljem koordinatnog položaja svakog ciljanog trsa (Ledderhof i sur., 2015). Na tako pripremljenim kartama refleksije za svaki termin i obje godine, unutar reda generirane su točke na udaljenosti od 2 m pomoću alata GENERATE POINTS ALONG LINES (ArcGIS) dok je površina unutar reda generirana pomoću alata BUFFER s pripremljenim radijusom od 0,5 m od lokacija generiranih u prethodnom koraku uz preklapanje s površinama redova (Bonilla i sur., 2015; Maynard, 2015). Za svaku ovako generiranu referentnu zonu (površinu) unutar reda provedena je kalkulacija vrijednosti vegetacijskih indeksa NDVI, NDRE i OSAVI pomoću alata ZONAL STATISTICS (ArcGIS) (Maynard, 2015). Geostatističkom analizom, metodom KRIGING (ArcGIS), na temelju vrijednosti dobivenih u prethodnom koraku izrađene su interpolirane karte NDVI, NDRE i OSAVI na promatranom području (Bonilla i sur., 2015, Oldoni i sur., 2021, Campos i sur., 2021), a dobivene vrijednosti kartografski su prikazane u dvije zone (klase) na temelju medijalne vrijednosti vegetacijskog indeksa. Završno, za svaku lokaciju i svaki termin snimanja

izrađene su generirane interpolirane karte NDVI, NDRE i OSAVI vegetacijskih indeksa s dvije zone bujnosti i prikazom lokacije ciljanih trsova na karti. Ovako pripremljene karte bujnosti- s prikazom zone manje (zelena) i veće (crvena) bujnosti u svim terminima i na svim lokacijama, korištene su u naknadnoj statističkoj analizi kako bi se utvrdila povezanost vegetacijskih indeksa odnosno zona bujnosti i ostalih podataka prikupljenih ručnim uzorkovanjem na ciljanim trsovima (Campos i sur., 2021). Na slici 13 prikazan je skraćeni grafički prikaz obrade multispektralnih snimaka u ArcGIS programskom paketu.

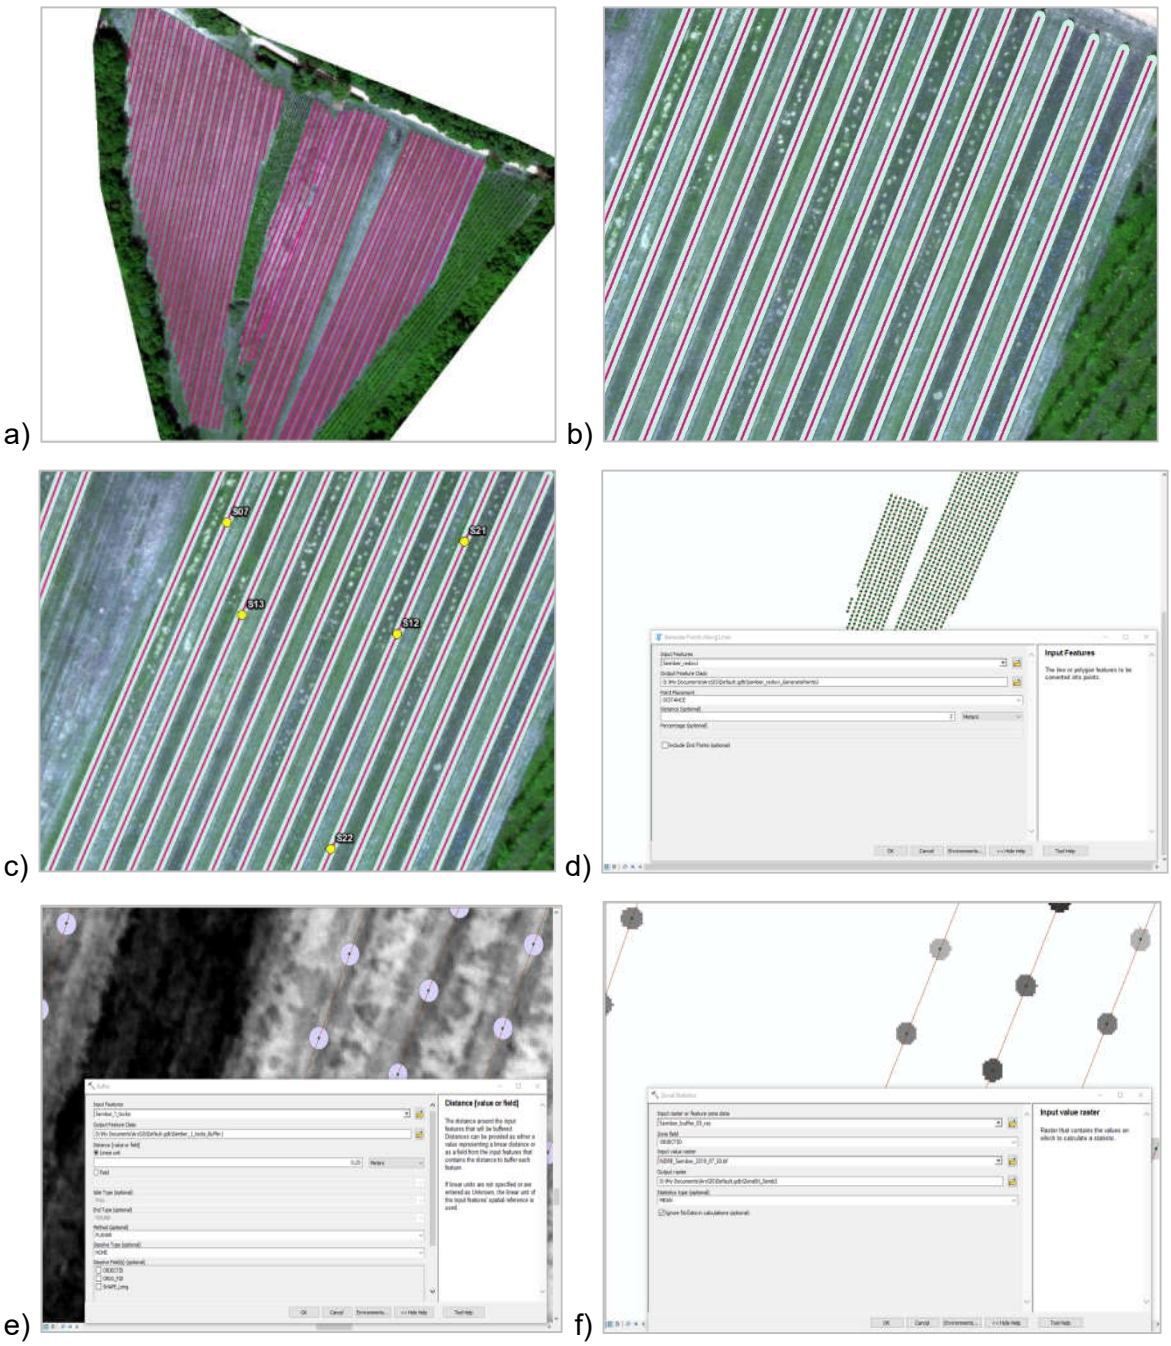

g)

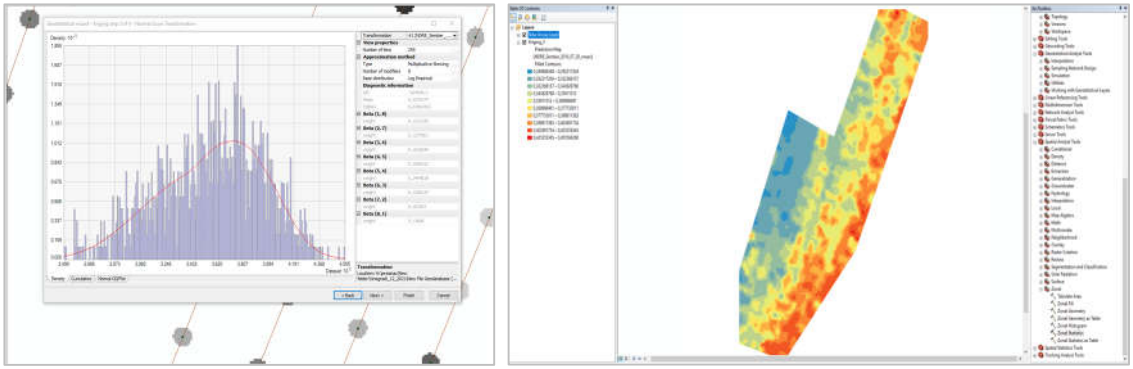

i)

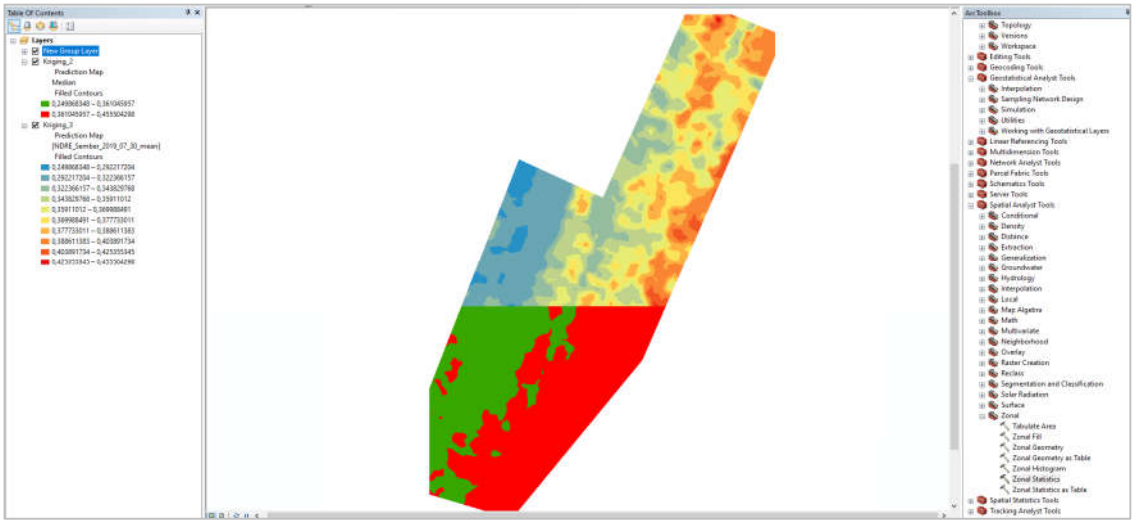

Slika 13. Skraćeni prikaz obrade multispektralnih snimaka u ArcGIS programskom paketu:

a) ručno identificiranje osi redova na temelju RGB snimke visoke rezolucije;

b) određivanje površina redova- alat BUFFER, na udaljenosti 45 cm od osi redova;

c) dodavanje sloja referentnih trsova temeljem tablice s koordinatama položaja;

d) generiranje točaka na promatranim redovima na udaljenosti od 2 m -alat GENERATE POINTS ALONG LINES;

e) generiranje površina unutar reda- alat BUFFER s promjerom 0,5 m od lokacija generiranih u prethodnom koraku;

f) izračun medijalne vrijednosti indeksa (NDVI, NDRE i OSAVI)- alat ZONAL STATISTICS, pri čemu je svaka površina generirana u prethodnom koraku definiran kao jedna zona;

g) geostatističkom analizom, metodom KRIGING, na temelju vrijednosti dobivenih u prethodnom koraku izrađene su karte vrijednosti NDRE, NDVI i OSAVI na promatranom području;

h) dobivene vrijednosti kartografski su prikazane u dvije zone (klase) na temelju medijalne vrijednosti.

Za izračun vegetacijskih indeksa NDVI, NDRE i OSAVI u ArcGIS programskom paketu korišteni su sljedeći matematički izrazi:

$\mathbf{NDVI} = \mathrm{NIR} - \mathrm{R}/\mathrm{NIR} + \mathrm{R}$ (Rouse i sur., 1973)

$\mathbf{NDRE} = \mathrm{NIR} - \mathrm{RE}/\mathrm{NIR} + \mathrm{RE}$ (Buschmann i Nagel, 1993)

$\mathbf{OSAVI} = (\mathrm{NIR} - \mathrm{R})/\mathrm{NIR} + \mathrm{R} + 0.16$ (Rondeaux i sur., 1996)

Dodatno je za svaku pojedinu generiranu kartu bujnosti izračunat postotak površine vinograda koji se nalazi u zoni manje bujnosti kao i postotak površine vinograda koji se nalazi u zoni veće bujnosti kako bi se mogli napraviti izračuni ekonomičnosti kvalitativnog zoniranja vinograda i selektivne berbe na temelju vegetacijskih indeksa.

3.4.2. Prikupljanje podataka ručnim uzorkovanjem

U obje vegetacijske godine (2019. i 2020.) prikupljeni su podaci ručnim uzorkovanjem na tri lokacije vinograda (KOS, TOMAC, ŠEMBER), dok je na lokaciji PUHELEK- PUREK prikupljanje podataka ručnim uzorkovanjem obavljeno samo u 2020. godini kako bi podaci bili kompatibilni s podacima prikupljenim multispektralnom kamerom. Termini prikupljanja podataka navedeni su u tablici 8. Prije prikupljanja podataka multispektralnom kamerom napravljeno je uzorkovanje lišća za mjerenje sadržaja ukupnog dušika u listu (% na bazi suhe tvari). Ukupni dušik u listu određen je u laboratoriju prema Kjeldahl metodi (AOAC, 1995). U istom terminu izbrojane su mladice i broj nodija (pupova) na svim ciljanim trsovima s ciljem utvrđivanja rodnosti temeljem koeficijenata rodnosti, kao pokazatelja generativnog potencijala sorte. Utvrđeni su koeficijent potencijalne rodnosti (KpR) – broj grozdova po pupu ostavljenom prilikom reza u zrelo i koeficijent relativne rodnosti (KrR) – broj grozdova po potjeraloj mladici (Maletić i sur., 2008). Koeficijent potencijalne rodnosti (KpR) izračunava se tako da se broj grozdova podijeli s brojem ostavljenih pupova (opterećenje), dok se koeficijent rodnosti mladica ili relativne rodnosti (KrR) izračunava dijeljenjem broja grozdova s ukupnim brojem mladica, a kreće se u vrlo širokim granicama 0,2-2,0. Vrijednosti do 0,5 označavaju sorte niskog KrR, do 1,0 srednjeg, do 1,5 visokog, a sorte koje pokazuju veće vrijednosti su sorte s vrlo visokim KrR (Maletić i sur., 2008).

U berbi su određene sastavnice prinosa - prinos po trsu (kg), prosječna masa grozda (kg), broj grozdova po trsu te su uzeti reprezentativni uzorci grožđa (3 grozda s različite pozicije na trsu), izmuljani u svježem stanju za osnovnu fizikalno- kemijsku analizu kvalitativnih svojstava grožđa (mošta) i to koncentracije šećera, ukupnih kiselina i pH vrijednosti. Koncentracija šećera u moštu određena je refraktometrijski (Master – Oe, ATAGO Japan) i izražena u stupnjevima Oechslea (°Oe). Ukupna kiselost mošta izražena je u g/L kao

vinska, a određivana je metodom neutralizacije uzorka s 0,1 M NaOH uz indikator bromtimol plavi prema metodi O.I.V.-a (2020). pH vrijednost mošta određena je mjerenjem na pH metru Schott, Lab 860.

Rezidba je napravljena u periodu zimskog mirovanja vinove loze te je izvagana masa orezane rozgve (kg) s ciljanih trsova kako bi se izračunao Ravazov vegetativno-proizvodni indeks tj. odredio odnos između generativnog i vegetativnog potencijala vinove loze. Prema Ravaz (1903) Indeks Ravaz se računa prema matematičkom izrazu:

$$\textbf{INDEKS RAVAZ} = \text{PRINOS/MASA OREZANE ROZGVE}$$

gdje se prinos iz trenutne berbe stavlja u odnos s masom orezane rozgve u sljedećoj sezoni zimskog mirovanja.

Tablica 8. Termini prikupljanja podataka ručnim uzorkovanjem u 2019. i 2020. godini

Lokacija		**TOMAC**	**ŠEMBER**	**KOS**	**PUHELEK-PUREK**
2019. godina	Uzorkovanje lišća i koef. rodnosti	09.07.	09.07.	11.07.	-
	Berba	10.09.	10.09.	17.09.	-
	Rezidba	13.01.2020.	13.01.2020.	22.01.2020.	-
2020. godina	Uzorkovanje lišća i koef. rodnosti	10.07.	10.07.	22.07.	22.07.
	Berba	27.08.	02.09.	18.09.	18.09.
	Rezidba	n/p	05.02.2021.	04.02.2021.	04.02.2021.

Na svim lokacijama pri prikupljanju podatka ručnim uzorkovanjem povremeno su se javila ograničenja u dostupnosti uzoraka te određeni parametri nisu mogli biti izmjereni u svim terminima na svim ciljanim trsovima. Ograničenja su se uglavnom odnosila na prijevremeno obrano grožđe na ciljanim trsovima ili prijevremeno provedenu zimsku rezidbu te su pri statističkim analizama korišteni isključivo cjelokupni setovi podataka, odnosno trsovi na kojima su iz bilo kojeg razloga nedostajali podaci, nisu korišteni u statističkoj analizi.

3.4.3. Prikupljanje podataka i metode za izračun ekonomske opravdanosti kvalitativnog zoniranja i selektivne berbe

S obzirom na složenost izračuna ekonomske opravdanosti za podatkovno intenzivne tehnologije, čijim korištenjem nije moguće direktno povećanje profitabilnosti, već one osiguravaju informacije koje omogućavaju kvalitetnije i učinkovitije upravljanje proizvodnjom kroz primjenu drugih tehnologija ili procesa (Castle, 2016), kao relevantni podaci korišteni su podaci o troškovima koji imaju direktan utjecaj na provedbu kvalitativnog zoniranja i selektivne berbe (trošak investicije u opremu, prikupljanje, priprema i obrada podataka te trošak selektivne berbe). Kao moguća razlika u prihodima koristi se mogućnost cjenovne diferencijacije grožđa prema kvaliteti nakon kvalitativnog zoniranja i selektivne berbe te razlika u prihodima koji bi nastali proizvodnjom različitih tipova vina na osnovu selektivne berbe sukladno kvalitativnim zonama u vinogradu određenih na temelju najprediktivnijeg vegetacijskog indeksa, što čini osnovu za izračun opravdanosti navedenih postupaka.

3.4.3.1. Prikupljanje podataka o troškovima i prihodima kvalitativnog zoniranja i selektivne berbe

Tehnologija vinogradarske proizvodnje sastoji se od provedbe različitih agrotehničkih i ampelotehničkih mjera s ciljem postizanja željene kakvoće grožđa. U ovom istraživanju sve uobičajene radne operacije u vinogradima i podrumu provodile su se po uobičajenom godišnjem planu i potrebi svakog od vinogradara. Istraživanje je prilagođeno operacijama u vinogradu i podrumu te je provedeno u dogovoru s vinogradarima. Isto tako, u obzir nisu uzeti troškovi koji se odnose na sve uobičajene radne operacije proizvodnje grožđa i vina, nego isključivo na operacije snimanja bespilotnim letjelicama, kvalitativno zoniranje i selektivnu berbu.

U ovom istraživanju bilježeni su fiksni i varijabilni troškovi pri provedbi i primjeni kvalitativnog zoniranja:

- Fiksni troškovi: Troškovi nabave opreme
    - Nabavna cijena nove bespilotne letjelice opremljene multispektralnom kamerom i potrebne prateće opreme
    - Obavezna edukacija za upravljanje bespilotnim letjelicama
    - Nabavna cijena novog računala za obradu podataka
    - Nabavna/pretplatna cijena programskog paketa za obradu podataka
    - Edukacija za obradu podataka prikupljenih bespilotnim letjelicama
    - Osiguranje i registracija opreme

- Varijabilni troškovi: troškovi ljudskog rada
    - vrijeme potrebno za ručno uzorkovanje na ciljanim trsovima (tri puta tijekom vegetacijske sezone, sukladno tablici 8)
    - vrijeme potrebno za edukaciju o primjeni bespilotnih letjelica
    - vrijeme potrebno za edukaciju o obradi prikupljenih podataka
    - vrijeme potrebno za provedbu snimanja bespilotnom letjelicom (tri puta tijekom vegetacijske sezone, sukladno tablici 7)
    - vrijeme potrebno za obradu podataka i kreiranje kvalitativnih zona u vinogradu (po provedbi snimanja, tri puta tijekom vegetacijske sezone)
    - vrijeme potrebno za provedbu selektivne berbe i/ili diferencijaciju grožđa prema kvalitativnim parametrima

Varijabilni trošak usluge specijalizirane tvrtke za snimanje bespilotnom letjelicom, koja ujedno nudi i obradu i analizu prikupljenih podataka s dostavom izvješća i preporuka proizvođaču, dobiven je istraživanjem tržišta uz dodatnu vlastitu procjenu troška usluge za obradu i analizu podataka te izradu izvješća i preporuka za proizvođača.

Prihodi u vinogradarskoj proizvodnji opterećeni su različitim troškovima od proizvodnje grožđa pa sve do stavljanja vina u promet, odnosno do njegove prodaje na tržištu različitim prodajnim kanalima. U obzir su uzeti samo prihodi koji nastaju temeljem razlike u prodajnoj cijeni grožđa i vina, a koji su izravan rezultat kvalitativnog zoniranja i selektivne berbe sukladno kvalitativnim zonama u vinogradu koje su određene na temelju najprediktivnijeg vegetacijskog indeksa.

Prihodi u ovom istraživanju odnose se na:

- Prihode koji bi nastali selektivnom berbom temeljem razlike u cijeni grožđa sukladno kvalitativnim zonama u vinogradu određenih na temelju najprediktivnijeg vegetacijskog indeksa
- Prihode koji bi nastali proizvodnjom različitih tipova vina na osnovu selektivne berbe sukladno kvalitativnim zonama u vinogradu određenih na temelju najprediktivnijeg vegetacijskog indeksa

3.4.3.2. Prikupljanje podataka o tržišnim cijenama grožđa i vina sorte 'Kraljevina' i sorte 'Pinot crni'

Za potrebe ovog istraživanja metodom ankete provedeno je prikupljanje podataka o tržišnim cijenama grožđa sorte 'Kraljevina' i sorte 'Pinot crni', upotrebom anketne tehnike usmenog anketiranja („Face to face“), pri čemu je anektiranje obavila autorica rada na uzorku od deset (10) profesionalnih vinogradara s područja Zagrebačke županije koji u svojoj proizvodnji imaju navedene sorte grožđa. Empirijski podaci koji se analiziraju u okviru ovoga rada prikupljeni su tijekom ožujka 2021. godine. Pripadnici relevantne istraživačke populacije vinogradara s područja Zagrebačke županije obuhvaćaju osobe koje posjeduju vlastite vinograde, bave se uzgojem različitih sorti grožđa za proizvodnju vina, proizvodnjom vina te vlastito vino stavljaju na tržište. Pet ispitanih vinogradara uzgaja sortu 'Kraljevina', a pet sortu 'Pinot crni'. Sudjelovanje u istraživanju bilo je dobrovoljno, pri čemu su ispitanici imali mogućnost u bilo kojem trenutku bez objašnjenja prekinuti sudjelovanje u istraživanju, dok su istraživački rezultati anonimni i povjerljivi, odnosno, prikupljeni podaci korišteni su isključivo za svrhu izrade ovoga rada te nisu davani na uvid drugim pojedincima ili ustanovama. Odgovori ispitanih analizirani su skupno, odnosno, na razini ukupnog uzorka, korištenjem anonimizirane baze podataka, pri čemu dobivene rezultate istraživanja nije moguće povezati s identitetom ispitanih.

Anketni upitnik sastojao se od deset (10) pitanja te je ukupno obuhvatio 23 varijable (Prilog 1). Upitnik se sastojao od seta pitanja namijenjenih mjerenju određenih karakteristika gospodarstva i vinogradarske proizvodnje (obuhvaćeno je pet varijabli: pravni status gospodarstva, lokacija gospodarstva/vinogradarske proizvodnje, ukupna površina vinograda (ha), diferencijacija grožđa prema kvaliteti) te seta pitanja o proizvodnji i tržišnim cijenama sorte 'Kraljevina' ili 'Pinot crni' (obuhvaćeno je pet varijabli: ukupna površina (ha) sorte 'Kraljevina'/'Pinot crni', ukupan prinos (kg) sorte 'Kraljevina'/'Pinot crni' u 2019. i 2020. godini, prosječna koncentracija šećera (°Oe) sorte 'Kraljevina'/'Pinot crni' u 2019. i 2020. godini, prosječna količina ukupnih kiselina (g/L) sorte 'Kraljevina'/'Pinot crni' u 2019. i 2020. godini te tržišne cijene sorte 'Kraljevina'/'Pinot crni' za razdoblje od 2011.-2020. godine). Prosječno trajanje ispunjavanja anketnog upitnika iznosilo je sedam minuta. S obzirom na opisani metodološki okvir istraživanja kao i način obrade podataka, radi se o kvantitativnom empirijskom anketnom istraživanju, provedenom u obliku jednokratnog korelacijskog istraživačkog nacrta, u kojem odabrane karakteristike vinogradarskih gospodarstava i vinogradarske proizvodnje predstavljaju nezavisne varijable, dok tržišna cijena grožđa predstavlja zavisnu varijablu. S obzirom na način provedbe istraživanja, odnosno, dizajn uzorkovanja te način odabira ispitanika, radi se o neprobabilističkom tipu uzorka, dok je po vrsti uzorka, riječ o prigodnom uzorku. Pri tome, s obzirom na to da nije osigurana probabilistička narav uzorkovanja te s obzirom na to da

je istraživanje provedeno na prigodnom uzorku, rezultati su korišteni samo kao osnova za izračun ekonomske opravdanosti kvalitativnog zoniranja, a tendencije uočene na realiziranom uzorku mogu poslužiti samo kao grubi indikator populacijskih parametara. Prikupljeni podaci obrađeni su i analizirani u statističkom programskom paketu SPSS 21 (Statistical Package for the Social Sciences, Armonk, NY: IBM Corp). Empirijski podaci analizirani su postupcima deskriptivne statistike, koristeći primjerene deskriptivne statističke pokazatelje (prosječne vrijednosti, medijalne vrijednosti, standardnu devijaciju) te su samo podaci relevantni za ovo istraživanje prikazani tabličnim i grafičkim prikazima.

Za usporedbu tržišnih cijena grožđa sorata 'Kraljevina' i 'Pinot crni' dobivenih anketnim ispitivanjem s prosječnim proizvođačkim cijenama vinskog grožđa u Republici Hrvatskoj, napravljeno je istraživanje desk-metodom kroz analizu dostupnih statističkih podataka iz europske baze podataka EUROSTAT o cijenama vinskog grožđa za razdoblje od 2011.-2020. godine na području Republike Hrvatske (EUROSTAT, 2021).

Za potrebe utvrđivanja cijena vina sorte 'Kraljevina' i sorte 'Pinot crni' provedeno je istraživanje tržišta, pri čemu su preuzete stvarne cijene mirnih i/ili pjenušavih vina za sva četiri proizvođača u ovom istraživanju. Nadalje, s obzirom na to da proizvođači vina sorte 'Pinot crni' iz ovog istraživanja (ŠEMBER i TOMAC) već imaju u proizvodnji dva tipa vina, prosječna tržišna cijena mirnog vina sorte 'Pinot crni' iz podregije Plešivica koje ima zaštićenu oznaku izvornosti Plešivica ili Zapadna kontinentalna Hrvatska, dobivena je istraživanjem tržišta. S obzirom na to da proizvođač KOS ima samo jedan tip vina sorte 'Kraljevina' u proizvodnji, prosječna tržišna cijena vina sorte 'Kraljevina' dobivena je istraživanjem tržišta cijena vina ostalih proizvođača vina sorte 'Kraljevina' iz vinogorja Zelina.

3.4.3.3. Metode za izračun ekonomske opravdanosti

Svaka nova investicija u proizvodnom procesu zahtijeva procjenu opravdanosti putem ekonomskih i financijskih metoda procjene investicijskih projekata. Većina investicijskih projekata zahtijeva ulaganja u fiksnu, primarno materijalnu imovinu (osnovna sredstva) te se koristi postupak budžetiranja kapitala za donošenje odluka o provedbi investicijskih projekata. Budžetiranje kapitala uključuje prognozu novčanih tokova projekta i ocjenu njihove financijske efikasnosti primjenom kriterija financijskog odlučivanja koji su ugrađeni u mnoge metode budžetiranja kapitala (Orsag, 2002). Procjena financijske efikasnosti realnih investicija, posebno investicija u zamjenu određene opreme kako bi se osigurala profitabilnost ili smanjili troškovi postojećeg poslovanja, nešto je složenija te se koriste temeljne, dodatne i posebne metode financijskog odlučivanja. Financijska efikasnost

projekta određena je veličinom i dinamikom novčanih tokova za koje se očekuje da će ih projekt ostvariti u budućnosti te njihovom vremenskom vrijednošću (Orsag, 2002).

Prema Orsag (2002) temeljne metode financijskog odlučivanja su metoda čiste sadašnje vrijednosti te metoda interne stope profitabilnosti, a koriste se u svim postupcima kvantifikacije financijskih odluka te su ključne i za primjenu ekonomskog koncepta vrijednosti. Dodatne metode uključuju metodu razdoblja povrata, metodu diskontiranog razdoblja povrata, metodu indeksa profitabilnosti, metodu sadašnje vrijednosti budućih troškova i metodu anuiteta. Dodatne metode razvijene su u svrhu poboljšanja kvalitete donesene odluke u slučaju izbora između više varijanti investicijskih ulaganja. Posebne metode uključuju metodu diferencijacije i metodu modificirane interne stope profitabilnosti, a razvijene su za potrebe odlučivanja u uvjetima rangiranja projekata. Pravila budžetiranja kapitala jesu određeni kriteriji kojima se prihvaćaju, odnosno odbacuju projekti, a ti kriteriji su rezultat primjene metoda financijskog odlučivanja. Metode financijskog odlučivanja korištene u ovom istraživanju navedene su u tablici 9.

Tablica 9. Metode financijskog odlučivanja (prerađeno prema Orsag (2002) i Vidučić i sur., 2015)

Klasifikacija metoda financijskog odlučivanja	**Naziv metode financijskog odlučivanja**	**Kratica**	**Matematički izraz**
Temeljne metode	Metoda čiste sadašnje vrijednosti	**NPV**	$\mathbf{S_0 = \sum_{t=1}^{T} \frac{V_t}{(1+k)^t} - I}$
	Metoda interne stope profitabilnosti	**IRR**	$\mathbf{\sum_{t=1}^{T} \frac{V_t}{(1+R)^t} - I}$ $\mathbf{O = -I_0 + \sum_{t=1}^{n} \frac{GT_t}{(1+r)^t}}$ $\mathbf{NPV = \sum_{t=1}^{n} \frac{GT_t}{(1+r)^t} - I_0 = 0}$
Dodatne	Metoda razdoblja povrata	$\mathbf{t_p}$	$\mathbf{I = \sum_{t=1}^{t_p} V_t}$

metode	Metoda diskontiranog razdoblja povrata		$\mathbf{I = \sum_{t=1}^{t_p} V_t \frac{1}{(1+k)^t}}$
Posebne metode	Metoda modificirane interne stope profitabilnosti	**mIRR**	$\boldsymbol{MIRR} = \left(\frac{-\mathbf{NPV\ (rstopa, vrijednost\ [pozitivna])} * (\mathbf{1+rstopa})^{\mathbf{n}}}{\mathbf{NPV\ (fstopa, vrijednost\ [negativna])} * (\mathbf{1+fstopa})}\right)^{\frac{1}{n-1}}$

Korištene metode odabrane su zbog mogućnosti ekonomske procjene koristi investicijskih projekata za kvalitativno zoniranje i selektivnu berbu.

Razdoblje povrata (engl. *payback period*) najjednostavniji je kriterij financijskog odlučivanja o realnim investicijama te predstavlja broj razdoblja (godina) u kojima će se vratiti uloženi novac i to pritjecanjem godišnjih čistih novčanih tokova kroz cijelo vrijeme efektuiranja projekta. U onoj godini u kojoj su čisti novčani tokovi od poslovanja projekta dostigli visinu uloženih investicijskih troškova, ostvaruje se i razdoblje povrata projekta. Nakon što je postignuto razdoblje povrata, poslovni novčani tokovi u ostatku efektuiranja projekta su zarađeni novac iznad veličine potrošenog novca prilikom investicijskog ulaganja (Orsag, 2002).

Čisti novčani tok jest razlika tekućih novčanih primitaka i tekućih novčanih izdataka koji nastaju tijekom efektuiranja projekta (Orsag, 2002). Novčani primci u tijeku provedbe projekta nastaju od prodaje proizvoda i/ili usluga, dok su novčani izdaci potrebni za osiguranje same provedbe projekta i neometano odvijanje procesa u tijeku provedbe projekta.

Matematički se kriterij razdoblja povrata može zapisati na sljedeći način (Orsag, 2002):

$$\mathbf{I = \sum_{t=1}^{t_p} V_t}$$

Pri čemu su:

I - investicijski troškovi

V_t - čisti novčani tokovi po godinama

t_p - razdoblje povrata

Prednost ove metode je jednostavnost izračuna i forsiranje likvidnosti projekta, odnosno forsiraju se projekti koji brže vraćaju uložen novac u visini investicijskih troškova. No, ova

metoda ne uzima u obzir učinke projekta nakon što se vrate investicijski troškovi odnosno zanemaruje ukupnu profitabilnost projekta u vijeku efektuiranja. Nadalje, razdoblje povrata ne uzima u obzir vremensku vrijednost novca, odnosno ne rangira različito projekte koji imaju različitu dinamiku pritjecanja novčanih tokova. Projekti u kojima najveći čisti novčani tokovi pritječu u prvim godinama efektuiranja projekta smatraju se da imaju bolji raspored novčanih tokova. Dakle, ova metoda ima dva nedostatka: ne uzima u obzir ukupnu profitabilnost projekta i ne uzima u obzir vremensku vrijednost novca te je razdoblje povrata potrebno koristiti kao dodatni kriterij pri financijskom odlučivanju (Orsag, 2002). S obzirom na to da se pri primjeni kvalitativnog zoniranja i selektivne berbe očekuju različiti novčani tokovi zbog različite količine ubranog grožđa i proizvedenog vina iz dviju kvalitativnih zona, ali i različite cijene grožđa i vina iz dviju kvalitativnih zona, razdoblje povrata računa se zbrajanjem kumuliranih novčanih tokova sve do one godine u kojoj se veličina kumuliranih novčanih tokova izjednači s veličinom investicijskih troškova.

Diskontirano razdoblje povrata (engl. *discounted payback*) varijanta je metode razdoblja povrata koja uklanja nedostatak ne uzimanja u obzir vremenske vrijednosti novca. Temeljna karakteristika diskontiranog razdoblja povrata je korištenje vremenske vrijednosti novca. Zbog umanjenih novčanih tokova, diskontirano razdoblje povrata duže je od originalnog razdoblja povrata, ali kriteriji za rangiranje projekata ostaju isti. Ovom se metodom izračunava vrijeme potrebno da diskontirani čisti novčani tokovi investicijskih projekata pokriju vrijednost investicijskih troškova. Diskontiranje originalnih novčanih tokova projekta provodi se uz diskontnu stopu koja odgovara trošku kapitala, odnosno originalni novčani tokovi umanjeni su za primjerene troškove kapitala koji odgovaraju interesima tvrtke investitora. Diskontirano razdoblje povrata računa se postupkom kumuliranja kao i kod originalnog razdoblja povrata, s razlikom što se kod ovog kriterija financijskog odlučivanja kumuliraju diskontirani umjesto originalni čisti novčani tokovi projekta. U onoj godini u kojoj diskontirani novčani tokovi projekta dostignu iznos njegovih investicijskih troškova određuje se i broj godina diskontiranog razdoblja povrata (Orsag, 2002).

Formula za izračun diskontiranog razdoblja povrata je (Orsag, 2002):

$$\mathbf{I} = \sum_{t=1}^{t_p} V_t \frac{1}{(1+k)^t}$$

Pri čemu su:

I - investicijski troškovi

V_t - čisti novčani tokovi po godinama

t_p - razdoblje povrata

k – diskontna stopa

Ova metoda, kao i razdoblje povrata, zahtijeva što brže vraćanje uloženih sredstava, ali kroz diskontirane novčane tokove koji su manji od originalnih te mogu utjecati na gornju granicu prihvatljivog broja godina vraćanja investicijskih troškova, odnosno broj godina vraćanja investicijskih troškova veći je nego kod originalnog razdoblja povrata. Nadalje, diskontirano razdoblje povrata može biti i dodatni kriterij za procjenu prihvatljivosti projekta, jer se može dogoditi da uz određenu diskontnu stopu projekt ne može pokriti investicijske troškove i trošak kapitala, odnosno da projekt nema diskontirano razdoblje povrata, što ga čini neprihvatljivom investicijom jer ne nadoknađuje troškove kapitala tvrtke. Također, može se koristiti i kao pokazatelj rizičnosti projekta, odnosno kao pokazatelj stupnja sigurnosti da će se pokriće investicijskih troškova dogoditi unutar životnog vijeka projekta. Što je razdoblje povrata investicijskih troškova kraće, to je i vremenski prostor za pritjecanje novčanih tokova nakon vraćanja investicijskih troškova veći. Niti ova metoda, kao ni razdoblje povrata, ne uzima u obzir ukupnu profitabilnost projekta nakon vraćanja investicijskih troškova zajedno s troškovima kapitala (Orsag, 2002). Pri izračunu diskontiranog razdoblja povrata investicije pri primjeni kvalitativnog zoniranja i selektivne berbe korištena je diskontna stopa od 10%.

Temeljni kriterij financijskog odlučivanja je metoda čiste sadašnje vrijednosti (engl. *Net Present Value- NPV*), a smatra se temeljnom metodom za procjenu efikasnosti projekata i temeljnom metodom investicijskog odlučivanja uopće. Izrazom čista ili neto vrijednost izražava se razlika između pozitivnih i negativnih učinaka nekog projekta ili aktivnosti. Kod novčanih tokova, pod čistom odnosno neto vrijednošću podrazumijeva se razlika između godišnjih novčanih tokova u cijelom vijeku efektuiranja projekta i investicijskih troškova (Orsag, 2002).

Izraz sadašnja upućuje na to da se je sve efekte potrebno svesti na sadašnju vrijednost kako bi bili vremenski međusobno usporedivi. Diskontiranje se vrši pomoću diskontne stope koja je jednaka trošku kapitala kao i kod diskontiranog razdoblja povrata. Na taj se način čista sadašnja vrijednost može definirati kao razlika između zbroja diskontiranih čistih novčanih tokova u cjelokupnom vijeku efektuiranja projekta i iznosa investicijskih troškova, odnosno matematički (Orsag, 2002):

$$\mathbf{S_0 = \sum_{t=1}^{T} \frac{V_t}{(1+k)^t} - I}$$

Pri čemu su:

S_0 - čista sadašnja vrijednost

I - investicijski troškovi

V_t - čisti novčani tokovi po godinama
T – vijek efektuiranja projekta
k – diskontna stopa

Temeljna karakteristika čiste sadašnje vrijednosti jest korištenje troška kapitala radi izračunavanja sadašnje vrijednosti budućih novčanih tokova projekta. Nulta čista sadašnja vrijednost označava da je projekt sposoban vratiti uloženi kapital i na njega osigurati prihvatljivu profitabilnost i s takvim projektom tvrtka postaje jača, no neće osigurati povećanje bogatstva dioničara jer samo projekti s pozitivnom čistom sadašnjom vrijednosti (većom od nule) imaju višu profitabilnost od one koja se zahtijeva na tržištu te donose ekstra profitabilnost dioničarima tvrtke. To znači da je pozitivna čista sadašnja vrijednost novčani iznos povećanja bogatstva dioničara tvrtke (Orsag, 2002), odnosno osigurava rast trajnog kapitala tvrtke (Vidučić i sur., 2015). U skladu s tim kriterijem ne bi se smjeli prihvatiti projekti koji imaju negativnu čistu sadašnju vrijednost jer bi oni smanjivali vrijednost tvrtke (Orsag, 2002).
Za usvajanje projekta čija je čista sadašnja vrijednost veća od nule, novčani tokovi moraju se diskontirati na sadašnju vrijednost odgovarajućom diskontnom stopom kao što su potrebna stopa povrata ili oportunitetni trošak kapitala (Vidučić i sur., 2015). No, veličina čiste sadašnje vrijednosti izrazito je osjetljiva na visinu diskontne stope, odnosno više diskontne stope smanjuju veličinu čiste sadašnje vrijednosti projekta, dok je primjena niže diskontne stope povećava (Orsag, 2002). Prema kriteriju čiste sadašnje vrijednosti, vrijednost investicijskih projekata je to bolja što projekt ima veću čistu sadašnju vrijednost. Isto tako, projekti s povoljnijom dinamikom pritjecanja čistih novčanih tokova (većih u prvim godinama efektuiranja projekta) imaju veću čistu sadašnju vrijednost projekta i veću financijsku efikasnost kroz jednako vrijeme efektuiranja jer su im najveći novčani tokovi najbliži sadašnjosti (Orsag, 2002).
U slučaju kada je diskontirano razdoblje povrata jednako životnom vijeku projekta, projekt ima nultu čistu sadašnju vrijednost. Svako dulje vraćanje investicijskih troškova i pripadajućeg troška kapitala rezultiralo bi negativnom čistom sadašnjom vrijednosti pa se zbog toga projekt treba odbaciti.

Interna stopa profitabilnosti (rentabilnosti) (engl. *Internal Rate of Return- IRR*) je drugi temeljni kriterij financijskog odlučivanja. To je ona diskontna stopa koja svodi čiste novčane tokove projekta u cijelom vijeku efektuiranja projekta na vrijednost investicijskih troškova projekta. To je stopa profitabilnosti ulaganja u projekt koja uvažava vremensku vrijednost novčanih tokova u cijelom vijeku efektuiranja projekta. Uz tu stopu ostvaruje se nulta, granična čista sadašnja vrijednost projekta odnosno to je ona diskontna stopa kod

koje je čista sadašnja vrijednost jednaka nuli (n=0). Matematički se interna stopa profitabilnosti može zapisati kroz jednakost diskontiranih novčanih tokova u cijelom vijeku efektuiranja projekta i vrijednosti njegovih investicijskih troškova, odnosno buduće čiste novčane tokove u cjelokupnom vijeku efektuiranja projekta izjednačava s investicijskim troškovima (s iznosom koji je potrebno uložiti u projekt) (Orsag, 2002):

$$\sum_{t=1}^{T} \frac{V_t}{(1+R)^t} - I$$

Pri čemu su:

I - investicijski troškovi

V_t - čisti novčani tokovi po godinama

T - vijek efektuiranja projekta

R – interna stopa profitabilnosti

Interna stopa profitabilnosti računa se metodom pokušaja i pogrešaka, no korištenjem računala je to danas vrlo jednostavno i primjenjuje se različita diskontna stopa sve dok se ne dobije NPV= 0.

Matematički se to može prikazati i ovako (Vidučić i sur., 2015)

$$NPV = \sum_{t=1}^{n} \frac{GT_t}{(1+r)^t} - I_0 = 0$$

Pri čemu su:

NPV- čista sadašnja vrijednost

I_0 – inicijalno ulaganje, gotovinski tijek u t= 0

GT_t – očekivani neto gotovinski tijek u razdoblju t

n - zadnje razdoblje u kojem se očekuju tijekovi novca

r – interna stopa rentabilnosti

Interna stopa profitabilnosti daje informaciju o marži sigurnosti projekta odnosno daje ideju o osjetljivosti projekta na podbačaj očekivanih gotovinskih tijekova i izloženost gubitka inicijalnog uloga (Vidučić i sur., 2015).

Interna stopa profitabilnosti usporediva je s troškovima kapitala tvrtke, odnosno ne bi se smjeli prihvatiti projekti čija je izračunata interna stopa profitabilnosti niža od troškova kapitala tvrtke. Interna stopa profitabilnosti pokazuje očekivanu profitabilnost jediničnog ulaganja u određeni projekt, a može se interpretirati i kao prosječna godišnja stopa prinosa investicije. Projekti koji obećavaju pozitivnu čistu sadašnju vrijednost projekta imat će internu stopu profitabilnosti višu od troškova kapitala (Orsag, 2002).

Modificirana interna stopa profitabilnosti (mIRR) je varijanta interne stope profitabilnosti u kojoj je ugrađena implicitna pretpostavka čiste sadašnje vrijednosti da se reinvestiranje primljenih novčanih tokova vrši uz troškove kapitala tvrtke te da se početni izdaci financiraju po trošku financiranja (Orsag, 2002). mIRR predstavlja stopu povrata koja izjednačava čistu sadašnju vrijednost konačnih novčanih prihoda s početnim novčanim rashodom u nultoj godini, odnosno investicijom. U ovoj tehnici, privremeni novčani tokovi, tj. svi novčani tokovi, osim početnog, dovode se do terminalne vrijednosti uz pomoć odgovarajuće stope povrata (obično trošak kapitala). To je specifičan tok novčanog priljeva u prošloj godini.

U mIRR-u, prijedlog ulaganja se prihvaća, ako je mIRR veći od tražene stope povrata, tj. granične stope, a odbijena ako je stopa niža od granične vrijednosti. Pri izračunu mIRR za primjenu kvalitativnog zoniranja i selektivne berbe korištena je stopa reinvestiranja od 12%.

Izračun mIRR matematički se može prikazati i ovako (Excel, 2010):

$$\boldsymbol{MIRR} = \left(\frac{-\mathbf{NPV}\ (\mathbf{rstopa}, \mathbf{vrijednost}\ [\mathbf{pozitivna}]) * (\mathbf{1}+\mathbf{rstopa})^{\mathbf{n}}}{\mathbf{NPV}\ (\mathbf{fstopa}, \mathbf{vrijednost}\ [\mathbf{negativna}]) * (\mathbf{1}+\mathbf{fstopa})}\right)^{\frac{1}{n-1}} -1$$

Pri čemu su:

n- broj zadanih vrijednosti novčanih tokova

fstopa- stopa financiranja

rstopa- stopa reinvestiranja

3.4.4. Statistička obrada podataka

Prikupljeni podaci obrađeni su i analizirani u statističkom programskom paketu SPSS 21 (Statistical Package for the Social Sciences, Armonk, NY: IBM Corp).

Prikupljeni su kvantitativni podaci o tri kvalitativna svojstva grožđa (koncentracija šećera (°Oe), količina ukupnih kiselina (g/L), pH vrijednost) i sedam sastavnica prinosa (sadržaj ukupnog dušika u listu (% na bazi suhe tvari), broj mladica, broj nodija, prinos po trsu (kg), broj grozdova, prosječna masa grozda (kg), masa orezane rozgve (kg)), odnosno, empirijski podaci sastoje se od 10 kvantitativnih varijabli koje su prikupljene zasebno za svaku lokaciju istraživanja i zasebno za svaku godinu, osim na lokaciji PUHELEK- PUREK gdje je prikupljanje podataka snimanjem multispektralnom kamerom i ručnim uzorkovanjem provedeno samo u 2020. godini u dva termina (kolovoz i rujan 2020.) zbog tehničkih problema. Na svim lokacijama pri prikupljanju podatka ručnim uzorkovanjem povremeno su se javila ograničenja u dostupnosti uzoraka te određeni parametri nisu mogli biti izmjereni u svim terminima na svim ciljanim trsovima te su pri statističkim analizama korišteni isključivo cjelokupni setovi podataka, odnosno trsovi na kojima su iz bilo kojeg razloga nedostajali podaci, nisu korišteni u statističkoj analizi.

Empirijski podaci analizirani su metodama i postupcima deskriptivne, inferencijalne (induktivne) te multivarijatne statistike.

Multivarijatne tehnike primijenjene su prilikom određivanja najprediktivnijeg indeksa, pri čemu je korištena klaster analiza. Prikupljeni podaci o izmjerenim kvalitativnim svojstvima grožđa (koncentracija šećera (°Oe), količina ukupnih kiselina (g/L), pH vrijednost) na svakoj lokaciji unutar svake godine podvrgnuti su postupku klasterizacije, koristeći *K means cluster* proceduru uz a priori zadani broj klastera koji iznosi dva. Na taj način dobivena su dva kvalitativna klastera, odnosno ciljani trsovi su podijeljeni u dvije grupe prema kvalitativnim parametrima (ciljani trsovi boljih i lošijih kvalitativnih parametara). Nakon toga je ta dobivena kvalitativna klasterska struktura uspoređena sa strukturom trsova dobivenom na osnovu zoniranja uz pomoć vegetacijskih indeksa NDVI, NDRE i OSAVI, na zone manje bujnosti (potencijalno bolja kvalitativna svojstva grožđa) i zone veće bujnosti (potencijalno lošija kvalitativna svojstva grožđa) za svaki vegetacijski indeks i svaki termin snimanja. Onaj indeks čija se klasifikacijska struktura dobivena zoniranjem u najvećoj mjeri poklapala s kvalitativnom klasterskom strukturom proglašen je najprediktivnijim.

U okviru deskriptivne statistike, kvantitativne varijable se analiziralo univarijatnim tehnikama, koristeći primjerene deskriptivne statističke pokazatelje (prosječne vrijednosti, standardne devijacije i koeficijent varijacija).

U okviru inferencijalne statističke analize podataka, varijable se analiziralo bivarijatnim tehnikama, pri čemu su za testiranje statističke značajnosti razlika i povezanosti korišteni neparametrijski i parametrijski testovi, ovisno o istraživačkom nacrtu te odstupanju analiziranih varijabli od normalne raspodjele.

U slučaju testiranja statističke značajnosti razlike (prosječnih) rezultata kvalitativnih svojstva grožđa i sastavnica prinosa dviju zona različite bujnosti koje su dobivene na temelju najprediktivnijeg vegetacijskog indeksa (dizajn između skupina, u kojem je glavni fokus stavljen na razlike među zonama u mjerenim pokazateljima) u slučaju varijabli koje ne odstupaju statistički značajno od normalne raspodjele korišten je t-test za dva nezavisna uzorka za testiranje razlike u prosjecima, a u slučaju varijabli koje odstupaju statistički značajno od normalne raspodjele korišten je Mann Whitney U test za dva nezavisna uzorka za testiranje razlike u rangovima. Pri tome, u svrhu testiranja statističke značajnosti odstupanja analiziranih varijabli od normalne raspodjele korišten je Shapiro - Wilk test.

U slučaju testiranja povezanosti između najprediktivnijeg vegetacijskog indeksa (dihotomna- binarna varijabla) i mjerenih kvalitativnih svojstva grožđa i sastavnica prinosa (kvantitativne varijable) korišten je point-biserijalni koeficijent korelacije (r_{pb}). Point-biserijalni koeficijent korelacije jednak je Pearsonovom (r) koeficijentu korelacije, a računa se između neke kontinuirane varijable i neke dihotomne (binarne) varijable. Prije računanja ovog koeficijenta korelacije dihotomnoj (binarnoj) varijabli dodijeljena je vrijednosti za svaku kategoriju te su trsovi iz veće zone bujnosti označni kodom 0, a trsovi iz zone manje bujnosti kodom 1.

Pri tome, svi su statistički testovi provedeni uz pet postotnu razinu rizika, odnosno, vjerojatnost pojavljivanja testovnog statistika manja od 0,05, smatrana je statistički značajnom.

4. REZULTATI ISTRAŽIVANJA

Na tri lokacije istraživanja (KOS, TOMAC, ŠEMBER) provedena su daljinska snimanja multispektralnom kamerom tijekom dvije vegetacijske sezone (2019. i 2020. godina) u tri različite fenofaze razvoja vinove loze: početak nakupljanja šećera, srednje vrijednosti šećera i tehnološka zrelost grožđa što odgovara fenofazama 34, 36 i 38 prema modificiranoj E-L skali za praćenje fenofaza vinove loze (Coombe, 1995), dok su na lokaciji PUHELEK- PUREK snimanja uspješno izvršena samo u 2020. godini u dvije različite fenofaze razvoja vinove loze: 36- srednje vrijednosti šećera i 38- tehnološka zrelost grožđa. Nakon obrade snimaka u ArcGIS programskom paketu (ESRI, 2012) izrađene su interpolirane karte bujnosti svakog vinograda u dvije zone (klase) na temelju medijalne vrijednosti sva tri istraživana vegetacijska indeksa (NDVI, NDRE i OSAVI) u sva tri termina snimanja, osim za lokaciju PUHELEK- PUREK -izrađene su interpolirane karte bujnosti u dva termina. Na svim generiranim kartama bujnosti zelena boja predstavlja zonu manje bujnosti gdje se vrijednosti vegetacijskih indeksa nalaze ispod medijalne vrijednosti vegetacijskog indeksa izračunatog za cijeli vinograd u određenom terminu snimanja, dok crvena boja predstavlja zonu veće bujnosti gdje se vrijednosti vegetacijskih indeksa nalaze iznad medijalne vrijednosti vegetacijskog indeksa izračunatog za cijeli vinograd u određenom terminu snimanja. Na svakoj generiranoj karti bujnosti, ciljani trsovi, na kojima su prikupljani podaci ručnim uzorkovanjem u vinogradu, označeni su žutom oznakom.

Na tri lokacije istraživanja (KOS, TOMAC, ŠEMBER) u obje vegetacijske godine (2019. i 2020.) i na lokaciji PUHELEK- PUREK u 2020. godini, na ciljanim trsovima prikupljeni su podaci ručnim uzorkovanjem o sastavnicama prinosa (sadržaj ukupnog dušika u listu (% na bazi suhe tvari), broj mladica, broj nodija, prinos po trsu (kg), broj grozdova, prosječna masa grozda (kg), masa orezane rozgve (kg)) i kvalitativnim svojstvima grožđa/mošta (koncentracija šećera (°Oe), količina ukupnih kiselina (g/L) i pH vrijednost).

Prikupljeni podaci korišteni su za utvrđivanje povezanosti vegetacijskih indeksa (NDVI, NDRE, OSAVI) i bujnosti kod dviju istraživanih sorata u različitim fenofazama razvoja vinove loze te za utvrđivanje povezanosti zona različite bujnosti sa sastavnicama prinosa i kvalitativnim svojstvima grožđa odnosno za procjenu mogućnosti kvalitativnog zoniranja vinograda na generiranim kartama bujnosti.

Pri utvrđivanju povezanosti vegetacijskih indeksa (NDVI, NDRE, OSAVI) i bujnosti utvrđeno je da podaci prikupljeni ručnim uzorkovanjem koji mogu biti prediktori bujnosti u vinogradu (broj mladica, broj nodija, masa orezane rozgve (kg)) nisu dostatni za utvrđivanje povezanosti vegetacijskih indeksa i bujnosti. Naime, vegetacijske indekse

potrebno je promatrati kao pokazatelje fotosintetski aktivne vegetacije prisutne u određenoj fenofazi razvoja vinove loze koji mogu detektirati varijabilnost mnogih svojstava vinove loze unutar vinograda, a da bi se procijenila bujnost potrebno je mjerenje više sastavnica vinove loze koje utječu na vegetativni rast i razvoj. Stoga je i klasterizacija ciljanih trsova na osnovu mjerenih vegetativnih parametara rezultirala nezadovoljavajućim klasterima jer broj mladica i broj nodija korelira s opterećenjem trsa u rezidbi što je prilično uniformno u svakom vinogradu u kojem je provedeno istraživanje, dok je masa orezane rozgve parametar koji se mjeri u rezidbi i nije ga moguće direktno povezati sa spektralnim mjerenjima fotosintetski aktivne vegetacije. Nadalje, kako bi se utvrdila povezanost vegetacijskih indeksa i bujnosti, a posebice kako bi se utvrdila razlika u povezanosti vegetacijskih indeksa i bujnosti u različitim fenofazama razvoja, utvrđeno je kako je potrebno vršiti ručna mjerenja više sastavnica vinove loze koje utječu na vegetativni rast i razvoj i to u istim terminima kada se vrše spektralna mjerenja kako bi se navedeni izmjereni parametri mogli statistički i opisno povezati. U ovom istraživanju prediktori bujnosti (broj mladica, broj nodija, masa orezane rozgve (kg)) mjereni su u jednom terminu koji se ne poklapa s terminima snimanja te tako dobiveni rezultati ne mogu biti relevantni za utvrđivanje povezanosti. Zbog intenzivnog daljnjeg vegetativnog razvoja vinove loze u toku vegetacije, koji ovisi i o mnoštvu drugih čimbenika (temperatura, vlaga, dostupnost hranjiva, zdravstveno stanje i sl.) utvrđene su razlike u bujnosti koje su detektirane spektralnim mjerenjima, a ručno mjereni parametri (broj mladica, broj nodija, masa orezane rozgve (kg)) ih ne opisuju na odgovarajući način. Iz prikazanih rezultata vidljivo je kako su generirane različite karte bujnosti u svim terminima snimanja jer su vegetacijski indeksi promjenjivi s obzirom na količinu fotosintetski aktivne vegetacije prisutne u određenoj fenofazi razvoja vinove loze, a usko su povezani s razinom reflektirajućeg zračenja u blisko infracrvenom (NIR), crvenom spektru (R) i rubnom crvenom dijelu spektra (RE). Isto tako, utvrđeno je su kako vegetacijski indeksi relevantni pokazatelji vegetativnog stanja vinove loze i dobri prediktori bujnosti u određenoj fenofazi razvoja te kako je moguće uspješno generirati različite karte bujnosti u svim fenofazama razvoja koje su pogodne za kvalitativno zoniranje vinograda kod obje istraživane sorte vinove loze.

Generiranim kartama bujnosti definirane su zona veće i manje bujnosti, a podaci prikupljeni ručnim uzorkovanjem korišteni su za utvrđivanje povezanosti zona različite bujnosti sa sastavnicama prinosa i kvalitativnim svojstvima grožđa, odnosno za utvrđivanje najprediktivnijeg vegetacijskog indeksa za određivanje kvalitativnih zona u vinogradu.

4.1. 'Kraljevina' (*Vitis vinifera* L.) - lokacija KOS

4.1.1. Rezultati istraživanja u 2019. godini

4.1.1.1. Generirane karte bujnosti na lokaciji KOS u 2019. godini

Na slici 14 prikazane su zone manje (zelena) i veće bujnosti (crvena) vinograda sorte 'Kraljevina' prema NDVI indeksu na lokaciji Kos u tri termina snimanja u 2019. godini. Vrijednosti NDVI indeksa u prvom terminu snimanja (fenofaza 34) kreću se od 0,581-0,919 pri čemu medijan iznosi 0,882. U drugom terminu snimanja (fenofaza 36) vrijednosti NDVI indeksa kreću se od 0,423-0,907 pri čemu medijan iznosi 0,852. U trećem terminu snimanja (fenofaza 38) vrijednosti NDVI indeksa kreću se od 0,401-0,838 pri čemu medijan iznosi 0,755.

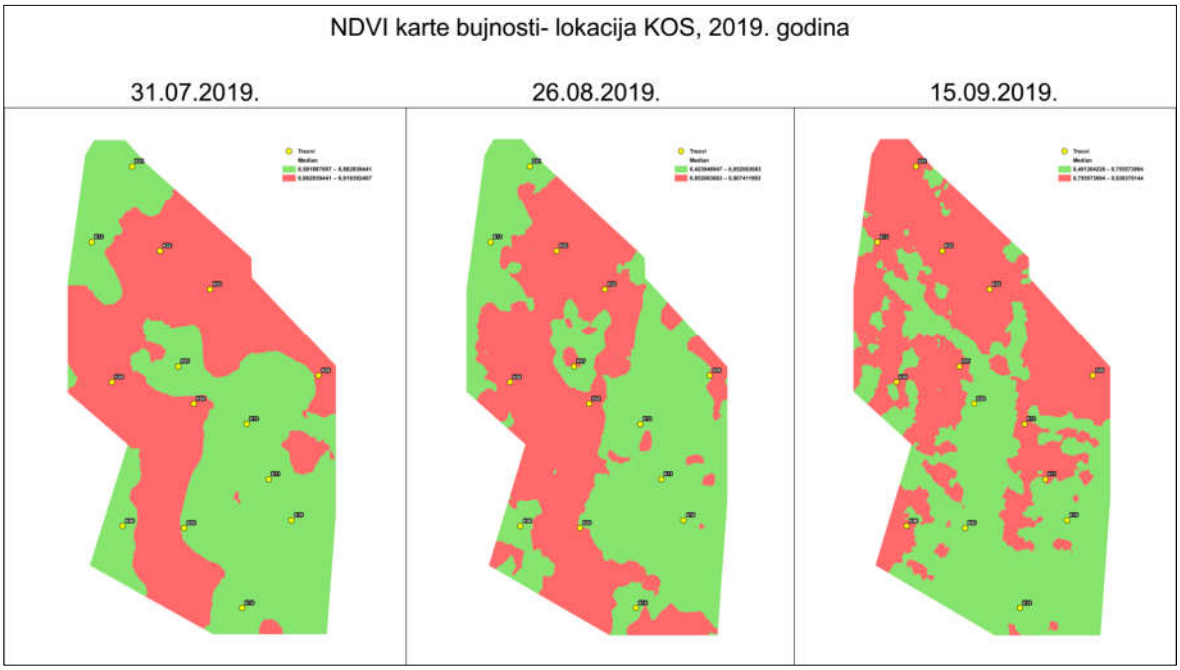

Slika 14. NDVI generirane karte bujnosti- lokacija KOS u 2019. godini

Na slici 15 prikazane su zone manje (zelena) i veće bujnosti (crvena) vinograda sorte 'Kraljevina' prema NDRE indeksu na lokaciji Kos u tri termina snimanja u 2019. godini. Vrijednosti NDRE indeksa u prvom terminu snimanja (fenofaza 34) kreću se od 0,255-0,594 pri čemu medijan iznosi 0,476. U drugom terminu snimanja (fenofaza 36) vrijednosti NDRE indeksa kreću se od 0,211-0,549 pri čemu medijan iznosi 0,412. U trećem terminu snimanja (fenofaza 38) vrijednosti NDRE indeksa kreću se od 0,170-0,512 pri čemu medijan iznosi 0,342.

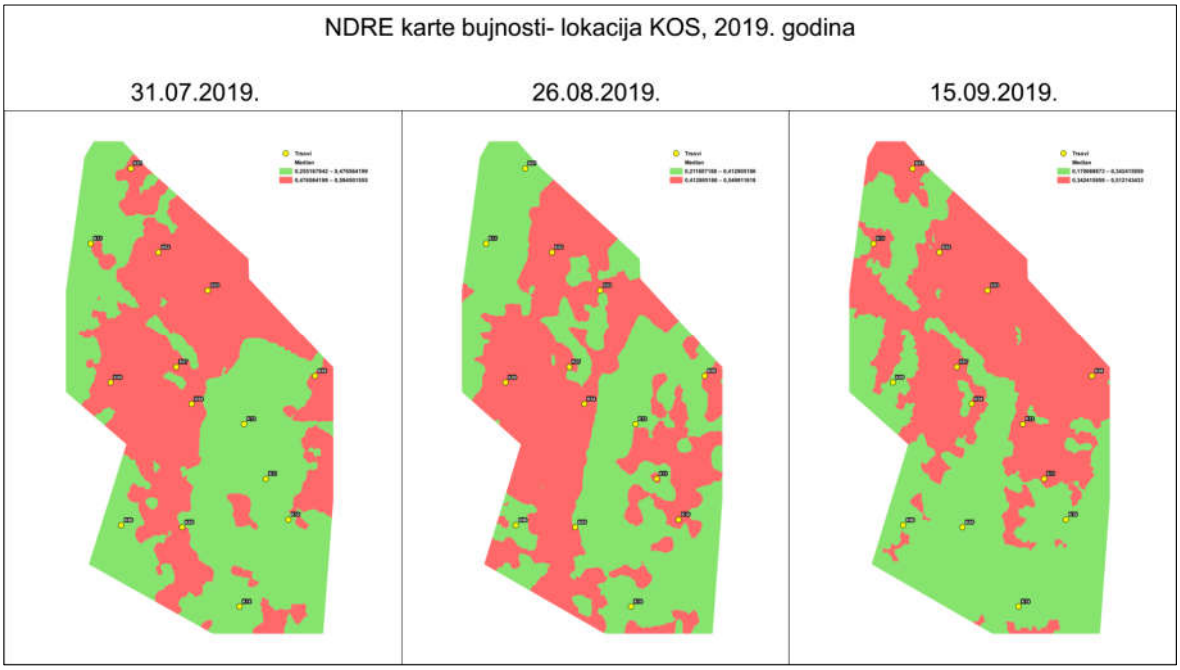

Slika 15. NDRE generirane karte bujnosti- lokacija KOS u 2019. godini

Na slici 16 prikazane su zone manje (zelena) i veće bujnosti (crvena) vinograda sorte 'Kraljevina' prema OSAVI indeksu na lokaciji Kos u tri termina snimanja u 2019. godini. Vrijednosti OSAVI indeksa u prvom terminu snimanja (fenofaza 34) kreću se od 0,426-0,716 pri čemu medijan iznosi 0,664. U drugom terminu snimanja (fenofaza 36) vrijednosti OSAVI indeksa kreću se od 0,312-0,708 pri čemu medijan iznosi 0,647. U trećem terminu snimanja (fenofaza 38) vrijednosti OSAVI indeksa kreću se od 0,250-0,614 pri čemu medijan iznosi 0,498.

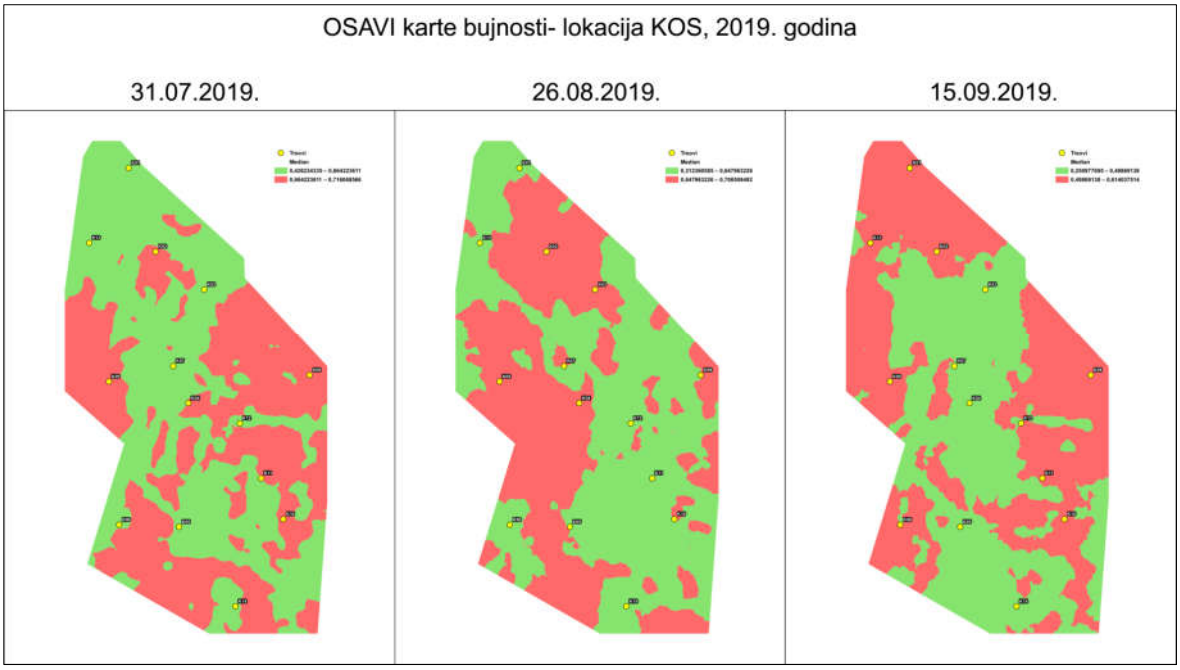

Slika 16. OSAVI generirane karte bujnosti- lokacija KOS u 2019. godini

4.1.1.2. Kvalitativno zoniranje na lokaciji KOS u 2019. godini

Prikupljeni podaci o kvalitativnim svojstvima grožđa sorte 'Kraljevina' (koncentracija šećera (°Oe), količina ukupnih kiselina (g/L) i pH vrijednost) na ciljanim trsovima (n=12) u 2019. godini podvrgnuti su postupku klasterizacije, koristeći *K means cluster* proceduru uz apriori zadani broj klastera koji iznosi dva. Na taj način dobivena su dva klastera koja se međusobno statistički značajno razlikuju prema koncentraciji šećera, pri čemu su u prvom klasteru oni ciljani trsovi koji imaju veću koncentraciju šećera, dok su u drugom klasteru oni ciljani trsovi koji imaju manju koncentraciju šećera (tablica 10).

Tablica 10. Rezultat klasterizacije kvalitativnih svojstava grožđa sorte 'Kraljevina' na ciljanim trsovima (n=12) u 2019. godini na lokaciji KOS

Kvalitativna svojstva grožđa	***F*** $_{(1,10)}$	***Sig.***	**Prvi klaster (n=3)**	**Drugi klaster (n=9)**
			M ± SD	*M ± SD*
Koncentracija šećera (°Oe)	**15,178**	**0,003**	**80,67 ± 9,07**	**63,00 ± 6,10**
Ukupna kiselost (g/L)	1,457	0,255	8,73 ± 1,42	9,38 ± 0,55
pH vrijednost	4,909	0,051	3,16 ± 0,11	3,03 ± 0,08

Prema podacima iz tablice 10, trsovi iz prvog klastera (n=3) okarakterizirani su kao trsovi čije grožđe ima bolja kvalitativna svojstva, dok su oni iz drugog klastera (n=9) okarakterizirani kao trsovi čije grožđe ima lošija kvalitativna svojstva.

Kako bi se odredio najprediktivniji vegetacijski indeks s obzirom na kvalitativna svojstva grožđa, napravljena su preklapanja klasifikacijskih struktura: kvalitativne strukture trsova dobivene postupkom klasterizacije kvalitativnih svojstava grožđa s kvalitativnom strukturom trsova dobivenom na osnovu zoniranja uz pomoć vegetacijskih indeksa NDVI, NDRE i OSAVI na zone manje bujnosti (potencijalno bolja kvalitativna svojstva grožđa) i zone veće bujnosti (potencijalno lošija kvalitativna svojstva grožđa). Prema podacima iz tablice 11, može se zaključiti kako je **najprediktivniji vegetacijski indeks za kvalitativno zoniranje vinograda sorte 'Kraljevina' na lokaciji KOS u 2019. godini NDRE vegetacijski indeks sa 75%-tnim preklapanjem kvalitativnih klasifikacijskih struktura u terminu snimanja u rujnu (15.9.)**, dok je najmanje prediktivan NDVI indeks u terminu snimanja u kolovozu (26.8.).

Tablica 11. Preklapanja kvalitativnih klasifikacijskih struktura dobivenih klasterizacijom i zoniranjem pomoću vegetacijskih indeksa na ciljanim trsovima (n=12) sorte 'Kraljevina' u 2019. godini na lokaciji KOS

Vegetacijski indeks	**NDRE**			**NDVI**			**OSAVI**		
Termin snimanja	Srpanj (31.7.)	Kolovoz (26.8.)	**Rujan (15.9.)**	Srpanj (31.7.)	Kolovoz (26.8.)	Rujan (15.9.)	Srpanj (31.7.)	Kolovoz (26.8.)	Rujan (15.9.)
Broj podjednako klasificiranih trsova	7	8	**9**	8	5	8	8	8	8
Udio podjednako klasificiranih trsova	58%	67%	**75%**	67%	42%	67%	67%	67%	67%

Na temelju najprediktivnijeg vegetacijskog indeksa- NDRE u terminu snimanja u rujnu (15.9.), ciljani trsovi (n=12) klasificirani su u dvije zone bujnosti – zonu veće i zonu manje bujnosti (slika 17) te su u tablici 12 prikazani odabrani deskriptivni statistički pokazatelji kvalitativnih svojstava grožđa i sastavnica prinosa na dvanaest ciljanih trsova sorte 'Kraljevina' u 2019. godini.

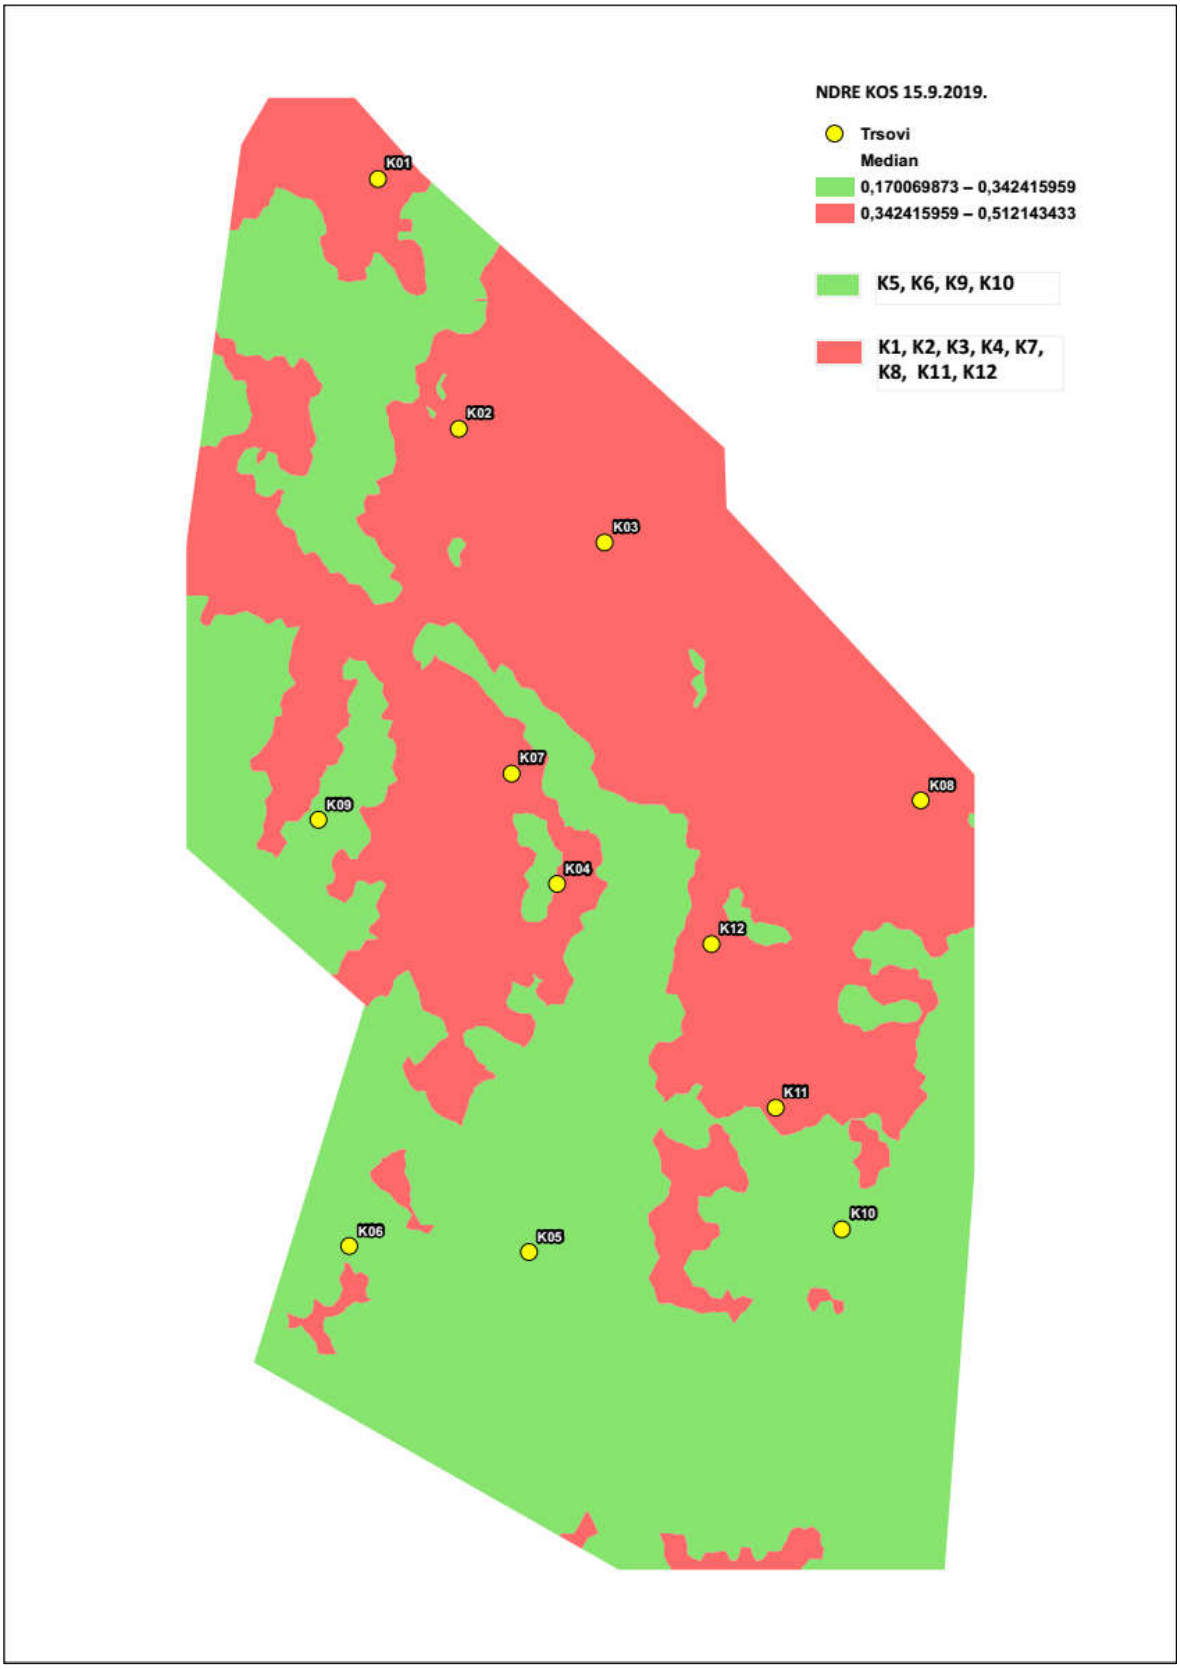

Slika 17. Generirana karta dviju zona bujnosti sorte 'Kraljevina' u 2019. godini na temelju najprediktivnijeg vegetacijskog indeksa NDRE u terminu snimanja u rujnu (15.9.) na lokaciji KOS s prikazom klasifikacije ciljanih trsova po zonama

Tablica 12. Odabrani deskriptivni statistički pokazatelji na ciljanim trsovima (n=12) sorte 'Kraljevina' u 2019. godini na lokaciji KOS klasificirani u dvije zone bujnosti na temelju NDRE indeksa iz rujna

Analizirane varijable	Trsovi iz zone veće bujnosti (n=8)	Trsovi iz zone manje bujnosti (n=4)
	M ± SD (*CV*)	*M ± SD* (*CV*)
Koncentracija šećera (°Oe)	65,88 ± 11,95 (18,13)	70,50 ± 6,03 (8,55)
Količina ukupnih kiselina (g/L)	9,21 ± 0,98 (10,64)	9,23 ± 0,46 (5,04)
pH vrijednost	3,07 ± 0,12 (3,95)	3,06 ± 0,06 (2,08)
Sadržaj ukupnog dušika u listu (% na bazi suhe tvari)	2,40 ± 0,13 (5,60)	2,59 ± 0,22 (8,38)
Broj grozdova	13,38 ± 4,87 (36,38)	15,00 ± 6,78 (45,21)
Prinos po trsu (kg)	3,38 ± 1,11 (32,84)	2,54 ± 0,48 (18,81)
Prosječna masa grozda (kg)	0,27 ± 0,09 (33,12)	0,20 ± 0,09 (45,60)
Masa orezane rozgve (kg)	0,42 ± 0,13 (31,28)	0,46 ± 0,24 (53,46)
Broj mladica	11,88 ± 2,48 (20,83)	14,25 ± 2,22 (15,56)
Broj nodija	13,75 ± 2,19 (15,91)	14,25 ± 0,96 (6,72)

Bilješka: M = prosječna vrijednost; SD = standardna devijacija, CV = koeficijent varijacija

Na temelju najprediktivnijeg vegetacijskog indeksa NDRE u terminu snimanja u rujnu (15.9.), testirana je statistička značajnost razlika u izmjerenim kvalitativnim svojstvima grožđa i sastavnicama prinosa između dviju zona- zone manje i zone veće bujnosti u prosječnim rezultatima na analiziranim varijablama. Analizirane varijable odnose se na: koncentraciju šećera (°Oe), količinu ukupnih kiselina (g/L), pH vrijednost, sadržaj ukupnog dušika u listu (% na bazi suhe tvari), broj mladica, broj nodija, prinos po trsu (kg), broj grozdova, prosječnu masa grozda (kg), masu orezane rozgve (kg) te je utvrđeno kako se dvije zone bujnosti **ne razlikuju statistički značajno u analiziranim varijablama**. Rezultati testiranja prikazani su u tablici 13.

Tablica 13. Rezultat testiranja statističke značajnosti razlika između zone veće i manje bujnosti dobivenih na temelju NDRE indeksa iz rujna u prosječnim rezultatima na analiziranim varijablama sorte 'Kraljevina' u 2019. godini na lokaciji KOS

Analizirane varijable	**Trsovi iz zone veće bujnosti (n=8)**	**Trsovi iz zone manje bujnosti (n=4)**	**Testiranje statističke značajnosti razlike u prosječnim rezultatima / rangovima**		
	Shapiro-Wilk	*Shapiro-Wilk*	*F*	$t_{(10)}$	*Mann-Whitney U*
Koncentracija šećera (°Oe)	0,889	0,936	0,431	-0,718	
Količina ukupnih kiselina (g/L)	0,813*	0,962			14,000
pH vrijednost	0,947	0,899	1,719	0,133	
Sadržaj ukupnog dušika u listu (% na bazi suhe tvari)	0,917	0,969	1,619	-1,909	
Broj grozdova	0,938	0,795	0,581	-0,481	
Prinos po trsu (kg)	0,962	0,805	1,098	1,422	
Prosječna masa grozda (kg)	0,966	0,998	0,000	1,304	
Masa orezane rozgve (kg)	0,969	0,934	3,167	-0,353	
Broj mladica	0,879	0,963	0,013	-1,616	
Broj nodija	0,942	0,863	2,807	-0,429	

*Bilješka: Shapiro-Wilk = iznos Shapiro-Wilk testovnog statistika, F = iznos Leveneovog testovnog statistika za testiranje homogenosti varijanci; $t_{(df)}$ = iznos t omjera s pripadnim stupnjevima slobode za testiranje statističke značajnosti razlike prosječnih rezultata; Mann-Whitney U = iznos Mann-Whitney U statistika za testiranje statističke značajnosti razlike rangova; *** p<0.001; ** p<0.01; * p<0.05*

Dodatno je za najprediktivniji vegetacijski indeks- NDRE u terminu snimanja u rujnu (15.9.), izračunat i point biserijalni koeficijent korelacije (r_{pb}) sa svim analiziranim varijablama koje ne odstupaju statistički značajno od normalne raspodjele te su rezultati prikazani u tablici 14. Iz rezultata je vidljivo kako **nema statistički značajne povezanosti analiziranih varijabli sa NDRE vegetacijskim indeksom iz rujna**. Pozitivna povezanost ukazuje na veću povezanost analiziranih varijabli i zone manje bujnosti, dok negativna povezanost ukazuje na veću povezanost analiziranih varijabli i zone veće bujnosti na temelju NDRE indeksa iz rujna.

Tablica 14. Point biserijalni koeficijenti korelacije (r_{pb}) između vegetacijskog indeksa NDRE u terminu snimanja u rujnu i analiziranih varijabli na ciljanim trsovima (n=12) sorte 'Kraljevina' u 2019. godini na lokaciji KOS

Analizirane varijable	r_{pb} (NDRE rujan)
Koncentracija šećera	0,22
pH vrijednost	-0,04
Sadržaj ukupnog dušika u listu	0,52
Broj grozdova	0,15
Prinos po trsu	-0,41
Prosječna masa grozda	-0,38
Masa orezane rozgve	0,11
Broj mladica	0,46
Broj nodija	0,13
Indeks Ravaz	-0,18

*Bilješka: *** p<0.001; ** p<0.01; * p<0.05*

Pokazatelji rodnosti

Rodni potencijal po trsu sorte 'Kraljevina' procijenjen je temeljem koeficijenata rodnosti za dvije zone- zonu manje i zonu veće bujnosti određene na temelju najprediktivnijeg vegetacijskog indeksa NDRE u terminu snimanja u rujnu (15.9.). Koeficijenti potencijalne i relativne rodnosti (KpR, KrR) te Indeks Ravaz prikazani su u tablici 15. Prosječan broj grozdova po pupu ostavljenih rezom (KpR) za obje zone je podjednak, čak su trsovi iz zone veće bujnosti imali nešto niži KpR. No uobičajeno se rodnost procjenjuje na temelju Koeficijenta relativne rodnosti (KrR) odnosno broja grozdova po mladici te su ciljani trsovi sorte 'Kraljevina' iz obje zone bujnosti imali u prosjeku 1 grozd po mladici i svrstani su u visoko rodne trsove (KrR do 1,5). Ravnoteža vegetativnog rasta i prinosa procjenjuje se uz pomoć Ravazovog indeksa kao omjera između prinosa i mase orezane rozgve, a vrijednosti indeksa između 5 i 10 govore o uravnoteženom vegetativnom rastu i prinosu trsa. Prema izračunatom Indeksu Ravaz ciljani trsovi iz obje zone bujnosti pokazuju uravnotežen vegetativni rast i prinos.

Tablica 15. Koeficijenti rodnosti i Indeks Ravaz za zonu manje i zonu veće bujnosti na temelju najprediktivnijeg vegetacijskog indeksa NDRE u terminu snimanja u rujnu (15.9.) na ciljanim trsovima (n=12) sorte 'Kraljevina' u 2019. godini na lokaciji KOS

	Trsovi iz zone veće bujnosti (n=8)	**Trsovi iz zone manje bujnosti (n=4)**
KpR	0,97	1,05
KrR	1,13	1,05
Indeks Ravaz	8,06	5,56

KpR - koeficijent potencijalne rodnosti; KrR - koeficijent relativne rodnosti

4.1.2. Rezultati istraživanja u 2020. godini

4.1.2.1. Generirane karte bujnosti na lokaciji KOS u 2020. godini

Na slici 18 prikazane su zone manje (zelena) i veće bujnosti (crvena) vinograda sorte 'Kraljevina' prema NDVI indeksu na lokaciji Kos u tri termina snimanja u 2020. godini. Vrijednosti NDVI indeksa u prvom terminu snimanja (fenofaza 34) kreću se od 0,586-0,918 pri čemu medijan iznosi 0,886. U drugom terminu snimanja (fenofaza 36) vrijednosti NDVI indeksa kreću se od 0,602-0,921 pri čemu medijan iznosi 0,881. U trećem terminu snimanja (fenofaza 38) vrijednosti NDVI indeksa kreću se od 0,591-0,894 pri čemu medijan iznosi 0,853.

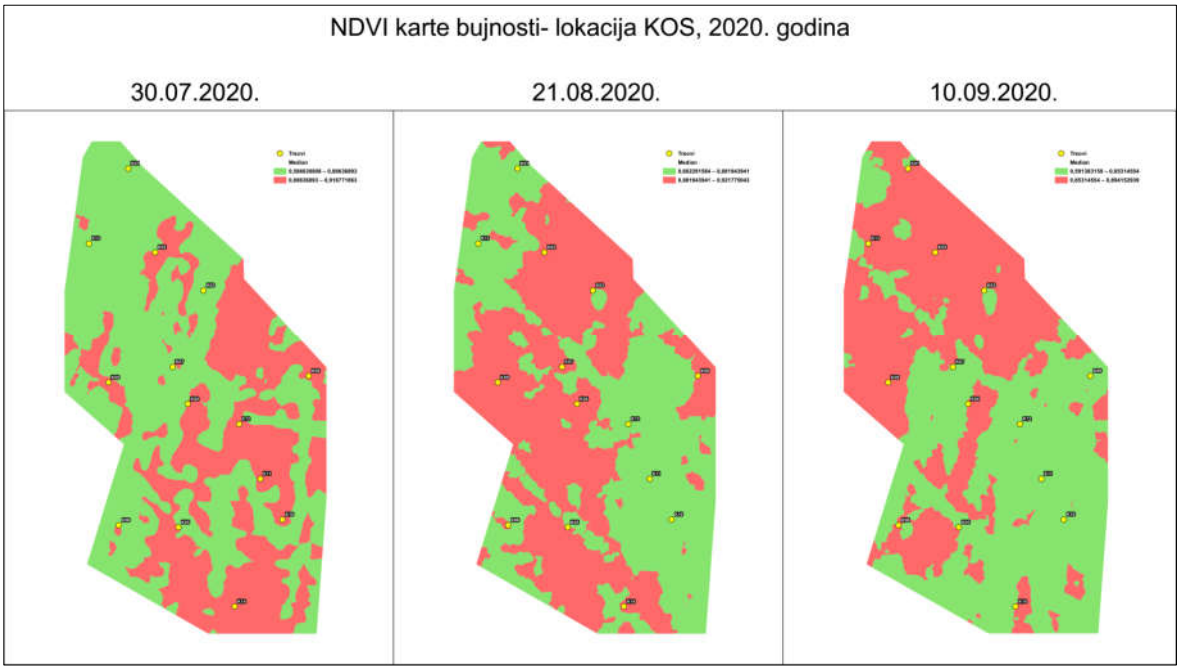

Slika 18. NDVI generirane karte bujnosti- lokacija KOS u 2020. godini

Na slici 19 prikazane su zone manje (zelena) i veće bujnosti (crvena) vinograda sorte 'Kraljevina' prema NDRE indeksu na lokaciji Kos u tri termina snimanja u 2020. godini. Vrijednosti NDRE indeksa u prvom terminu snimanja (fenofaza 34) kreću se od 0,298-0,522 pri čemu medijan iznosi 0,457. U drugom terminu snimanja (fenofaza 36) vrijednosti NDRE indeksa kreću se od 0,278-0,532 pri čemu medijan iznosi 0,427. U trećem terminu snimanja (fenofaza 38) vrijednosti NDRE indeksa kreću se od 0,267-0,495 pri čemu medijan iznosi 0,417.

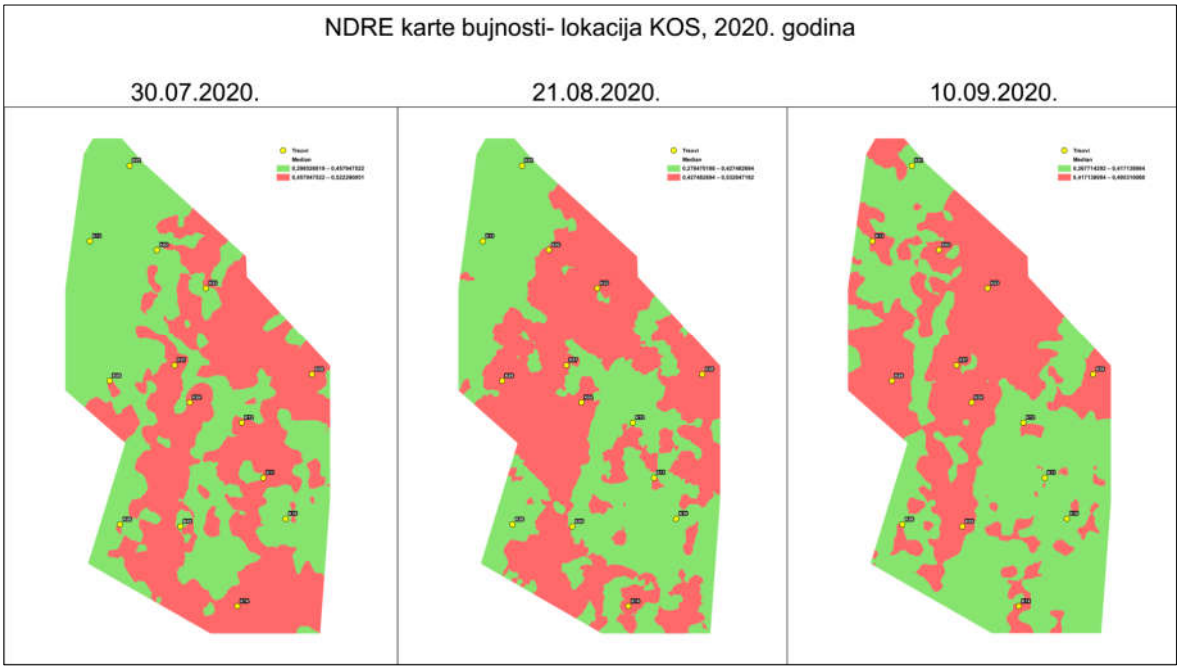

Slika 19. NDRE generirane karte bujnosti- lokacija KOS u 2020. godini

Na slici 20 prikazane su zone manje (zelena) i veće bujnosti (crvena) vinograda sorte 'Kraljevina' prema OSAVI indeksu na lokaciji Kos u tri termina snimanja u 2020. godini. Vrijednosti OSAVI indeksa u prvom terminu snimanja (fenofaza 34) kreću se od 0,366-0,721 pri čemu medijan iznosi 0,647. U drugom terminu snimanja (fenofaza 36) vrijednosti OSAVI indeksa kreću se od 0,466-0,743 pri čemu medijan iznosi 0,694. U trećem terminu snimanja (fenofaza 38) vrijednosti OSAVI indeksa kreću se od 0,338-0,675 pri čemu medijan iznosi 0,592.

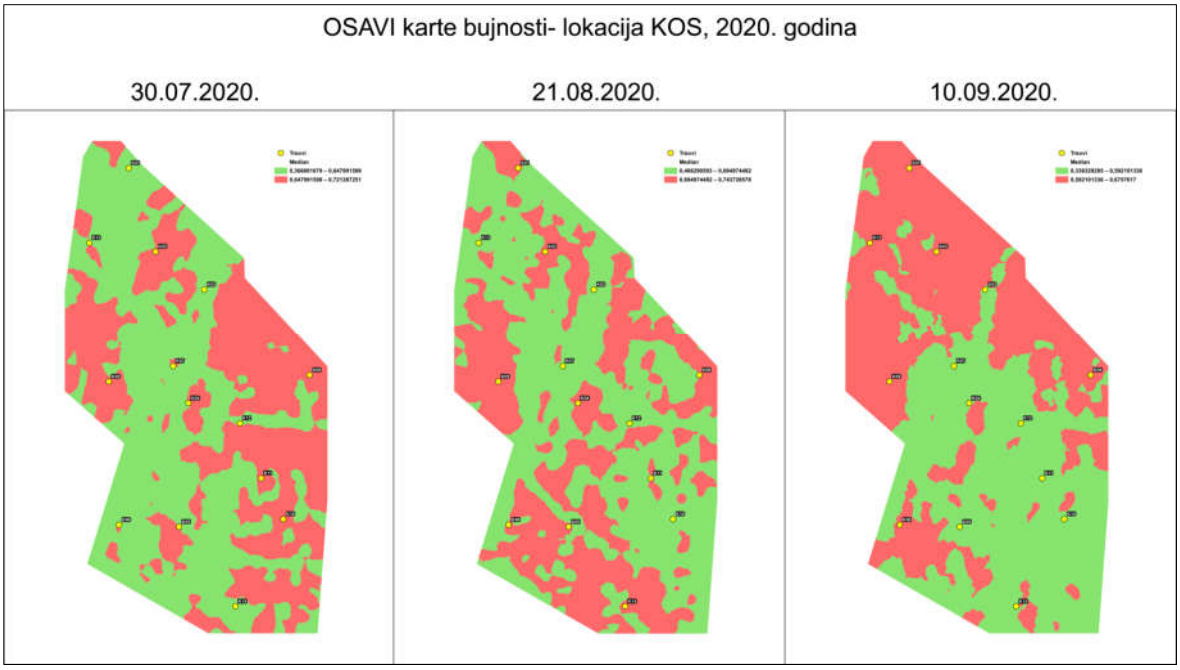

Slika 20. OSAVI generirane karte bujnosti- lokacija KOS u 2020. godini

4.1.2.2. Kvalitativno zoniranje na lokaciji KOS u 2020. godini

Prikupljeni podaci o kvalitativnim svojstvima grožđa sorte 'Kraljevina' (koncentracija šećera (°Oe), količina ukupnih kiselina (g/L) i pH vrijednost) na ciljanim trsovima (n=14) u 2020. godini podvrgnuti su postupku klasterizacije, koristeći *K means cluster* proceduru uz apriori zadani broj klastera koji iznosi dva. Na taj način dobivena su dva klastera koja se međusobno statistički značajno razlikuju prema koncentraciji šećera, količini ukupnih kiselina i pH vrijednosti, pri čemu su u prvom klasteru oni ciljani trsovi koji imaju veću koncentraciju šećera, manju količinu ukupnih kiselina i veću pH vrijednost, dok su u drugom klasteru oni ciljani trsovi koji imaju manju koncentraciju šećera, veću količinu ukupnih kiselina i manju pH vrijednost (tablica 16).

Tablica 16. Rezultat klasterizacije kvalitativnih svojstava grožđa sorte 'Kraljevina' na ciljanim trsovima (n=14) u 2020. godini na lokaciji KOS

Kvalitativna svojstva grožđa	***F*** $_{(1,12)}$	***Sig.***	**Prvi klaster (n=7)**	**Drugi klaster (n=7)**
			M ± SD	*M ± SD*
Koncentracija šećera (°Oe)	**50,304**	**0,000**	**74,57 ± 3,41**	**62,86 ± 2,73**
Ukupna kiselost (g/L)	**6,816**	**0,023**	**8,73 ± 0,81**	**10,19 ± 1,24**
pH vrijednost	**5,124**	**0,043**	**3,03 ± 0,06**	**2,93 ± 0,10**

Prema podacima iz tablice 16, trsovi iz prvog klastera (n=7) okarakterizirani su kao trsovi čije grožđe ima bolja kvalitativna svojstva, dok su oni iz drugog klastera (n=7) okarakterizirani kao trsovi čije grožđe ima lošija kvalitativna svojstva.

Kako bi se odredio najprediktivniji vegetacijski indeks s obzirom na kvalitativna svojstva grožđa, napravljena su preklapanja klasifikacijskih struktura: kvalitativne strukture trsova dobivene postupkom klasterizacije kvalitativnih svojstava grožđa s kvalitativnom strukturom trsova dobivenom na osnovu zoniranja uz pomoć vegetacijskih indeksa NDVI, NDRE i OSAVI na zone manje bujnosti (potencijalno bolja kvalitativna svojstva grožđa) i zone veće bujnosti (potencijalno lošija kvalitativna svojstva grožđa). Prema podacima iz tablice 17, može se zaključiti kako je **najprediktivniji vegetacijski indeks za kvalitativno zoniranje vinograda sorte 'Kraljevina' na lokaciji KOS u 2020. godini NDVI vegetacijski indeks s 93%-tnim preklapanjem kvalitativnih klasifikacijskih struktura u terminu snimanja u kolovozu (21.8.),** dok je najmanje prediktivan OSAVI indeks u terminu snimanja u rujnu (10.9.).

Tablica 17. Preklapanja kvalitativnih klasifikacijskih struktura dobivenih klasterizacijom i zoniranjem pomoću vegetacijskih indeksa na ciljanim trsovima (n=14) sorte 'Kraljevina' u 2020. godini na lokaciji KOS

Vegetacijski indeks	**NDRE**			**NDVI**			**OSAVI**		
Termin snimanja	Srpanj (30.7.)	Kolovoz (21.8.)	Rujan (10.9.)	Srpanj (30.7.)	**Kolovoz (21.8.)**	Rujan (10.9.)	Srpanj (30.7.)	Kolovoz (21.8.)	Rujan (10.9.)
Broj podjednako klasificiranih trsova	10	12	12	9	**13**	7	8	8	5
Udio podjednako klasificiranih trsova	71%	86%	86%	64%	**93%**	50%	57%	57%	36%

Na temelju najprediktivnijeg vegetacijskog indeksa- NDVI u terminu snimanja u kolovozu (21.8.), ciljani trsovi (n=14) klasificirani su u dvije zone bujnosti – zonu veće i zonu manje bujnosti (slika 21) te su u tablici 18 prikazani odabrani deskriptivni statistički pokazatelji kvalitativnih svojstava grožđa i sastavnica prinosa na četrnaest ciljanih trsova sorte 'Kraljevina' u 2020. godini.

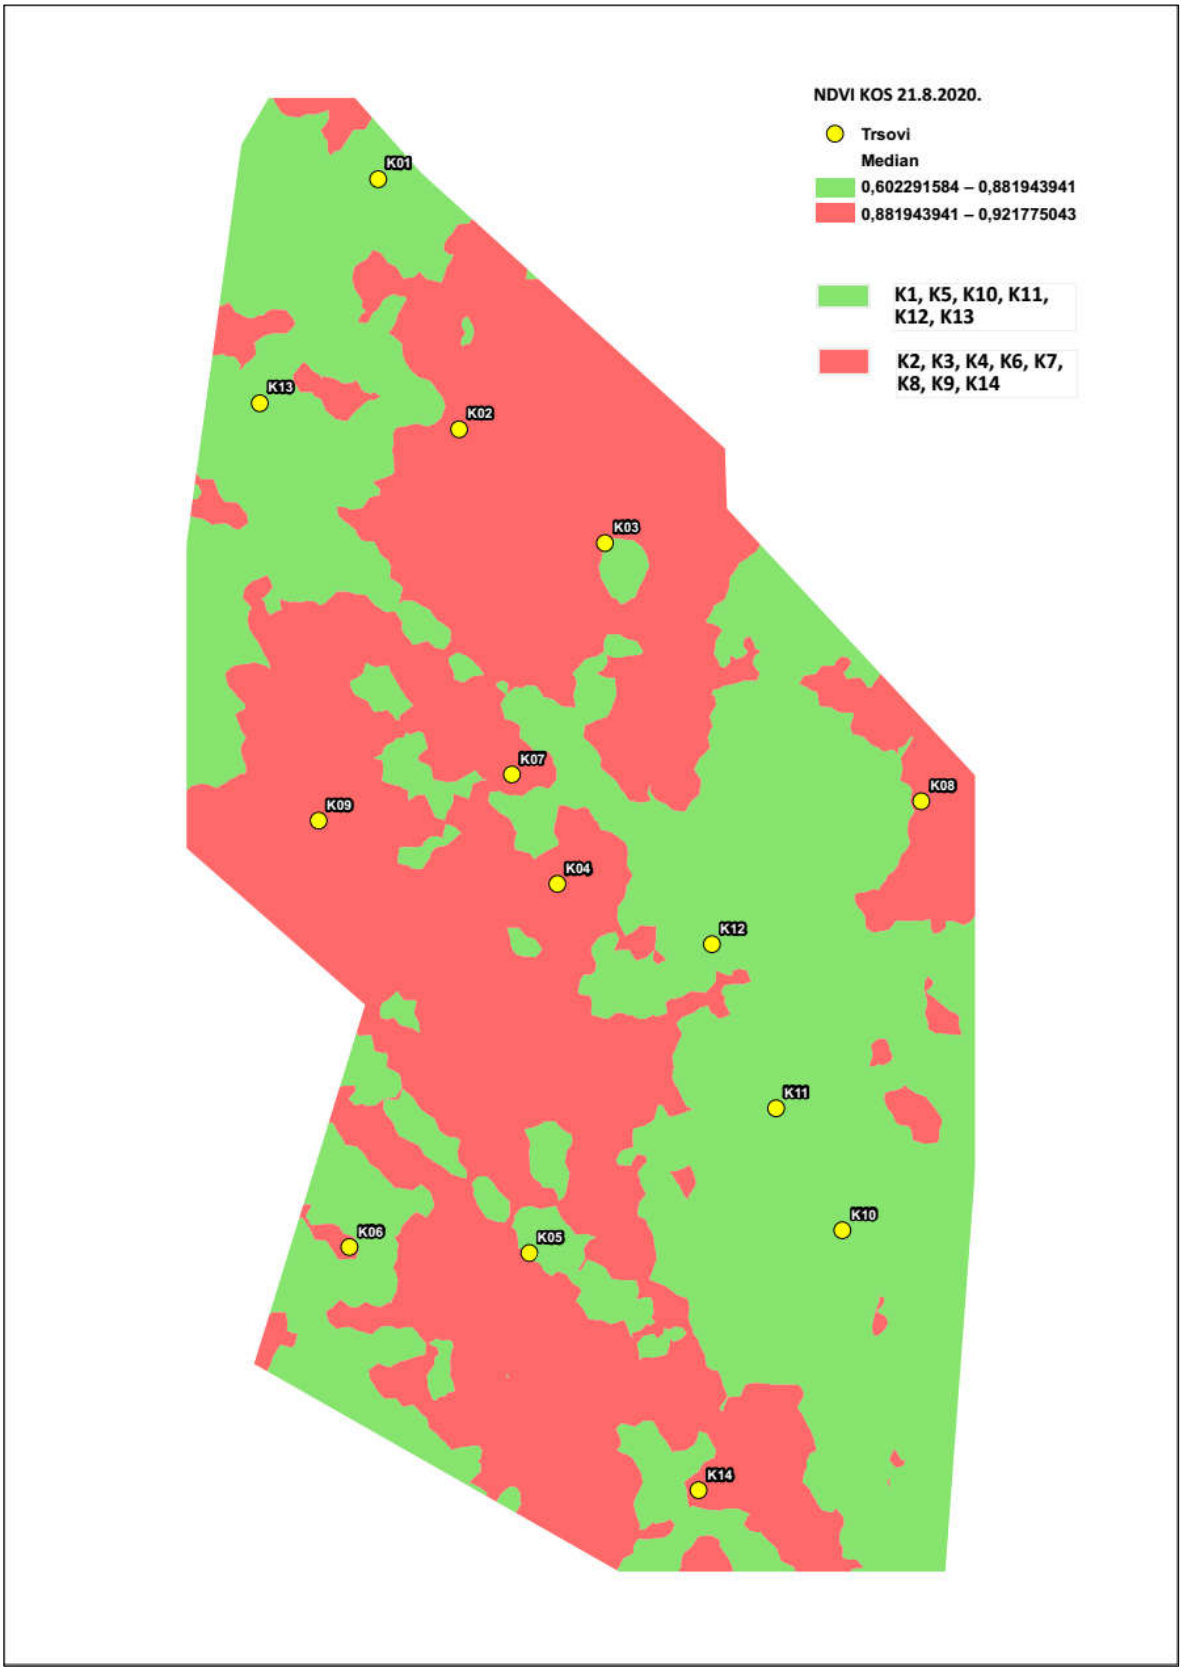

Slika 21. Generirana karta dviju zona bujnosti sorte 'Kraljevina' u 2020. godini na temelju najprediktivnijeg vegetacijskog indeksa NDVI u terminu snimanja u kolovozu (21.8.) na lokaciji KOS s prikazom klasifikacije ciljanih trsova po zonama

Tablica 18. Odabrani deskriptivni statistički pokazatelji na ciljanim trsovima (n=14) sorte 'Kraljevina' u 2020. godini na lokaciji KOS klasificirani u dvije zone bujnosti na temelju NDVI indeksa iz kolovoza

Analizirane varijable	Trsovi iz zone veće bujnosti (n=8)	Trsovi iz zone manje bujnosti (n=6)
	M ± SD (CV)	*M ± SD (CV)*
Koncentracija šećera (°Oe)	**64,38 ± 4,98 (7,74)**	**74,50 ± 3,73 (5,00)**
Količina ukupnih kiselina (g/L)	**10,14 ± 1,15 (11,35)**	**8,55 ± 0,71 (8,35)**
pH vrijednost	2,94 ± 0,09 (3,22)	3,04 ± 0,06 (1,95)
Sadržaj ukupnog dušika u listu (% na bazi suhe tvari)	2,11 ± 0,14 (6,83)	2,15 ± 0,17 (7,75)
Broj grozdova	**15,75 ± 4,27 (27,10)**	**10,17 ± 3,87 (38,04)**
Prinos po trsu (kg)	**5,01 ± 1,59 (31,69)**	**2,94 ± 1,35 (45,94)**
Prosječna masa grozda (kg)	0,33 ± 0,12 (36,66)	0,28 ± 0,04 (15,09)
Masa orezane rozgve (kg)	0,57 ± 0,27 (46,78)	0,53 ± 0,17 (32,66)
Broj mladica	13,63 ± 2,88 (21,09)	12,00 ± 2,00 (16,67)
Broj nodija	13,63 ± 1,85 (13,55)	12,83 ± 2,14 (16,66)

Bilješka: M = prosječna vrijednost; SD = standardna devijacija, CV = koeficijent varijacija

Na temelju najprediktivnijeg vegetacijskog indeksa NDVI u terminu snimanja u kolovozu (21.8.), testirana je statistička značajnost razlika u izmjerenim kvalitativnim svojstvima grožđa i sastavnicama prinosa između dviju zona- zone manje i zone veće bujnosti u prosječnim rezultatima na analiziranim varijablama. Analizirane varijable odnose se na: koncentraciju šećera (°Oe), količinu ukupnih kiselina (g/L), pH vrijednost, sadržaj ukupnog dušika u listu (% na bazi suhe tvari), broj mladica, broj nodija, prinos po trsu (kg), broj grozdova, prosječnu masa grozda (kg), masu orezane rozgve (kg) te **utvrđeno je kako se dvije zone bujnosti razlikuju statistički značajno u prosječnim rezultatima u koncentraciji šećera** (homogene varijance, $t_{(12)}=4,163,\ p<0,01$), **količini ukupne kiseline** (homogene varijance, $t_{(12)}=-2,963,\ p<0,05$), **broju grozdova** (homogene varijance, $t_{(12)}=-2,518,\ p<0,05$) te **prinosu** (homogene varijance, $t_{(12)}=-2,570,\ p<0,05$); pri čemu trsovi iz zone manje bujnosti imaju veću koncentraciju šećera (M±SD= 74,50±3,73), manju količinu ukupne kiseline (M±SD= 8,55±0,71), manji broj grozdova (M±SD= 10,17±3,87) te manji prinos (M±SD= 2,94±1,35); dok trsovi iz zone veće bujnosti imaju

manju koncentraciju šećera (M±SD= 64,38±4,98), veću količinu ukupne kiseline (M±SD= 10,14±1,15), veći broj grozdova (M±SD= 15,75±4,27) te veći prinos (M±SD= 5,01±1,59). Rezultati testiranja prikazani su u tablici 19.

Tablica 19. Rezultat testiranja statističke značajnosti razlika između zone veće i manje bujnosti dobivenih na temelju NDVI indeksa iz kolovoza u prosječnim rezultatima na analiziranim varijablama sorte 'Kraljevina' u 2020. godini na lokaciji KOS

Analizirane varijable	**Trsovi iz zone veće bujnosti (n=8)**	**Trsovi iz zone manje bujnosti (n=6)**	**Testiranje statističke značajnosti razlike u prosječnim rezultatima / rangovima**		
	Shapiro-Wilk	*Shapiro-Wilk*	*F*	*$t_{(12)}$*	*Mann-Whitney U*
Koncentracija šećera (°Oe)	**0,883**	**0,968**	**0,054**	**4,163****	
Količina ukupnih kiselina (g/L)	**0,975**	**0,905**	**0,775**	**-2,963***	
pH vrijednost	0,959	0,959	0,844	2,123	
Sadržaj ukupnog dušika u listu (% na bazi suhe tvari)	0,950	0,902	0,483	0,437	
Broj grozdova	**0,966**	**0,980**	**0,283**	**-2,518***	
Prinos po trsu (kg)	**0,949**	**0,923**	**0,271**	**-2,570***	
Prosječna masa grozda (kg)	0,959	0,902	3,788	-1,007	
Masa orezane rozgve (kg)	0,781*	0,946			20,000
Broj mladica	0,940	0,896	1,283	-1,181	
Broj nodija	0,969	0,818	0,757	-0,743	

*Bilješka: Shapiro-Wilk = iznos Shapiro-Wilk testovnog statistika, F = iznos Leveneovog testovnog statistika za testiranje homogenosti varijanci; $t_{(df)}$ = iznos t omjera s pripadnim stupnjevima slobode za testiranje statističke značajnosti razlike prosječnih rezultata; Mann-Whitney U = iznos Mann-Whitney U statistika za testiranje statističke značajnosti razlike rangova; *** p<0.001; ** p<0.01; *p<0.05*

Dodatno je za najprediktivniji vegetacijski indeks- NDVI u terminu snimanja u kolovozu (21.8.), izračunat i point biserijalni koeficijent korelacije (r_{pb}) s analiziranim varijablama koje ne odstupaju statistički značajno od normalne raspodjele te su rezultati prikazani u tablici 20. Iz rezultata je vidljivo kako je **koncentracija šećera statistički značajno pozitivno povezana s NDVI indeksom iz kolovoza; a količina ukupnih kiselina, broj**

grozdova i prinos po trsu statistički su značajno negativno povezani s NDVI indeksom iz kolovoza, odnosno utvrđeno je da trsovi iz zone manje bujnosti imaju statistički značajno veću koncentraciju šećera, a trsovi iz zone veće bujnosti imaju statistički značajno veću količinu ukupnih kiselina, veći broja grozdova i veći prinos po trsu na temelju NDVI indeksa iz kolovoza.

Tablica 20. Point biserijalni koeficijenti korelacije (r_{pb}) između vegetacijskog indeksa NDVI u terminu snimanja u kolovozu i analiziranih varijabli na ciljanim trsovima (n=14) sorte 'Kraljevina' u 2020. godini na lokaciji KOS

Analizirane varijable	r_{pb} (NDVI kolovoz)
Koncentracija šećera	**0,77****
Količina ukupnih kiselina	**-0,65***
pH vrijednost	0,52
Sadržaj ukupnog dušika u listu	0,13
Broj grozdova	**-0,59***
Prinos po trsu	**-0,60***
Prosječna masa grozda	-0,28
Broj mladica	-0,32
Broj nodija	-0,21
Indeks Ravaz	-0,51

*Bilješka: *** p<0.001; ** p<0.01; * p<0.05*

Pokazatelji rodnosti

Rodni potencijal po trsu sorte 'Kraljevina' procijenjen je temeljem koeficijenata rodnosti za dvije zone- zonu manje i zonu veće bujnosti određene na temelju najprediktivnijeg vegetacijskog indeksa NDVI u terminu snimanja u kolovozu (21.8.). Koeficijenti potencijalne i relativne rodnosti (KpR, KrR) te Indeks Ravaz prikazani su u tablici 21. Prosječan broj grozdova po pupu ostavljenih rezom (KpR) u zoni veće bujnosti iznosi 1,16 grozda dok u zoni manje bujnosti iznosi 0,79 što ukazuje na razliku u opterećenju između dviju zona bujnosti. Uobičajeno se rodnost procjenjuje na temelju Koeficijenta relativne rodnosti (KrR) odnosno broja grozdova po mladici te su ciljani trsovi sorte 'Kraljevina' iz različitih zona bujnosti pokazali i različite koeficijente. U zoni veće bujnosti trsovi su imali 1,16 grozdova po mladici te su svrstani u visoko rodne trsove (KrR do 1,5). Trsovi iz zone manje bujnosti imali su manje od jednog grozda po mladici te su svrstani u srednje rodne

trsove (KrR do 1,0). Ravnoteža vegetativnog rasta i prinosa procjenjuje se uz pomoć Ravazovog indeksa kao omjera između prinosa i mase orezane rozgve, a vrijednosti indeksa između 5 i 10 govore o uravnoteženom vegetativnom rastu i prinosu trsa. Prema izračunatom Indeksu Ravaz ciljani trsovi iz obje zone bujnosti pokazuju uravnotežen vegetativni rast i prinos.

Tablica 21. Koeficijenti rodnosti i Indeks Ravaz za zonu manje i zonu veće bujnosti na temelju najprediktivnijeg vegetacijskog indeksa NDVI u terminu snimanja u kolovozu (21.8.) na ciljanim trsovima (n=14) sorte 'Kraljevina' u 2020. godini na lokaciji KOS

	Trsovi iz zone veće bujnosti (n=8)	**Trsovi iz zone manje bujnosti (n=6)**
KpR	1,16	0,79
KrR	1,16	0,85
Indeks Ravaz	8,73	5,51

KpR - koeficijent potencijalne rodnosti; KrR - koeficijent relativne rodnosti

4.2. 'Kraljevina' (*Vitis vinifera* L.) - lokacija PUHELEK- PUREK

4.2.1. Rezultati istraživanja u 2020. godini

4.2.1.1. Generirane karte bujnosti na lokaciji PUHELEK- PUREK u 2020. godini

Na slici 22 prikazane su zone manje (zelena) i veće bujnosti (crvena) vinograda sorte 'Kraljevina' prema NDVI indeksu na lokaciji Puhelek- Purek u dva termina snimanja u 2020. godini. Vrijednosti NDVI indeksa u prvom terminu snimanja (fenofaza 36) kreću se od 0,314-0,942 pri čemu medijan iznosi 0,844. U drugom terminu snimanja (fenofaza 38) vrijednosti NDVI indeksa kreću se od 0,220-0,918 pri čemu medijan iznosi 0,834.

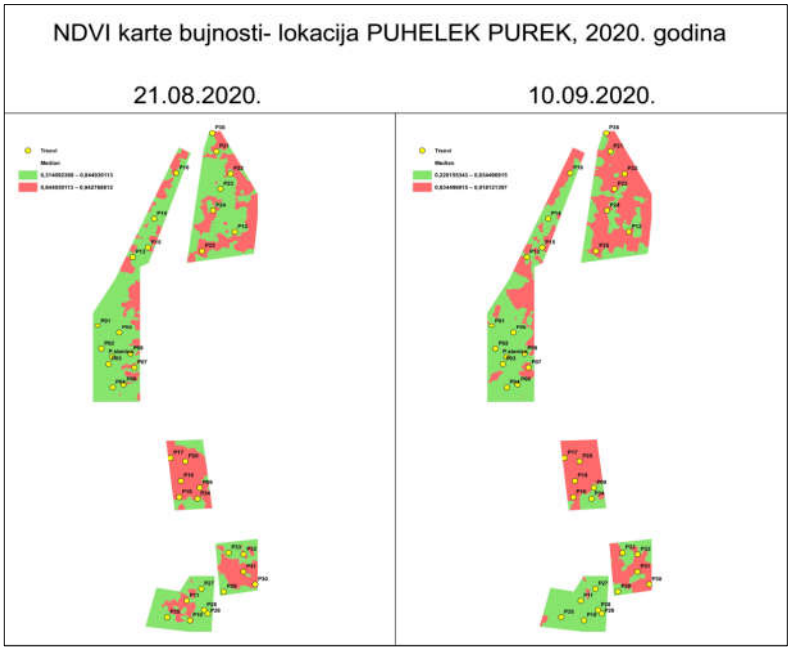

Slika 22. NDVI generirane karte bujnosti- lokacija PUHELEK- PUREK u 2020. godini

Na slici 23 prikazane su zone manje (zelena) i veće bujnosti (crvena) vinograda sorte 'Kraljevina' prema NDRE indeksu na lokaciji Puhelek- Purek u dva termina snimanja u 2020. godini. Vrijednosti NDRE indeksa u prvom terminu snimanja (fenofaza 36) kreću se od 0,159-0,610 pri čemu medijan iznosi 0,403. U drugom terminu snimanja (fenofaza 38) vrijednosti NDRE indeksa kreću se od 0,111-0,540 pri čemu medijan iznosi 0,377.

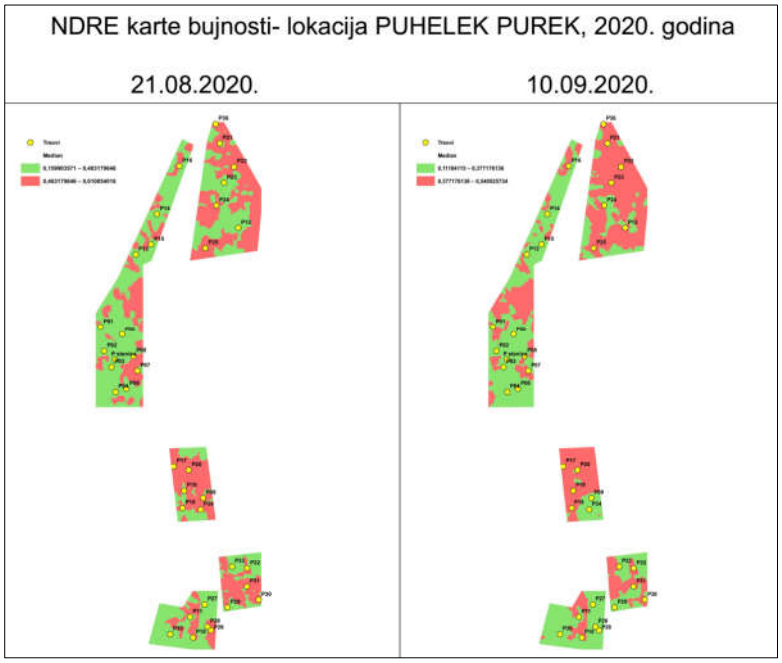

Slika 23. NDRE generirane karte bujnosti- lokacija PUHELEK- PUREK u 2020. godini

Na slici 24 prikazane su zone manje (zelena) i veće bujnosti (crvena) vinograda sorte 'Kraljevina' prema OSAVI indeksu na lokaciji Puhelek- Purek u dva termina snimanja u 2020. godini. Vrijednosti OSAVI indeksa u prvom terminu snimanja (fenofaza 36) kreću se od 0,230-0,756 pri čemu medijan iznosi 0,649. U drugom terminu snimanja (fenofaza 38) vrijednosti OSAVI indeksa kreću se od 0,172-0,708 pri čemu medijan iznosi 0,599.

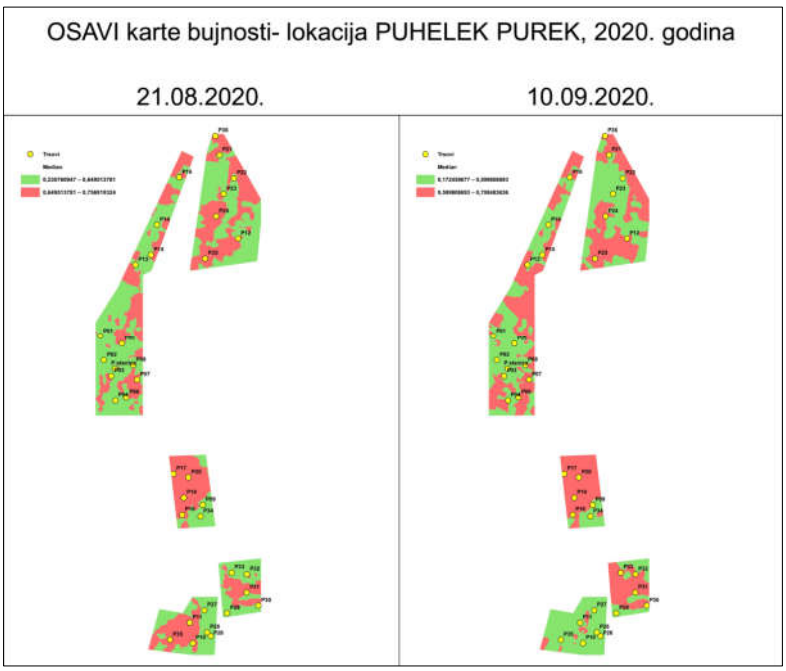

Slika 24. OSAVI generirane karte bujnosti- lokacija PUHELEK- PUREK u 2020. godini

4.2.1.2. Kvalitativno zoniranje na lokaciji PUHELEK- PUREK u 2020. godini

Prikupljeni podaci o kvalitativnim svojstvima grožđa sorte 'Kraljevina' (koncentracija šećera (°Oe), količina ukupnih kiselina (g/L) i pH vrijednost) na ciljanim trsovima (n=36) u 2020. godini podvrgnuti su postupku klasterizacije, koristeći *K means cluster* proceduru uz apriori zadani broj klastera koji iznosi dva. Na taj način dobivena su dva klastera koja se međusobno statistički značajno razlikuju prema koncentraciji šećera, količini ukupnih kiselina i pH vrijednosti, pri čemu su u prvom klasteru oni ciljani trsovi koji imaju veću koncentraciju šećera, manju količinu ukupnih kiselina i veću pH vrijednost, dok su u drugom klasteru oni ciljani trsovi koji imaju manju koncentraciju šećera, veću količinu ukupnih kiselina i manju pH vrijednost (tablica 22).

Tablica 22. Rezultat klasterizacije kvalitativnih svojstava grožđa sorte 'Kraljevina' na ciljanim trsovima (n=36) u 2020. godini na lokaciji PUHELEK- PUREK

Kvalitativna svojstva grožđa	***F*** $_{(1,34)}$	***Sig.***	**Prvi klaster (n=19)**	**Drugi klaster (n=17)**
			M ± SD	*M ± SD*
Koncentracija šećera (°Oe)	**52,546**	**0,000**	**65,37 ± 5,46**	**79,18 ± 5,97**
Ukupna kiselost (g/L)	**5,221**	**0,029**	**9,03 ± 1,64**	**7,88 ± 1,33**
pH vrijednost	**4,366**	**0,044**	**2,92 ± 0,10**	**2,98 ± 0,06**

Prema podacima iz tablice 22, trsovi iz prvog klastera (n=19) okarakterizirani su kao trsovi čije grožđe ima lošija kvalitativna svojstva, dok su oni iz drugog klastera (n=17) okarakterizirani kao trsovi čije grožđe ima bolja kvalitativna svojstva.

Kako bi se odredio najprediktivniji vegetacijski indeks s obzirom na kvalitativna svojstva grožđa, napravljena su preklapanja klasifikacijskih struktura: kvalitativne strukture trsova dobivene postupkom klasterizacije kvalitativnih svojstava grožđa s kvalitativnom strukturom trsova dobivenom na osnovu zoniranja uz pomoć vegetacijskih indeksa NDVI, NDRE i OSAVI na zone manje bujnosti (potencijalno bolja kvalitativna svojstva grožđa) i zone veće bujnosti (potencijalno lošija kvalitativna svojstva grožđa). Prema podacima iz tablice 23, može se zaključiti kako je **najprediktivniji vegetacijski indeks za kvalitativno zoniranje vinograda sorte 'Kraljevina' na lokaciji PUHELEK- PUREK u 2020. godini NDVI vegetacijski indeks s 81%-tnim preklapanjem kvalitativnih**

klasifikacijskih struktura u terminu snimanja u kolovozu (21.8.), dok je najmanje prediktivan OSAVI indeks u terminu snimanja u rujnu (10.9.).

Tablica 23. Preklapanja kvalitativnih klasifikacijskih struktura dobivenih klasterizacijom i zoniranjem pomoću vegetacijskih indeksa na ciljanim trsovima (n=36) sorte 'Kraljevina' u 2020. godini na lokaciji PUHELEK- PUREK

Vegetacijski indeks	**NDRE**			**NDVI**			**OSAVI**		
Termin snimanja	Srpanj (30.7.)	Kolovoz (21.8.)	Rujan (10.9.)	Srpanj (30.7.)	**Kolovoz (21.8.)**	Rujan (10.9.)	Srpanj (30.7.)	Kolovoz (21.8.)	Rujan (10.9.)
Broj podjednako klasificiranih trsova	-	28	24	-	**29**	25	-	27	22
Udio podjednako klasificiranih trsova	-	78%	67%	-	**81%**	69%	-	75%	61%

Na temelju najprediktivnijeg vegetacijskog indeksa- NDVI u terminu snimanja u kolovozu (21.8.), ciljani trsovi (n=36) klasificirani su u dvije zone bujnosti – zonu veće i zonu manje bujnosti (slika 25) te su u tablici 24 prikazani odabrani deskriptivni statistički pokazatelji kvalitativnih svojstava grožđa i sastavnica prinosa na trideset i šest ciljanih trsova sorte 'Kraljevina' u 2020. godini.

Slika 25. Generirana karta dviju zona bujnosti sorte 'Kraljevina' u 2020. godini na temelju najprediktivnijeg vegetacijskog indeksa NDVI u terminu snimanja u kolovozu (21.8.) na lokaciji PUHELEK- PUREK s prikazom klasifikacije ciljanih trsova po zonama

Tablica 24. Odabrani deskriptivni statistički pokazatelji na ciljanim trsovima (n=36) sorte 'Kraljevina' u 2020. godini na lokaciji PUHELEK- PUREK klasificirani u dvije zone bujnosti na temelju NDVI indeksa iz kolovoza

Analizirane varijable	Trsovi iz zone veće bujnosti (n=18)	Trsovi iz zone manje bujnosti (n=18)
	M ± SD (CV)	*M ± SD (CV)*
Koncentracija šećera (°Oe)	**65,78 ± 6,15 (9,35)**	**78,00 ± 6,99 (8,96)**
Količina ukupnih kiselina (g/L)	**9,34 ± 1,37 (14,66)**	**7,63 ± 1,34 (17,51)**
pH vrijednost	**2,91 ± 0,09 (2,99)**	**2,98 ± 0,08 (2,73)**
Sadržaj ukupnog dušika u listu (% na bazi suhe tvari)	1,80 ± 0,20 (11,18)	1,77 ± 0,18 (10,04)
Broj grozdova	**17,67 ± 6,46 (36,58)**	**12,67 ± 9,18 (72,49)**
Prinos po trsu (kg)	**4,68 ± 1,49 (31,80)**	**3,34 ± 2,20 (65,78)**
Prosječna masa grozda (kg)	0,27 ± 0,07 (23,91)	0,29 ± 0,09 (30,29)
Masa orezane rozgve (kg)	0,45 ± 0,17 (39,12)	0,39 ± 0,16 (41,48)
Broj mladica	12,94 ± 2,46 (19,02)	13,44 ± 4,91 (36,56)
Broj nodija	13,28 ± 2,05 (15,45)	13,61 ± 2,43 (17,85)

Bilješka: M = prosječna vrijednost; SD = standardna devijacija, CV = koeficijent varijacija

Na temelju najprediktivnijeg vegetacijskog indeksa NDVI u terminu snimanja u kolovozu (21.8.), testirana je statistička značajnost razlika u izmjerenim kvalitativnim svojstvima grožđa i sastavnicama prinosa između dviju zona- zone manje i zone veće bujnosti u prosječnim rezultatima na analiziranim varijablama. Analizirane varijable odnose se na: koncentraciju šećera (°Oe), količinu ukupnih kiselina (g/L), pH vrijednost, sadržaj ukupnog dušika u listu (% na bazi suhe tvari), broj mladica, broj nodija, prinos po trsu (kg), broj grozdova, prosječnu masa grozda (kg), masu orezane rozgve (kg) te **utvrđeno je kako se dvije zone bujnosti razlikuju statistički značajno u prosječnim rezultatima u koncentraciji šećera** (homogene varijance, $t_{(34)}=-5,570,\ p<0,001$), **količini ukupne kiseline** (Mann-Whitney U= 59,000, p<0,01), **pH vrijednosti** (homogene varijance, $t_{(34)}=-2,653,\ p<0,05$), **broju grozdova** (Mann-Whitney U= 83,500, p<0,05) **te prinosu** (Mann-Whitney U= 76,500, p<0,01); pri čemu trsovi iz zone manje bujnosti imaju veću koncentraciju šećera (M±SD= 78,00±6,99), manju količinu ukupne kiseline (M±SD= 7,63±1,34), veću pH vrijednost (M±SD= 2,98±0,08), manji broj grozdova (M±SD=

12,67±9,18) te manji prinos (M±SD= 3,34±2,20); dok trsovi iz zone veće bujnosti imaju manju koncentraciju šećera (M±SD= 65,78±6,15), veću količinu ukupne kiseline (M±SD= 9,34±1,37), manju pH vrijednost (M±SD= 2,91±0,09), veći broj grozdova (M±SD= 17,67±6,46) te veći prinos (M±SD= 4,68±1,49). Rezultati testiranja prikazani su u tablici 25.

Tablica 25. Rezultat testiranja statističke značajnosti razlika između zone veće i manje bujnosti dobivenih na temelju NDVI indeksa iz kolovoza u prosječnim rezultatima na analiziranim varijablama sorte 'Kraljevina' u 2020. godini na lokaciji PUHELEK- PUREK

Analizirane varijable	**Trsovi iz zone veće bujnosti (n=18)**	**Trsovi iz zone manje bujnosti (n=18)**	**Testiranje statističke značajnosti razlike u prosječnim rezultatima / rangovima**		
	Shapiro-Wilk	*Shapiro-Wilk*	*F*	*t (34)*	*Mann-Whitney U*
Koncentracija šećera (°Oe)	**0,926**	**0,969**	**0,326**	**-5,570*** **	
Količina ukupnih kiselina (g/L)	**0,892***	**0,982**			**59,000** **
pH vrijednost	**0,953**	**0,922**	**0,624**	**-2,653***	
Sadržaj ukupnog dušika u listu (% na bazi suhe tvari)	0,957	0,960	0,536	0,493	
Broj grozdova	**0,962**	**0,846** **			**83,500***
Prinos po trsu (kg)	**0,961**	**0,836** **			**76,500** **
Prosječna masa grozda (kg)	0,892*	0,973			137,500
Masa orezane rozgve (kg)	0,959	0,959	0,271	1,008	
Broj mladica	0,901	0,951	3,642	-0,386	
Broj nodija	0,890*	0,950			142,500

*Bilješka: Shapiro-Wilk = iznos Shapiro-Wilk testovnog statistika, F = iznos Leveneovog testovnog statistika za testiranje homogenosti varijanci; $t_{(df)}$ = iznos t omjera s pripadnim stupnjevima slobode za testiranje statističke značajnosti razlike prosječnih rezultata; Mann-Whitney U = iznos Mann-Whitney U statistika za testiranje statističke značajnosti razlike rangova; *** p<0.001; ** p<0.01; * p<0.05*

Dodatno je za najprediktivniji vegetacijski indeks- NDVI u terminu snimanja u kolovozu (21.8.), izračunat i point biserijalni koeficijent korelacije (r_{pb}) s analiziranim varijablama koje ne odstupaju statistički značajno od normalne raspodjele te su rezultati prikazani u tablici 26. Iz rezultata je vidljivo kako su **koncentracija šećera i pH vrijednost statistički**

značajno pozitivno povezane s NDVI indeksom iz kolovoza; odnosno utvrđeno je da trsovi iz zone manje bujnosti imaju statistički značajno veću koncentraciju šećera i pH vrijednost na temelju NDVI indeksa iz kolovoza.

Tablica 26. Point biserijalni koeficijenti korelacije (r_{pb}) između vegetacijskog indeksa NDVI u terminu snimanja u kolovozu i analiziranih varijabli na ciljanim trsovima (n=36) sorte 'Kraljevina' u 2020. godini na lokaciji PUHELEK- PUREK

Analizirane varijable	r_{pb} (NDVI kolovoz)
Koncentracija šećera	**0,69*** **
pH vrijednost	**0,41***
Sadržaj ukupnog dušika u listu	-0,08
Masa orezane rozgve	-0,17
Broj mladica	0,07
Indeks Ravaz	-0,30

*Bilješka: *** p<0.001; ** p<0.01; * p<0.05*

Pokazatelji rodnosti

Rodni potencijal po trsu sorte 'Kraljevina' procijenjen je temeljem koeficijenata rodnosti za dvije zone- zonu manje i zonu veće bujnosti određene na temelju najprediktivnijeg vegetacijskog indeksa NDVI u terminu snimanja u kolovozu (21.8.). Koeficijenti potencijalne i relativne rodnosti (KpR, KrR) te Indeks Ravaz prikazani su u tablici 27. Prosječan broj grozdova po pupu ostavljenih rezom (KpR) u zoni veće bujnosti iznosi 1,33 grozda dok u zoni manje bujnosti iznosi 0,93 što ukazuje na razliku u opterećenju između dviju zona bujnosti. Uobičajeno se rodnost procjenjuje na temelju Koeficijenta relativne rodnosti (KrR) odnosno broja grozdova po mladici te su ciljani trsovi sorte 'Kraljevina' iz različitih zona bujnosti pokazali i različite koeficijente. U zoni veće bujnosti trsovi su imali 1,36 grozdova po mladici te su svrstani u visoko rodne trsove (KrR do 1,5). Trsovi iz zone manje bujnosti imali su manje od jednog grozda po mladici te su svrstani u srednje rodne trsove (KrR do 1,0). Ravnoteža vegetativnog rasta i prinosa procjenjuje se uz pomoć Ravazovog indeksa kao omjera između prinosa i mase orezane rozgve, a vrijednosti indeksa između 5 i 10 govore o uravnoteženom vegetativnom rastu i prinosu trsa. Prema izračunatom Indeksu Ravaz ciljani trsovi iz obje zone bujnosti pokazuju relativno uravnotežen vegetativni rast i prinos iako se nalaze bliže gornjoj granici vrijednosti indeksa.

Tablica 27. Koeficijenti rodnosti i Indeks Ravaz za zonu manje i zonu veće bujnosti na temelju najprediktivnijeg vegetacijskog indeksa NDVI u terminu snimanja u kolovozu (21.8.) na ciljanim trsovima (n=36) sorte 'Kraljevina' u 2020. godini na lokaciji PUHELEK-PUREK

	Trsovi iz zone veće bujnosti (n=18)	**Trsovi iz zone manje bujnosti (n=18)**
KpR	1,33	0,93
KrR	1,37	0,94
Indeks Ravaz	10,46	8,54

KpR - koeficijent potencijalne rodnosti; KrR - koeficijent relativne rodnosti

4.3. 'Pinot crni' (*Vitis vinifera* L.) – lokacija TOMAC

4.3.1. Rezultati istraživanja u 2019. godini

4.3.1.1. Generirane karte bujnosti na lokaciji TOMAC u 2019. godini

Na slici 26 prikazane su zone manje (zelena) i veće bujnosti (crvena) vinograda sorte 'Pinot crni' prema NDVI indeksu na lokaciji Tomac u tri termina snimanja u 2019. godini. Vrijednosti NDVI indeksa u prvom terminu snimanja (fenofaza 34) kreću se od 0,581-0,900 pri čemu medijan iznosi 0,812. U drugom terminu snimanja (fenofaza 36) vrijednosti NDVI indeksa kreću se od 0,556-0,908 pri čemu medijan iznosi 0,837. U trećem terminu snimanja (fenofaza 38) vrijednosti NDVI indeksa kreću se od 0,549-0,914 pri čemu medijan iznosi 0,865.

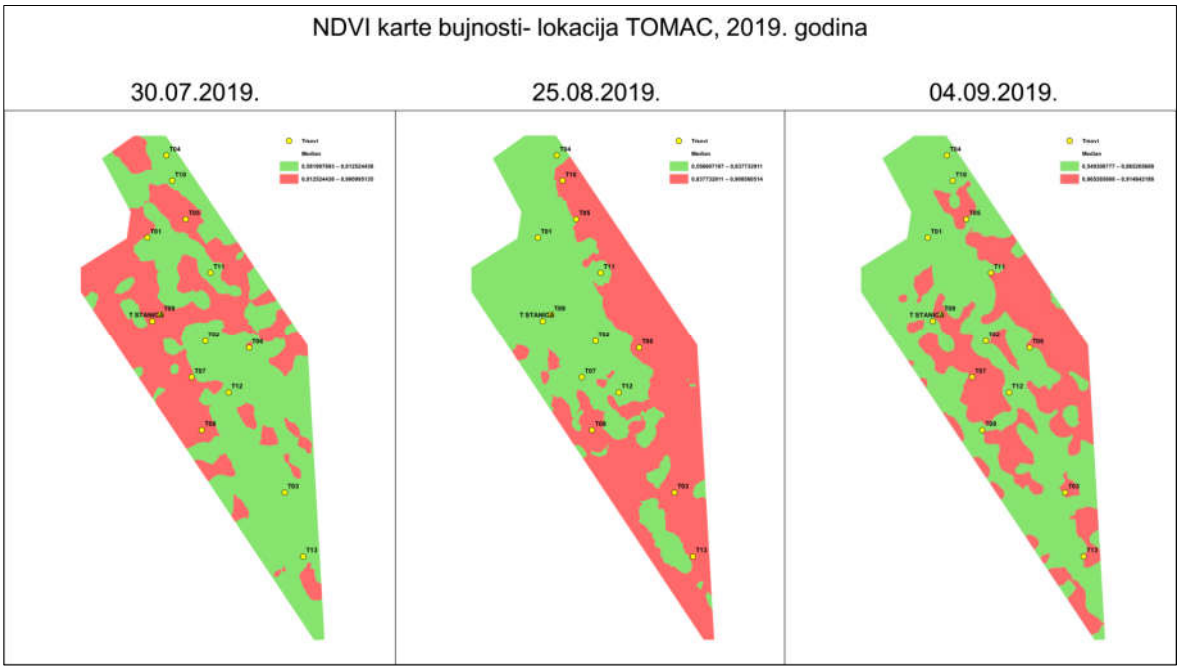

Slika 26. NDVI generirane karte bujnosti- lokacija TOMAC u 2019. godini

Na slici 27 prikazane su zone manje (zelena) i veće bujnosti (crvena) vinograda sorte 'Pinot crni' prema NDRE indeksu na lokaciji Tomac u tri termina snimanja u 2019. godini. Vrijednosti NDRE indeksa u prvom terminu snimanja (fenofaza 34) kreću se od 0,249-0,412 pri čemu medijan iznosi 0,338. U drugom terminu snimanja (fenofaza 36) vrijednosti NDRE indeksa kreću se od 0,271-0,462 pri čemu medijan iznosi 0,376. U trećem terminu snimanja (fenofaza 38) vrijednosti NDRE indeksa kreću se od 0,267-0,432 pri čemu medijan iznosi 0,360.

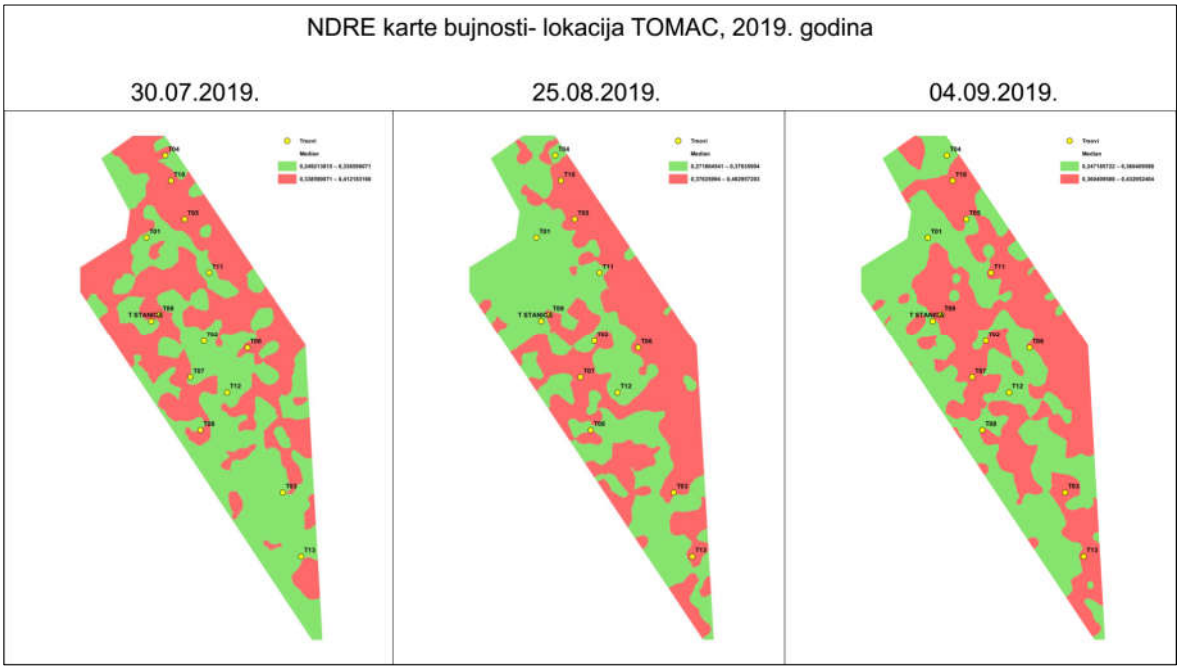

Slika 27. NDRE generirane karte bujnosti- lokacija TOMAC u 2019. godini

Na slici 28 prikazane su zone manje (zelena) i veće bujnosti (crvena) vinograda sorte 'Pinot crni' prema OSAVI indeksu na lokaciji Tomac u tri termina snimanja u 2019. godini. Vrijednosti OSAVI indeksa u prvom terminu snimanja (fenofaza 34) kreću se od 0,369-0,686 pri čemu medijan iznosi 0,594. U drugom terminu snimanja (fenofaza 36) vrijednosti OSAVI indeksa kreću se od 0,529-0,879 pri čemu medijan iznosi 0,803. U trećem terminu snimanja (fenofaza 38) vrijednosti OSAVI indeksa kreću se od 0,408-0,730 pri čemu medijan iznosi 0,670.

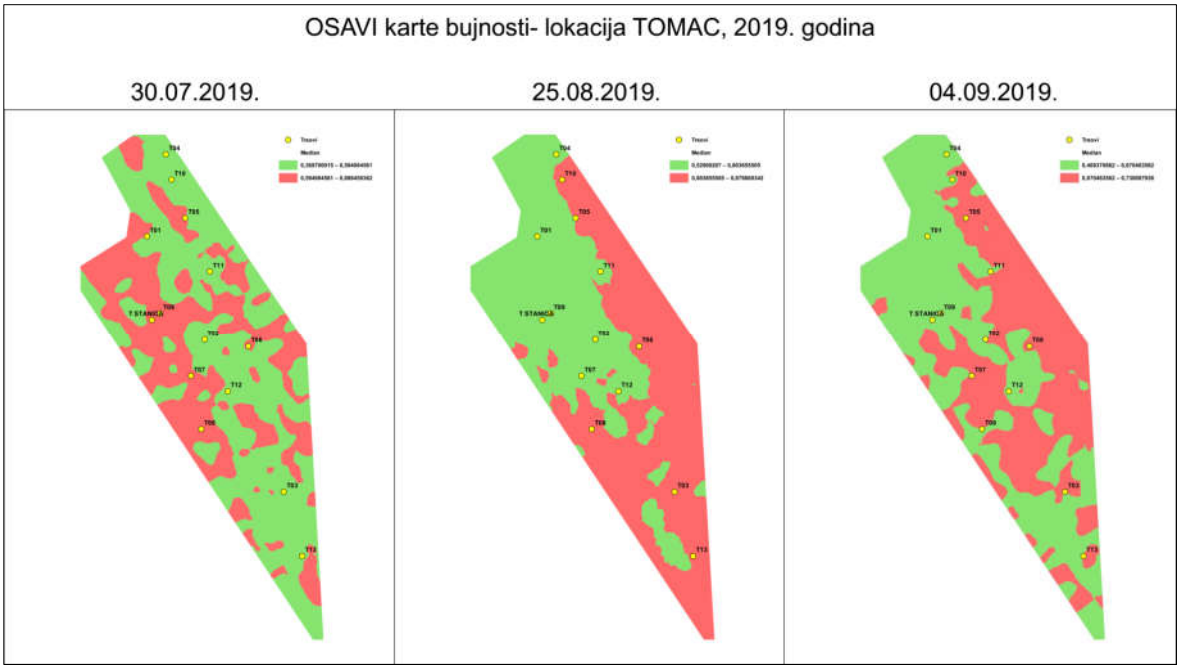

Slika 28. OSAVI generirane karte bujnosti- lokacija TOMAC u 2019. godini

4.3.1.2. Kvalitativno zoniranje na lokaciji TOMAC u 2019. godini

Prikupljeni podaci o kvalitativnim svojstvima grožđa sorte 'Pinot crni' (koncentracija šećera (°Oe), količina ukupnih kiselina (g/L) i pH vrijednost) na ciljanim trsovima (n=9) u 2019. godini podvrgnuti su postupku klasterizacije, koristeći *K means cluster* proceduru uz apriori zadani broj klastera koji iznosi dva. Na taj način dobivena su dva klastera koja se međusobno statistički značajno razlikuju prema koncentraciji šećera, količini ukupnih kiselina i pH vrijednosti, pri čemu su u prvom klasteru oni ciljani trsovi koji imaju veću koncentraciju šećera, manju količinu ukupnih kiselina i veću pH vrijednost, dok su u drugom klasteru oni ciljani trsovi koji imaju manju koncentraciju šećera, veću količinu ukupnih kiselina i manju pH vrijednost (tablica 28).

Tablica 28. Rezultat klasterizacije kvalitativnih svojstava grožđa sorte 'Pinot crni' na ciljanim trsovima (n=9) u 2019. godini na lokaciji TOMAC

Kvalitativna svojstva grožđa	***F*** $_{(1,7)}$	***Sig.***	**Prvi klaster (n=2)**	**Drugi klaster (n=7)**
			M ± SD	*M ± SD*
Koncentracija šećera (°Oe)	**8,365**	**0,023**	**91,00 ± 4,24**	**84,71 ± 2,36**
Ukupna kiselost (g/L)	**10,647**	**0,014**	**5,56 ± 0,55**	**6,83 ± 0,47**
pH vrijednost	**7,402**	**0,030**	**3,15 ± 0,02**	**3,09 ± 0,03**

Prema podacima iz tablice 28, trsovi iz prvog klastera (n=2) okarakterizirani su kao trsovi čije grožđe ima bolja kvalitativna svojstva, dok su oni iz drugog klastera (n=7) okarakterizirani kao trsovi čije grožđe ima lošija kvalitativna svojstva.

Kako bi se odredio najprediktivniji vegetacijski indeks s obzirom na kvalitativna svojstva grožđa, napravljena su preklapanja klasifikacijskih struktura: kvalitativne strukture trsova dobivene postupkom klasterizacije kvalitativnih svojstava grožđa s kvalitativnom strukturom trsova dobivenom na osnovu zoniranja uz pomoć vegetacijskih indeksa NDVI, NDRE i OSAVI na zone manje bujnosti (potencijalno bolja kvalitativna svojstva grožđa) i zone veće bujnosti (potencijalno lošija kvalitativna svojstva grožđa). Prema podacima iz tablice 29, može se zaključiti kako je **najprediktivniji vegetacijski indeks za kvalitativno zoniranje vinograda sorte 'Pinot crni' na lokaciji TOMAC u 2019. godini NDVI vegetacijski indeks s 89%-tnim preklapanjem kvalitativnih klasifikacijskih**

struktura u terminu snimanja u rujnu (4.9.), dok je najmanje prediktivan NDRE indeks u terminu snimanja u srpnju (30.7.).

Tablica 29. Preklapanja kvalitativnih klasifikacijskih struktura dobivenih klasterizacijom i zoniranjem pomoću vegetacijskih indeksa na ciljanim trsovima (n=9) sorte 'Pinot crni' u 2019. godini na lokaciji TOMAC

Vegetacijski indeks	**NDRE**			**NDVI**			**OSAVI**		
Termin snimanja	Srpanj (30.7.)	Kolovoz (25.8.)	Rujan (4.9.)	Srpanj (30.7.)	Kolovoz (25.8.)	**Rujan (4.9.)**	Srpanj (30.7.)	Kolovoz (25.8.)	Rujan (4.9.)
Broj podjednako klasificiranih trsova	4	7	7	7	6	**8**	6	6	6
Udio podjednako klasificiranih trsova	44%	78%	78%	78%	67%	**89%**	67%	67%	67%

Na temelju najprediktivnijeg vegetacijskog indeksa- NDVI u terminu snimanja u rujnu (4.9.), ciljani trsovi (n=9) klasificirani su u dvije zone bujnosti – zonu veće i zonu manje bujnosti (slika 29) te su u tablici 30 prikazani odabrani deskriptivni statistički pokazatelji kvalitativnih svojstava grožđa i sastavnica prinosa na devet ciljanih trsova sorte 'Pinot crni' u 2019. godini.

Slika 29. Generirana karta dviju zona bujnosti sorte 'Pinot crni' u 2019. godini na temelju najprediktivnijeg vegetacijskog indeksa NDVI u terminu snimanja u rujnu (4.9.) na lokaciji TOMAC s prikazom klasifikacije ciljanih trsova po zonama

Tablica 30. Odabrani deskriptivni statistički pokazatelji na ciljanim trsovima (n=9) sorte 'Pinot crni' u 2019. godini na lokaciji TOMAC klasificirani u dvije zone bujnosti na temelju NDVI indeksa iz rujna

Analizirane varijable	Trsovi iz zone veće bujnosti (n=6)	Trsovi iz zone manje bujnosti (n=3)
	M ± SD (CV)	*M ± SD (CV)*
Koncentracija šećera (°Oe)	**84,33 ± 2,34 (2,77)**	**89,67 ± 3,79 (4,22)**
Količina ukupnih kiselina (g/L)	**6,90 ± 0,49 (7,04)**	**5,86 ± 0,65 (11,01)**
pH vrijednost	3,09 ± 0,03 (0,90)	3,12 ± 0,04 (1,29)
Sadržaj ukupnog dušika u listu (% na bazi suhe tvari)	1,88 ± 0,15 (8,12)	1,72 ± 0,04 (2,53)
Broj grozdova	21,33 ± 5,54 (25,96)	15,00 ± 6,56 (43,71)
Prinos po trsu (kg)	**2,71 ± 0,61 (22,56)**	**1,56 ± 0,77 (49,32)**
Prosječna masa grozda (kg)	0,13 ± 0,02 (15,70)	0,10 ± 0,01 (14,51)
Masa orezane rozgve (kg)	0,34 ± 0,06 (18,04)	0,33 ± 0,04 (12,12)
Broj mladica	11,67 ± 1,37 (11,71)	12,00 ± 0,00 (0,00)
Broj nodija	12,83 ± 1,47 (11,47)	14,67 ± 2,08 (14,19)

Bilješka: M = prosječna vrijednost; SD = standardna devijacija, CV = koeficijent varijacija

Na temelju najprediktivnijeg vegetacijskog indeksa NDVI u terminu snimanja u rujnu (4.9.), testirana je statistička značajnost razlika u izmjerenim kvalitativnim svojstvima grožđa i sastavnicama prinosa između dviju zona- zone manje i zone veće bujnosti u prosječnim rezultatima na analiziranim varijablama. Analizirane varijable odnose se na: koncentraciju šećera (°Oe), količinu ukupnih kiselina (g/L), pH vrijednost, sadržaj ukupnog dušika u listu (% na bazi suhe tvari), broj mladica, broj nodija, prinos po trsu (kg), broj grozdova, prosječnu masa grozda (kg), masu orezane rozgve (kg) te utvrđeno je kako se **dvije zone bujnosti razlikuju statistički značajno u prosječnim rezultatima u koncentraciji šećera** (homogene varijance, $t_{(7)}=-2,667,\ p<0,05$), **količini ukupne kiseline** (homogene varijance, $t_{(7)}=2,739,\ p<0,05$) **te prinosu** (homogene varijance, $t_{(7)}=2,448,\ p<0,05$); pri čemu trsovi iz zone manje bujnosti imaju veću koncentraciju šećera (M±SD= 89,67±3,79), manju količinu ukupne kiseline (M±SD= 5,86±0,65) te manji prinos (M±SD= 1,56±0,77); dok trsovi iz zone veće bujnosti imaju manju koncentraciju šećera (M±SD= 84,33±2,34),

veću količinu ukupne kiseline (M±SD= 6,90±0,49) te veći prinos (M±SD= 2,71±0,61). Rezultati testiranja prikazani su u tablici 31.

Tablica 31. Rezultat testiranja statističke značajnosti razlika između zone veće i manje bujnosti dobivenih na temelju NDVI indeksa iz rujna u prosječnim rezultatima na analiziranim varijablama sorte 'Pinot crni' u 2019. godini na lokaciji TOMAC

Analizirane varijable	**Trsovi iz zone veće bujnosti (n=6)**	**Trsovi iz zone manje bujnosti (n=3)**	**Testiranje statističke značajnosti razlike u prosječnim rezultatima / rangovima**		
	Shapiro-Wilk	*Shapiro-Wilk*	*F*	*t* $_{(7)}$	*Mann-Whitney U*
Koncentracija šećera (°Oe)	**0,836**	**0,855**	**1,514**	**-2,667***	
Količina ukupnih kiselina (g/L)	**0,898**	**0,984**	**0,146**	**2,739***	
pH vrijednost	0,864	0,98	0,593	-1,401	
Sadržaj ukupnog dušika u listu (% na bazi suhe tvari)	0,863	0,842	4,395	1,725	
Broj grozdova	0,905	0,983	0,150	1,532	
Prinos po trsu (kg)	**0,860**	**0,896**	**0,184**	**2,448***	
Prosječna masa grozda (kg)	0,929	0,997	0,523	2,048	
Masa orezane rozgve (kg)	0,836	0,98	1,367	0,168	
Broj mladica	0,823	n/p			9,000
Broj nodija	0,958	0,923	0,520	-1,553	

Bilješka: Shapiro-Wilk = iznos Shapiro-Wilk testovnog statistika, F = iznos Leveneovog testovnog statistika za testiranje homogenosti varijanci; t $_{(df)}$ *= iznos t omjera s pripadnim stupnjevima slobode za testiranje statističke značajnosti razlike prosječnih rezultata; Mann-Whitney U = iznos Mann-Whitney U statistika za testiranje statističke značajnosti razlike rangova; *** p<0.001; ** p<0.01; * p<0.05*
n/p: Testovni statistik nije mogao biti izračunat s obzirom na to da sva tri trsa iz zone manje bujnosti imaju identičnu vrijednost broja mladica (12).

Dodatno je za najprediktivniji vegetacijski indeks- NDVI u terminu snimanja u rujnu (4.9.), izračunat i point biserijalni koeficijent korelacije (r_{pb}) s analiziranim varijablama koje ne odstupaju statistički značajno od normalne raspodjele te su rezultati prikazani u tablici 32. Iz rezultata je vidljivo kako je **koncentracija šećera statistički značajno pozitivno povezana s NDVI indeksom iz rujna, a količina ukupnih kiselina, prinos po trsu i**

Indeks Ravaz statistički su značajno negativno povezani s NDVI indeksom iz rujna, odnosno utvrđeno je da trsovi iz zone manje bujnosti imaju statistički značajno veću koncentraciju šećera, a trsovi iz zone veće bujnosti imaju statistički značajno veću količinu ukupnih kiselina, veći prinos po trsu i veći Indeks Ravaz na temelju NDVI indeksa iz rujna.

Tablica 32. Point biserijalni koeficijenti korelacije (r_{pb}) između vegetacijskog indeksa NDVI u terminu snimanja u rujnu i analiziranih varijabli na ciljanim trsovima (n=9) sorte 'Pinot crni' u 2019. godini na lokaciji TOMAC

Analizirane varijable	r_{pb} (NDVI rujan)
Koncentracija šećera	**0,71***
Količina ukupnih kiselina	**-0,72***
pH vrijednost	0,47
Sadržaj ukupnog dušika u listu	-0,55
Broj grozdova	-0,50
Prinos po trsu	**-0,68***
Prosječna masa grozda	-0,61
Masa orezane rozgve	-0,06
Broj nodija	0,51
Indeks Ravaz	**-0,83****

*Bilješka: *** p<0.001; ** p<0.01; * p<0.05*

Pokazatelji rodnosti

Rodni potencijal po trsu sorte 'Pinot crni' procijenjen je temeljem koeficijenata rodnosti za dvije zone- zonu manje i zonu veće bujnosti određene na temelju najprediktivnijeg vegetacijskog indeksa NDVI u terminu snimanja u rujnu (4.9.). Koeficijenti potencijalne i relativne rodnosti (KpR, KrR) te Indeks Ravaz prikazani su u tablici 33. Prosječan broj grozdova po pupu ostavljenih rezom (KpR) u zoni veće bujnosti iznosi 1,66 grozda dok u zoni manje bujnosti iznosi 1,02 što ukazuje na razliku u opterećenju između dviju zona bujnosti. Uobičajeno se rodnost procjenjuje na temelju Koeficijenta relativne rodnosti (KrR) odnosno broja grozdova po mladici te su ciljani trsovi sorte 'Pinot crni' iz različitih zona bujnosti pokazali i različite koeficijente. U zoni veće bujnosti trsovi su imali 1,83 grozdova po mladici te su svrstani u vrlo visoko rodne trsove (KrR > 1,5). Trsovi iz zone manje bujnosti imali su 1,25 grozdova po mladici te su svrstani u visoko rodne trsove (KrR do 1,5). Ravnoteža vegetativnog rasta i prinosa procjenjuje se uz pomoć Ravazovog indeksa kao omjera između prinosa i mase orezane rozgve, a vrijednosti indeksa između

5 i 10 govore o uravnoteženom vegetativnom rastu i prinosu trsa. Prema izračunatom Indeksu Ravaz ciljani trsovi iz zone manje bujnosti nalaze se ispod vrijednosti indeksa 5 i ukazuju na nešto nepovoljniji omjer vegetativnog rasta i prinosa (mali prinos u odnosu na vegetativni rast) dok trsovi iz veće zone bujnosti pokazuju uravnotežen vegetativni rast i prinos.

Tablica 33. Koeficijenti rodnosti i Indeks Ravaz za zonu manje i zonu veće bujnosti na temelju najprediktivnijeg vegetacijskog indeksa NDVI u terminu snimanja u rujnu (4.9.) na ciljanim trsovima (n=9) sorte 'Pinot crni' u 2019. godini na lokaciji TOMAC

	Trsovi iz zone veće bujnosti (n=6)	**Trsovi iz zone manje bujnosti (n=3)**
KpR	1,66	1,02
KrR	1,83	1,25
Indeks Ravaz	7,96	4,69

KpR - koeficijent potencijalne rodnosti; KrR - koeficijent relativne rodnosti

4.3.2. Rezultati istraživanja u 2020. godini

4.3.2.1. Generirane karte bujnosti na lokaciji TOMAC u 2020. godini

Na slici 30 prikazane su zone manje (zelena) i veće bujnosti (crvena) vinograda sorte 'Pinot crni' prema NDVI indeksu na lokaciji Tomac u tri termina snimanja u 2020. godini. Vrijednosti NDVI indeksa u prvom terminu snimanja (fenofaza 34) kreću se od 0,587-0,892 pri čemu medijan iznosi 0,819. U drugom terminu snimanja (fenofaza 36) vrijednosti NDVI indeksa kreću se od 0,595-0,892 pri čemu medijan iznosi 0,834. U trećem terminu snimanja (fenofaza 38) vrijednosti NDVI indeksa kreću se od 0,605-0,886 pri čemu medijan iznosi 0,823.

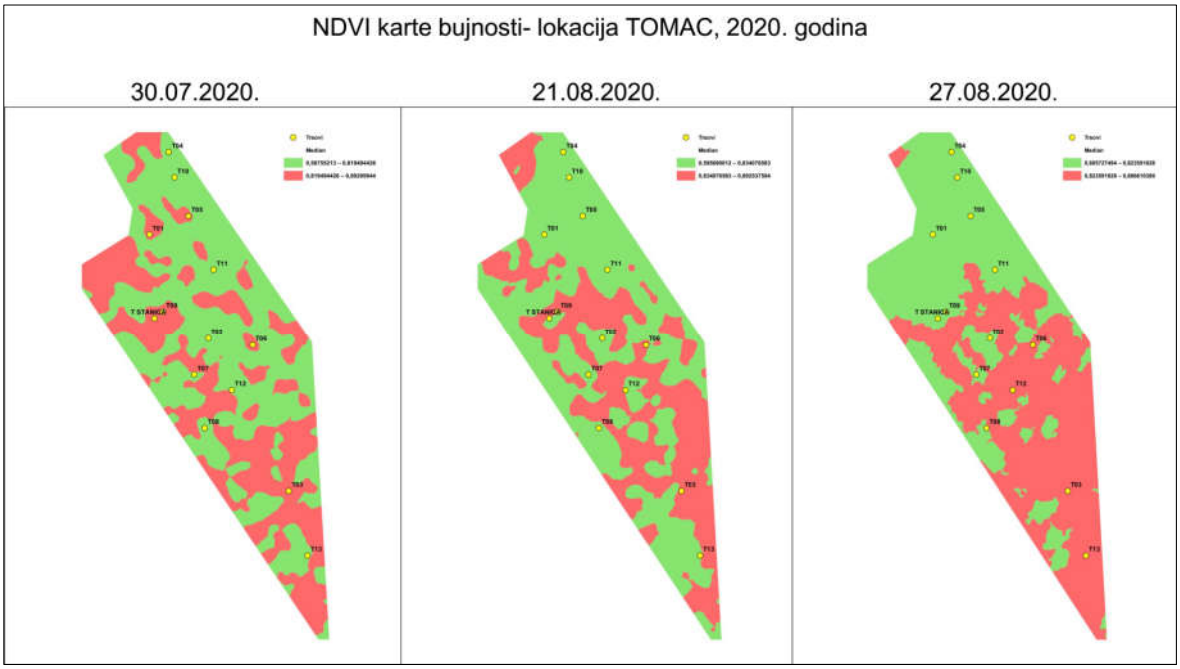

Slika 30. NDVI generirane karte bujnosti- lokacija TOMAC u 2020. godini

Na slici 31 prikazane su zone manje (zelena) i veće bujnosti (crvena) vinograda sorte 'Pinot crni' prema NDRE indeksu na lokaciji Tomac u tri termina snimanja u 2020. godini. Vrijednosti NDRE indeksa u prvom terminu snimanja (fenofaza 34) kreću se od 0,216-0,439 pri čemu medijan iznosi 0,337. U drugom terminu snimanja (fenofaza 36) vrijednosti NDRE indeksa kreću se od 0,259-0,432 pri čemu medijan iznosi 0,337. U trećem terminu snimanja (fenofaza 38) vrijednosti NDRE indeksa kreću se od 0,265-0,410 pri čemu medijan iznosi 0,340.

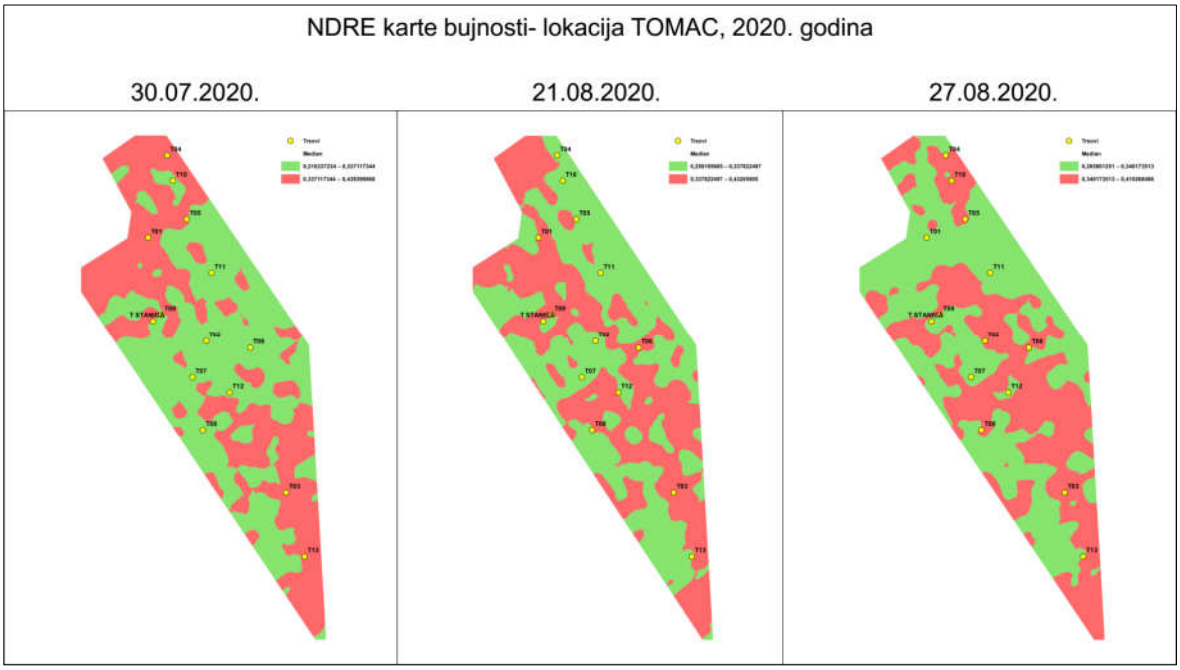

Slika 31. NDRE generirane karte bujnosti- lokacija TOMAC u 2020. godini

Na slici 32 prikazane su zone manje (zelena) i veće bujnosti (crvena) vinograda sorte 'Pinot crni' prema OSAVI indeksu na lokaciji Tomac u tri termina snimanja u 2020. godini. Vrijednosti OSAVI indeksa u prvom terminu snimanja (fenofaza 34) kreću se od 0,419-0,692 pri čemu medijan iznosi 0,578. U drugom terminu snimanja (fenofaza 36) vrijednosti OSAVI indeksa kreću se od 0,451-0,716 pri čemu medijan iznosi 0,589. U trećem terminu snimanja (fenofaza 38) vrijednosti OSAVI indeksa kreću se od 0,415-0,690 pri čemu medijan iznosi 0,565.

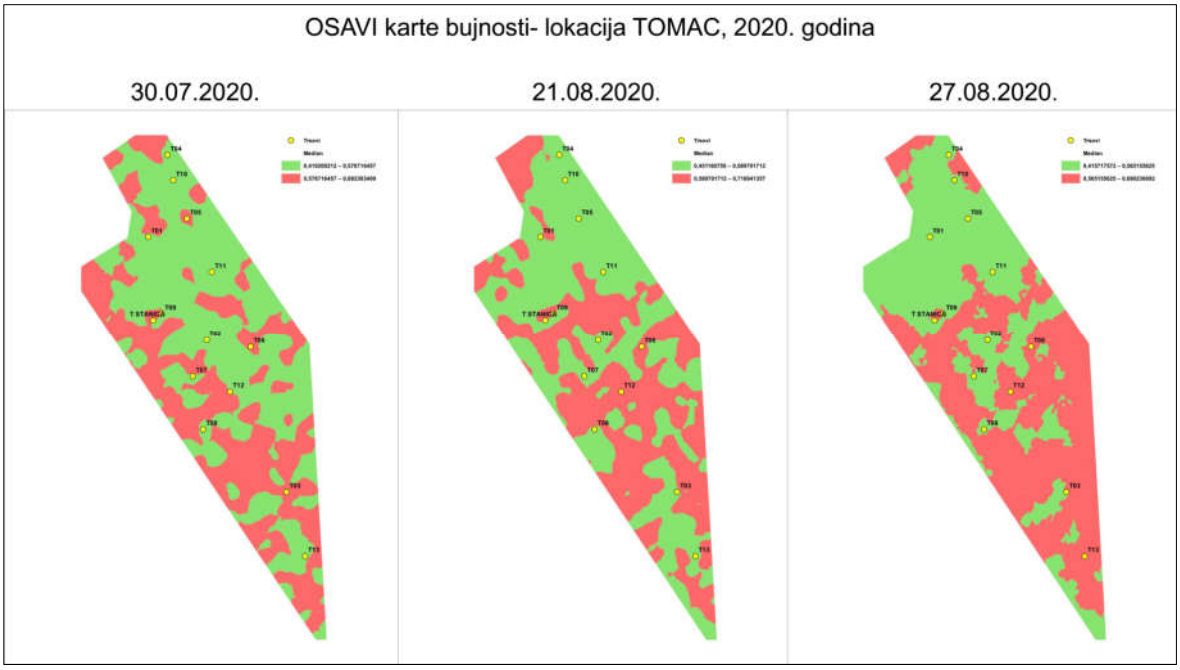

Slika 32. OSAVI generirane karte bujnosti- lokacija TOMAC u 2020. godini

4.3.2.2. Kvalitativno zoniranje na lokaciji TOMAC u 2020. godini

Prikupljeni podaci o kvalitativnim svojstvima grožđa sorte 'Pinot crni' (koncentracija šećera (°Oe), količina ukupnih kiselina (g/L) i pH vrijednost) na ciljanim trsovima (n=13) u 2020. godini podvrgnuti su postupku klasterizacije, koristeći *K means cluster* proceduru uz apriori zadani broj klastera koji iznosi dva. Na taj način dobivena su dva klastera koja se međusobno statistički značajno razlikuju prema koncentraciji šećera, pri čemu su u prvom klasteru oni ciljani trsovi koji imaju veću koncentraciju šećera, dok su u drugom klasteru oni ciljani trsovi koji imaju manju koncentraciju šećera (tablica 34).

Tablica 34. Rezultat klasterizacije kvalitativnih svojstava grožđa sorte 'Pinot crni' na ciljanim trsovima (n=13) u 2020. godini na lokaciji TOMAC

Kvalitativna svojstva grožđa	$F_{(1,11)}$	***Sig.***	**Prvi klaster (n=5)**	**Drugi klaster (n=8)**
			M ± SD	*M ± SD*
Koncentracija šećera (°Oe)	**13,162**	**0,004**	**88,00 ± 3,39**	**81,00 ± 3,38**
Ukupna kiselost (g/L)	3,703	0,081	6,86 ± 0,85	7,66 ± 0,65
pH vrijednost	1,776	0,210	3,09 ± 0,08	3,01 ± 0,11

Prema podacima iz tablice 34, trsovi iz prvog klastera (n=5) okarakterizirani su kao trsovi čije grožđe ima bolja kvalitativna svojstva, dok su oni iz drugog klastera (n=8) okarakterizirani kao trsovi čije grožđe ima lošija kvalitativna svojstva.

Kako bi se odredio najprediktivniji vegetacijski indeks s obzirom na kvalitativna svojstva grožđa, napravljena su preklapanja klasifikacijskih struktura: kvalitativne strukture trsova dobivene postupkom klasterizacije kvalitativnih svojstava grožđa s kvalitativnom strukturom trsova dobivenom na osnovu zoniranja uz pomoć vegetacijskih indeksa NDVI, NDRE i OSAVI na zone manje bujnosti (potencijalno bolja kvalitativna svojstva grožđa) i zone veće bujnosti (potencijalno lošija kvalitativna svojstva grožđa). Prema podacima iz tablice 35, može se zaključiti kako je **najprediktivniji vegetacijski indeks za kvalitativno zoniranje vinograda sorte 'Pinot crni' na lokaciji TOMAC u 2020. godini NDRE vegetacijski indeks s 85%-tnim preklapanjem kvalitativnih klasifikacijskih struktura u drugom terminu snimanja u kolovozu (27.8.)**, dok je najmanje prediktivan OSAVI indeks u prvom terminu snimanja u kolovozu (21.8.).

Tablica 35. Preklapanja kvalitativnih klasifikacijskih struktura dobivenih klasterizacijom i zoniranjem pomoću vegetacijskih indeksa na ciljanim trsovima (n=13) sorte 'Pinot crni' u 2020. godini na lokaciji TOMAC

Vegetacijski indeks	**NDRE**			**NDVI**			**OSAVI**		
Termin snimanja	Srpanj (30.7.)	Kolovoz I (21.8.)	**Kolovoz II (27.8.)**	Srpanj (30.7.)	Kolovoz I (21.8.)	Kolovoz II (27.8.)	Srpanj (30.7.)	Kolovoz I (21.8.)	Kolovoz II (27.8.)
Broj podjednako klasificiranih trsova	8	7	**11**	8	8	8	8	6	8
Udio podjednako klasificiranih trsova	62%	54%	**85%**	62%	62%	54%	62%	46%	62%

Na temelju najprediktivnijeg vegetacijskog indeksa- NDRE u drugom terminu snimanja u kolovozu (27.8.), ciljani trsovi (n=13) klasificirani su u dvije zone bujnosti – zonu veće i zonu manje bujnosti (slika 33) te su u tablici 36 prikazani odabrani deskriptivni statistički pokazatelji kvalitativnih svojstava grožđa i sastavnica prinosa na trinaest ciljanih trsova sorte 'Pinot crni' u 2020. godini.

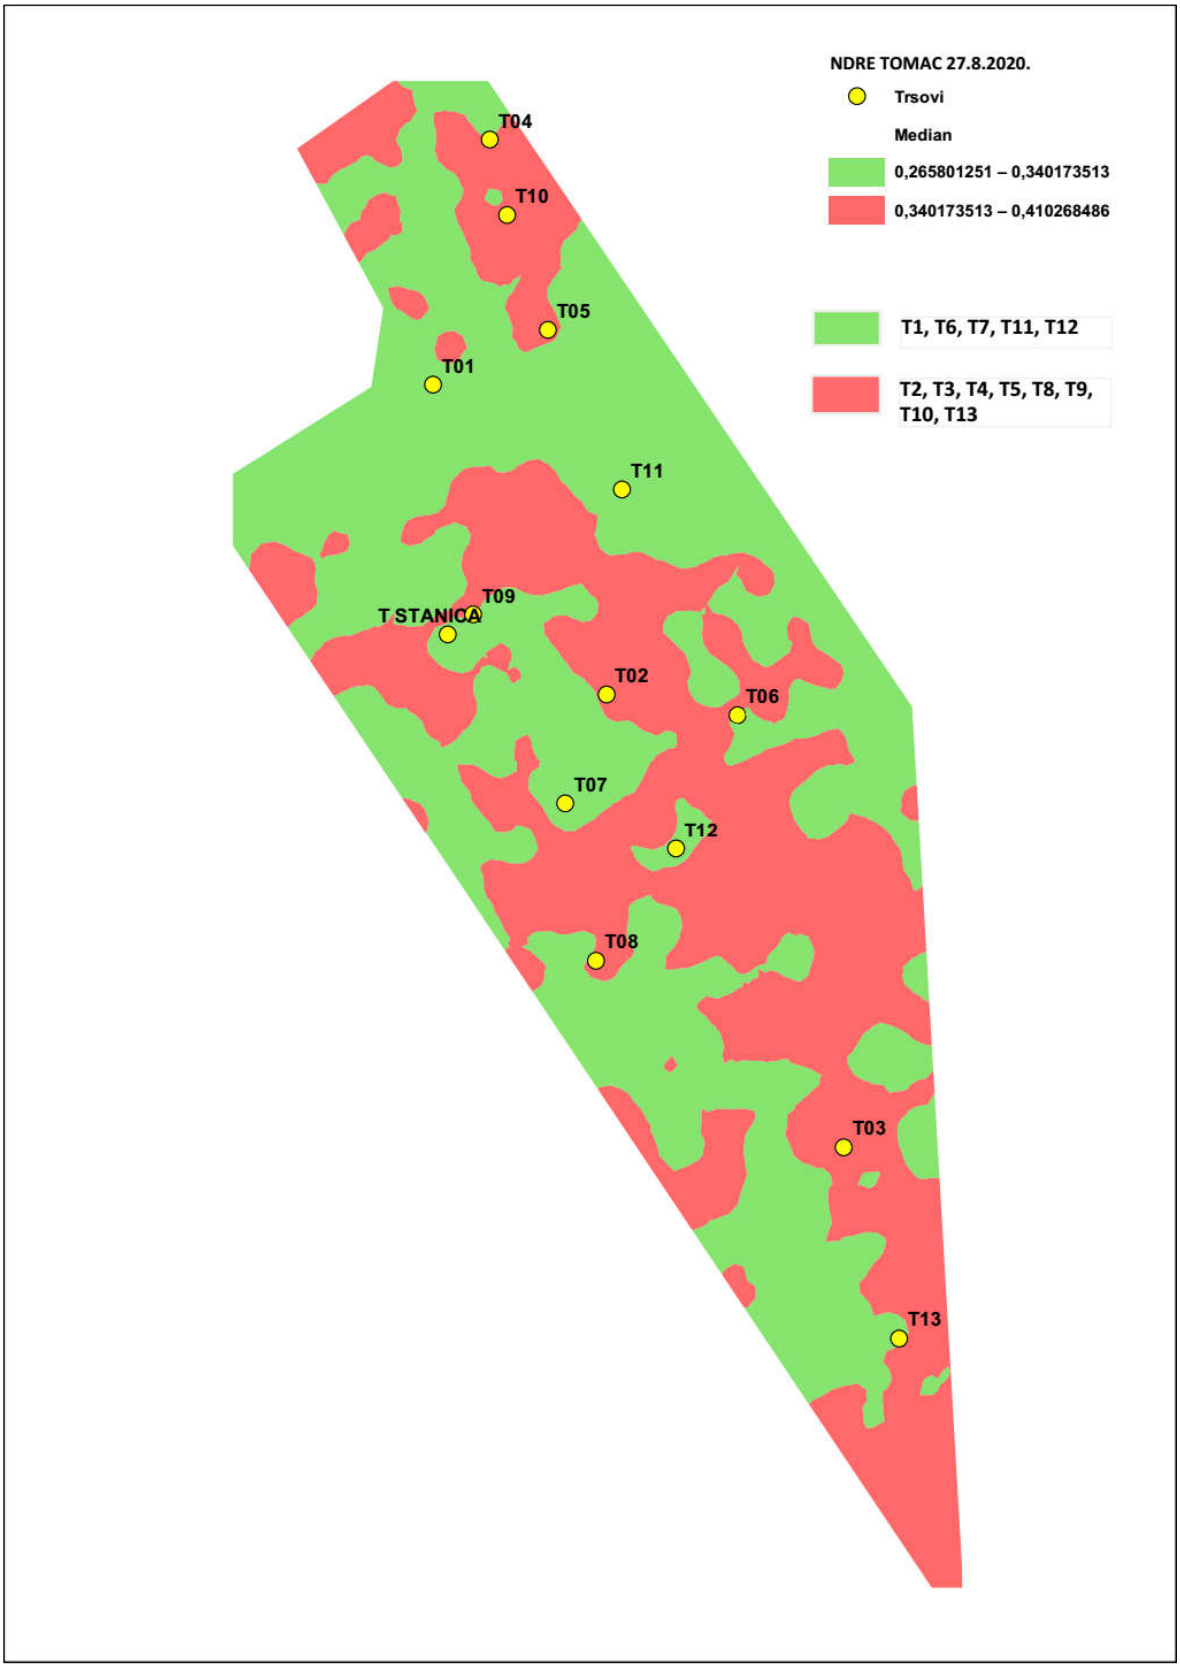

Slika 33. Generirana karta dviju zona bujnosti sorte 'Pinot crni' u 2020. godini na temelju najprediktivnijeg vegetacijskog indeksa NDRE u drugom terminu snimanja u kolovozu (27.8.) na lokaciji TOMAC s prikazom klasifikacije ciljanih trsova po zonama

Tablica 36. Odabrani deskriptivni statistički pokazatelji na ciljanim trsovima (n=13) sorte 'Pinot crni' u 2020. godini na lokaciji TOMAC klasificirani u dvije zone bujnosti na temelju NDRE indeksa iz drugog termina snimanja u kolovozu

Analizirane varijable	Trsovi iz zone veće bujnosti (n=8)	Trsovi iz zone manje bujnosti (n=5)
	M ± SD (CV)	*M ± SD (CV)*
Koncentracija šećera (°Oe)	**81,13 ± 3,52 (4,34)**	**87,80 ± 3,63 (4,14)**
Količina ukupnih kiselina (g/L)	**7,75 ± 0,62 (8,01)**	**6,73 ± 0,70 (10,40)**
pH vrijednost	3,03 ± 0,13 (4,19)	3,07 ± 0,07 (2,33)
Sadržaj ukupnog dušika u listu (% na bazi suhe tvari)	1,90 ± 0,10 (5,16)	1,84 ± 0,09 (4,75)
Broj grozdova	14,75 ± 6,63 (44,94)	13,40 ± 9,10 (67,90)
Prinos po trsu (kg)	2,06 ± 0,90 (43,94)	1,61 ± 1,15 (71,55)
Prosječna masa grozda (kg)	0,14 ± 0,01 (10,13)	0,12 ± 0,03 (24,31)
Broj mladica	10,38 ± 3,70 (35,66)	11,40 ± 3,44 (30,13)
Broj nodija	15,38 ± 3,25 (21,12)	18,60 ± 3,44 (18,47)

Bilješka: M = prosječna vrijednost; SD = standardna devijacija, CV = koeficijent varijacija

Na temelju najprediktivnijeg vegetacijskog indeksa NDRE u drugom terminu snimanja u kolovozu (27.8.), testirana je statistička značajnost razlika u izmjerenim kvalitativnim svojstvima grožđa i sastavnicama prinosa između dviju zona- zone manje i zone veće bujnosti u prosječnim rezultatima na analiziranim varijablama. Analizirane varijable odnose se na: koncentraciju šećera (°Oe), količinu ukupnih kiselina (g/L), pH vrijednost, sadržaj ukupnog dušika u listu (% na bazi suhe tvari), broj mladica, broj nodija, prinos po trsu (kg), broj grozdova, prosječnu masa grozda (kg), masu orezane rozgve (kg) te utvrđeno je kako se **dvije zone bujnosti razlikuju statistički značajno u prosječnim rezultatima u koncentraciji šećera** (homogene varijance, $t_{(11)}=-3,286,\ p<0,01$) te **količini ukupne kiseline** (homogene varijance, $t_{(11)}=2,749,\ p<0,05$) pri čemu trsovi iz zone manje bujnosti imaju veću koncentraciju šećera (M±SD= 87,80±3,63) i manju količinu ukupne kiseline (M±SD= 6,73±0,70) dok trsovi iz zone veće bujnosti imaju manju koncentraciju šećera (M±SD= 81,13±3,52) i veću količinu ukupne kiseline (M±SD= 7,75±0,62). Rezultati testiranja prikazani su u tablici 37.

Tablica 37. Rezultat testiranja statističke značajnosti razlika između zone veće i manje bujnosti dobivenih na temelju NDRE indeksa iz drugog termina snimanja u kolovozu u prosječnim rezultatima na analiziranim varijablama sorte 'Pinot crni' u 2020. godini na lokaciji TOMAC

Analizirane varijable	**Trsovi iz zone veće bujnosti (n=8)**	**Trsovi iz zone manje bujnosti (n=5)**	**Testiranje statističke značajnosti razlike u prosječnim rezultatima / rangovima**		
	Shapiro-Wilk	*Shapiro-Wilk*	*F*	*$t_{(11)}$*	*Mann-Whitney U*
Koncentracija šećera (°Oe)	**0,901**	**0,914**	**0,015**	**-3,286****	
Količina ukupnih kiselina (g/L)	**0,924**	**0,973**	**0,063**	**2,749***	
pH vrijednost	0,895	0,959	3,788	-0,750	
Sadržaj ukupnog dušika u listu (% na bazi suhe tvari)	0,932	0,958	0,073	0,998	
Broj grozdova	0,889	0,992	0,642	0,311	
Prinos po trsu (kg)	0,943	0,967	0,309	0,786	
Prosječna masa grozda (kg)	0,882	0,975	1,460	1,186	
Broj mladica	0,854	0,836	0,101	-0,499	
Broj nodija	0,927	0,902	0,043	-1,705	

*Bilješka: Shapiro-Wilk = iznos Shapiro-Wilk testovnog statistika, F = iznos Leveneovog testovnog statistika za testiranje homogenosti varijanci; $t_{(df)}$ = iznos t omjera s pripadnim stupnjevima slobode za testiranje statističke značajnosti razlike prosječnih rezultata; Mann-Whitney U = iznos Mann-Whitney U statistika za testiranje statističke značajnosti razlike rangova; *** p<0.001; ** p<0.01; *p<0.05*

Dodatno je za najprediktivniji vegetacijski indeks- NDRE u drugom terminu snimanja u kolovozu (27.8.), izračunat i point biserijalni koeficijent korelacije (r_{pb}) s analiziranim varijablama koje ne odstupaju statistički značajno od normalne raspodjele te su rezultati prikazani u tablici 38. Iz rezultata je vidljivo kako je **koncentracija šećera statistički značajno pozitivno povezana s NDRE indeksom iz drugog termina snimanja u kolovozu, a količina ukupnih kiselina statistički je značajno negativno povezana s NDRE indeksom iz drugog termina snimanja u kolovozu**, odnosno utvrđeno je da trsovi iz zone manje bujnosti imaju statistički značajno veću koncentraciju šećera, a trsovi iz zone veće bujnosti imaju statistički značajno veću količinu ukupnih kiselina na temelju NDRE indeksa iz drugog termina snimanja u kolovozu.

Tablica 38. Point biserijalni koeficijenti korelacije (r_{pb}) između vegetacijskog indeksa NDRE iz drugog termina snimanja u kolovozu i analiziranih varijabli na ciljanim trsovima (n=13) sorte 'Pinot crni' u 2020. godini na lokaciji TOMAC

Analizirane varijable	r_{pb} (NDRE kolovoz II)
Koncentracija šećera	**0,70****
Količina ukupnih kiselina	**-0,64***
pH vrijednost	0,22
Sadržaj ukupnog dušika u listu	-0,29
Broj grozdova	-0,09
Prinos po trsu	-0,23
Prosječna masa grozda	-0,34
Broj mladica	0,15
Broj nodija	0,46

*Bilješka: *** p<0.001; ** p<0.01; * p<0.05*

Pokazatelji rodnosti

Rodni potencijal po trsu sorte 'Pinot crni' procijenjen je temeljem koeficijenata rodnosti za dvije zone- zonu manje i zonu veće bujnosti određene na temelju najprediktivnijeg vegetacijskog indeksa NDRE u drugom terminu snimanja u kolovozu (27.8.). Koeficijenti potencijalne i relativne rodnosti (KpR, KrR) te Indeks Ravaz prikazani su u tablici 39. Prosječan broj grozdova po pupu ostavljenih rezom (KpR) za zonu veće bujnosti iznosi 0,96, a za zonu manje bujnosti iznosi 0,72 što ukazuje na razliku u opterećenju između dviju zona bujnosti. Uobičajeno se rodnost procjenjuje na temelju Koeficijenta relativne rodnosti (KrR) odnosno broja grozdova po mladici te su ciljani trsovi sorte 'Pinot crni' crni' iz različitih zona bujnosti pokazali i različite koeficijente. U zoni veće bujnosti trsovi su imali 1,42 grozda po mladici, dok su trsovi iz zone manje bujnosti imali 1,18 grozdova po mladici te su trsovi iz obje zone bujnosti svrstani u visoko rodne trsove (KrR do 1,5). Podaci za izračun Indeksa Ravaz nisu mogli biti prikupljeni na ciljanim trsovima zbog prijevremeno provedene zimske rezidbe od strane proizvođača.

Tablica 39. Koeficijenti rodnosti za zonu manje i zonu veće bujnosti na temelju najprediktivnijeg vegetacijskog indeksa NDRE u drugom terminu snimanja u kolovozu (27.8.) na ciljanim trsovima (n=13) sorte 'Pinot crni' u 2020. godini na lokaciji TOMAC

	Trsovi iz zone veće bujnosti (n=8)	**Trsovi iz zone manje bujnosti (n=5)**
KpR	0,96	0,72
KrR	1,42	1,18
Indeks Ravaz	-	-

KpR - koeficijent potencijalne rodnosti; KrR - koeficijent relativne rodnosti

4.4. 'Pinot crni' (*Vitis vinifera* L.) – lokacija ŠEMBER

4.4.1. Rezultati istraživanja u 2019. godini

4.4.1.1. Generirane karte bujnosti na lokaciji ŠEMBER u 2019. godini

Na slici 34 prikazane su zone manje (zelena) i veće bujnosti (crvena) vinograda sorte 'Pinot crni' prema NDVI indeksu na lokaciji Šember u tri termina snimanja u 2019. godini. Vrijednosti NDVI indeksa u prvom terminu snimanja (fenofaza 34) kreću se od 0,601-0,915 pri čemu medijan iznosi 0,856. U drugom terminu snimanja (fenofaza 36) vrijednosti NDVI indeksa kreću se od 0,804-0,932 pri čemu medijan iznosi 0,904. U trećem terminu snimanja (fenofaza 38) vrijednosti NDVI indeksa kreću se od 0,435-0,897 pri čemu medijan iznosi 0,797.

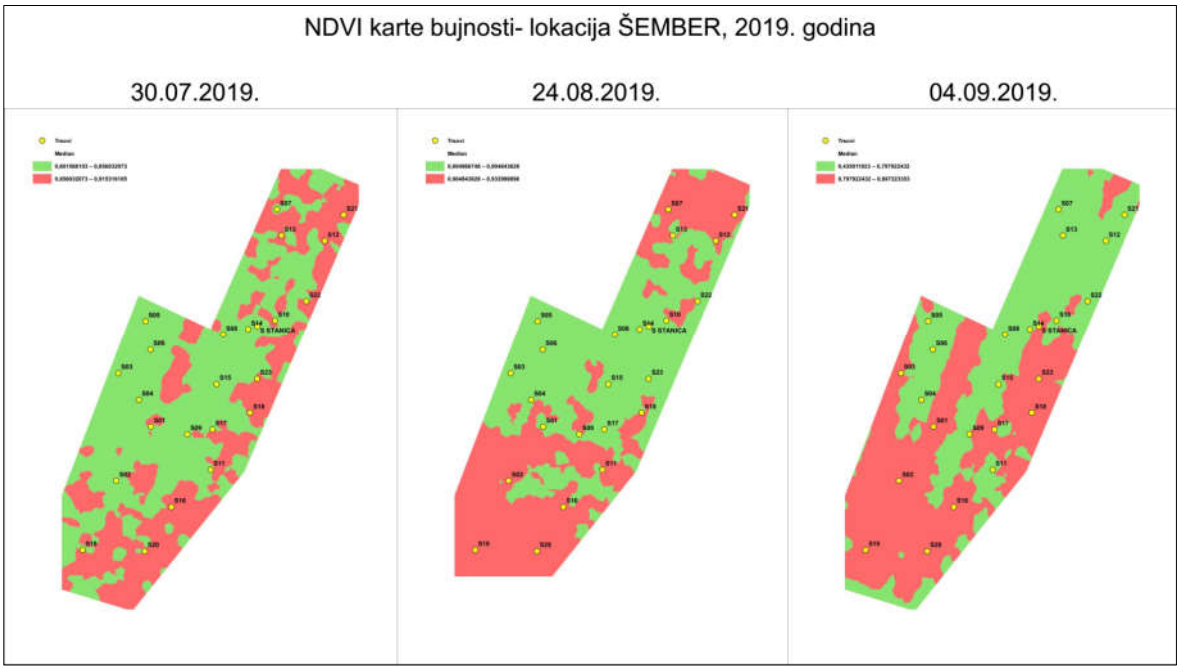

Slika 34. NDVI generirane karte bujnosti- lokacija ŠEMBER u 2019. godini

Na slici 35 prikazane su zone manje (zelena) i veće bujnosti (crvena) vinograda sorte 'Pinot crni' prema NDRE indeksu na lokaciji Šember u tri termina snimanja u 2019. godini. Vrijednosti NDRE indeksa u prvom terminu snimanja (fenofaza 34) kreću se od 0,249-0,455 pri čemu medijan iznosi 0,361. U drugom terminu snimanja (fenofaza 36) vrijednosti NDRE indeksa kreću se od 0,346-0,549 pri čemu medijan iznosi 0,457. U trećem terminu snimanja (fenofaza 38) vrijednosti NDRE indeksa kreću se od 0,263-0,502 pri čemu medijan iznosi 0,409.

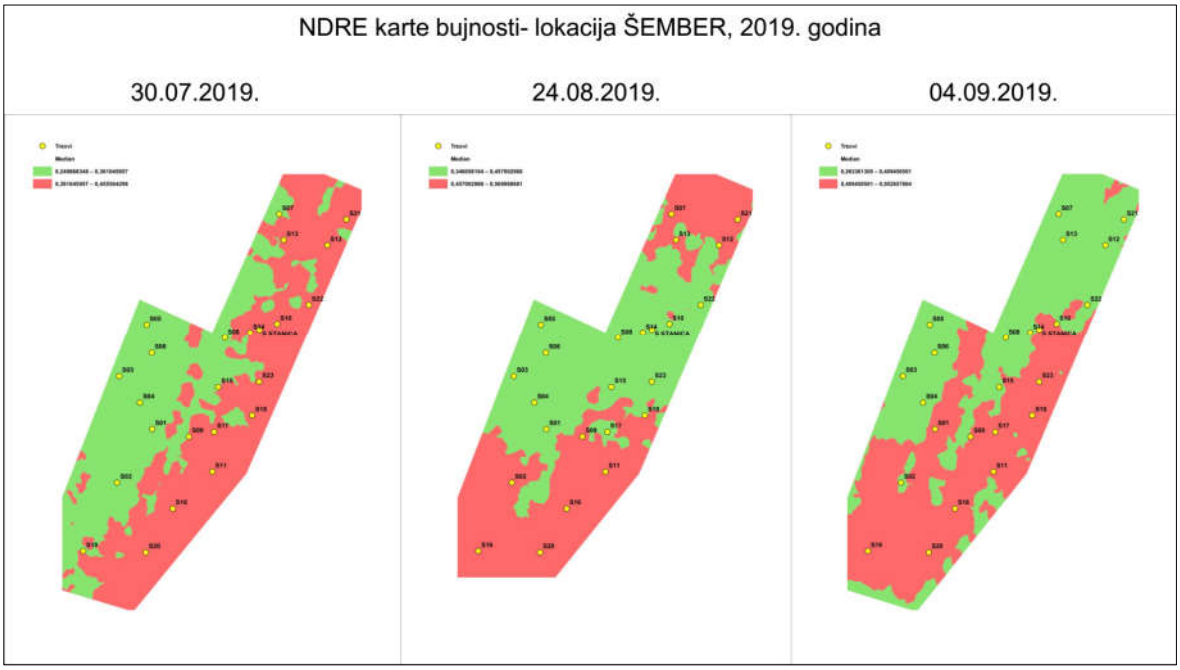

Slika 35. NDRE generirane karte bujnosti- lokacija ŠEMBER u 2019. godini

Na slici 36 prikazane su zone manje (zelena) i veće bujnosti (crvena) vinograda sorte 'Pinot crni' prema OSAVI indeksu na lokaciji Šember u tri termina snimanja u 2019. godini. Vrijednosti OSAVI indeksa u prvom terminu snimanja (fenofaza 34) kreću se od 0,423-0,730 pri čemu medijan iznosi 0,659. U drugom terminu snimanja (fenofaza 36) vrijednosti OSAVI indeksa kreću se od 0,542-0,699 pri čemu medijan iznosi 0,653. U trećem terminu snimanja (fenofaza 38) vrijednosti OSAVI indeksa kreću se od 0,362-0,684 pri čemu medijan iznosi 0,574.

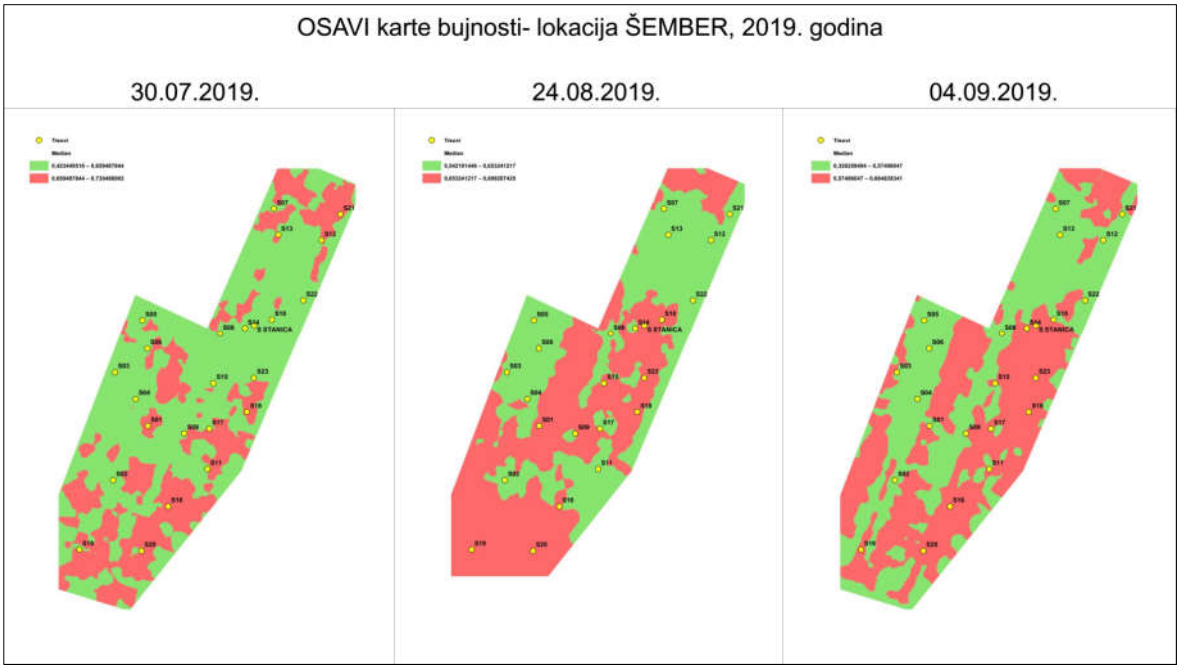

Slika 36. OSAVI generirane karte bujnosti- lokacija ŠEMBER u 2019. godini

4.4.1.2. Kvalitativno zoniranje na lokaciji ŠEMBER u 2019. godini

Prikupljanje podataka ručnim uzorkovanjem u 2019. godini zbog dostupnosti uzoraka grožđa provedeno je na 12 umjesto na 18 ciljanih trsova. Prikupljeni podaci o kvalitativnim svojstvima grožđa sorte 'Pinot crni' (koncentracija šećera (°Oe), količina ukupnih kiselina (g/L) i pH vrijednost) na ciljanim trsovima (n=12) u 2019. godini podvrgnuti su postupku klasterizacije, koristeći *K means cluster* proceduru uz apriori zadani broj klastera koji iznosi dva. Na taj način dobivena su dva klastera koja se međusobno statistički značajno razlikuju prema koncentraciji šećera, količini ukupnih kiselina i pH vrijednosti, pri čemu su u prvom klasteru oni ciljani trsovi koji imaju manju koncentraciju šećera, veću količinu ukupnih kiselina i manju pH vrijednost, dok su u drugom klasteru oni ciljani trsovi koji imaju veću koncentraciju šećera, manju količinu ukupnih kiselina i veću pH vrijednost (tablica 40).

Tablica 40. Rezultat klasterizacije kvalitativnih svojstava grožđa sorte 'Pinot crni' na ciljanim trsovima (n=12) u 2019. godini na lokaciji ŠEMBER

Kvalitativna svojstva grožđa	***F*** $_{(1,10)}$	***Sig.***	**Prvi klaster (n=4)**	**Drugi klaster (n=8)**
			M ± SD	*M ± SD*
Koncentracija šećera (°Oe)	**32,502**	**0,000**	**75,75 ± 2,22**	**84,63 ± 2,67**
Ukupna kiselost (g/L)	**10,146**	**0,010**	**9,84 ± 1,08**	**8,02 ± 0,86**
pH vrijednost	**26,378**	**0,000**	**2,93 ± 0,02**	**3,07 ± 0,05**

Prema podacima iz tablice 40, trsovi iz prvog klastera (n=4) okarakterizirani su kao trsovi čije grožđe ima lošija kvalitativna svojstva, dok su oni iz drugog klastera (n=8) okarakterizirani kao trsovi čije grožđe ima bolja kvalitativna svojstva.

Kako bi se odredio najprediktivniji vegetacijski indeks s obzirom na kvalitativna svojstva grožđa, napravljena su preklapanja klasifikacijskih struktura: kvalitativne strukture trsova dobivene postupkom klasterizacije kvalitativnih svojstava grožđa s kvalitativnom strukturom trsova dobivenom na osnovu zoniranja uz pomoć vegetacijskih indeksa NDVI, NDRE i OSAVI na zone manje bujnosti (potencijalno bolja kvalitativna svojstva grožđa) i zone veće bujnosti (potencijalno lošija kvalitativna svojstva grožđa). Prema podacima iz tablice 41, može se zaključiti kako je **najprediktivniji vegetacijski indeks za kvalitativno zoniranje vinograda sorte 'Pinot crni' na lokaciji ŠEMBER u 2019. godini**

NDRE vegetacijski indeks sa 75%-tnim preklapanjem kvalitativnih klasifikacijskih struktura u terminu snimanja u kolovozu (24.8.), dok je najmanje prediktivan OSAVI indeks u terminu snimanja u kolovozu (24.8.) i rujnu (4.9.).

Tablica 41. Preklapanja kvalitativnih klasifikacijskih struktura dobivenih klasterizacijom i zoniranjem pomoću vegetacijskih indeksa na ciljanim trsovima (n=12) sorte 'Pinot crni' u 2019. godini na lokaciji ŠEMBER

Vegetacijski indeks	**NDRE**			**NDVI**			**OSAVI**		
Termin snimanja	Srpanj (30.7.)	**Kolovoz (24.8.)**	Rujan (4.9.)	Srpanj (30.7.)	Kolovoz (24.8.)	Rujan (4.9.)	Srpanj (30.7.)	Kolovoz (24.8.)	Rujan (4.9.)
Broj podjednako klasificiranih trsova	7	**9**	6	8	7	6	8	5	5
Udio podjednako klasificiranih trsova	58%	**75%**	50%	67%	58%	50%	67%	42%	42%

Na temelju najprediktivnijeg vegetacijskog indeksa- NDRE u terminu snimanja u kolovozu (24.8.), ciljani trsovi (n=12) klasificirani su u dvije zone bujnosti – zonu veće i zonu manje bujnosti (slika 37) te su u tablici 42 prikazani odabrani deskriptivni statistički pokazatelji kvalitativnih svojstava grožđa i sastavnica prinosa na dvanaest ciljanih trsova sorte 'Pinot crni' u 2019. godini.

Slika 37. Generirana karta dviju zona bujnosti sorte 'Pinot crni' u 2019. godini na temelju najprediktivnijeg vegetacijskog indeksa NDRE u terminu snimanja u kolovozu (24.8.) na lokaciji ŠEMBER s prikazom klasifikacije ciljanih trsova po zonama

Tablica 42. Odabrani deskriptivni statistički pokazatelji na ciljanim trsovima (n=12) sorte 'Pinot crni' u 2019. godini na lokaciji ŠEMBER klasificirani u dvije zone bujnosti na temelju NDRE indeksa iz kolovoza

Analizirane varijable	Trsovi iz zone veće bujnosti (n=7)	Trsovi iz zone manje bujnosti (n=5)
	M ± SD (CV)	*M ± SD (CV)*
Koncentracija šećera (°Oe)	**78,29 ± 3,55 (4,53)**	**86,40 ± 1,34 (1,55)**
Količina ukupnih kiselina (g/L)	**9,32 ± 1,07 (11,49)**	**7,66 ± 0,83 (10,89)**
pH vrijednost	**2,98 ± 0,07 (2,20)**	**3,08 ± 0,06 (2,07)**
Sadržaj ukupnog dušika u listu (% na bazi suhe tvari)	**2,21 ± 0,12 (5,28)**	**2,01 ± 0,10 (4,94)**
Broj grozdova	22,71 ± 6,65 (29,29)	20,00 ± 5,15 (25,74)
Prinos po trsu (kg)	2,74 ± 1,19 (43,50)	2,65 ± 0,30 (11,19)
Prosječna masa grozda (kg)	0,13 ± 0,05 (41,39)	0,14 ± 0,02 (16,86)
Masa orezane rozgve (kg)	0,47 ± 0,09 (19,34)	0,38 ± 0,15 (39,28)
Broj mladica	12,29 ± 1,38 (11,23)	10,60 ± 3,05 (28,77)
Broj nodija	12,57 ± 1,40 (11,11)	11,80 ± 2,17 (18,37)

Bilješka: M = prosječna vrijednost; SD = standardna devijacija, CV = koeficijent varijacija

Na temelju najprediktivnijeg vegetacijskog indeksa NDRE u terminu snimanja u kolovozu (24.8.), testirana je statistička značajnost razlika u izmjerenim kvalitativnim svojstvima grožđa i sastavnicama prinosa između dviju zona- zone manje i zone veće bujnosti u prosječnim rezultatima na analiziranim varijablama. Analizirane varijable odnose se na: koncentraciju šećera (°Oe), količinu ukupnih kiselina (g/L), pH vrijednost, sadržaj ukupnog dušika u listu (% na bazi suhe tvari), broj mladica, broj nodija, prinos po trsu (kg), broj grozdova, prosječnu masa grozda (kg), masu orezane rozgve (kg) te utvrđeno je kako se dvije zone **bujnosti razlikuju statistički značajno u prosječnim rezultatima u koncentraciji šećera** (Mann-Whitney U= *0,000, p<0,01*), **količini ukupne kiseline** (homogene varijance, $t_{(10)}$*=2,872, p<0,05*), **pH vrijednosti** (Mann-Whitney U= *3,000, p<0,05)* te **sadržaju ukupnog dušika u listu** (homogene varijance, $t_{(10)}$*=3,009, p<0,05*); pri čemu trsovi iz zone manje bujnosti imaju veću koncentraciju šećera (M±SD= 86,40±1,34), manju količinu ukupne kiseline (M±SD= 7,66±0,83), veću pH vrijednost (M±SD= 3,08±0,06) te manji sadržaj ukupnog dušika u listu (M±SD= 2,01±0,10), dok

trsovi iz zone veće bujnosti imaju manju koncentraciju šećera (M±SD= 76,14±8,44), veću količinu ukupne kiseline (M±SD= 9,32±1,07), manju pH vrijednost (M±SD= 2,98±0,07) te veći sadržaj ukupnog dušika u listu (M±SD= 2,21±0,12). Rezultati testiranja prikazani su u tablici 43.

Tablica 43. Rezultat testiranja statističke značajnosti razlika između zone veće i manje bujnosti dobivenih na temelju NDRE indeksa iz kolovoza u prosječnim rezultatima na analiziranim varijablama sorte 'Pinot crni' u 2019. godini na lokaciji ŠEMBER

Analizirane varijable	**Trsovi iz zone veće bujnosti (n=7)**	**Trsovi iz zone manje bujnosti (n=5)**	**Testiranje statističke značajnosti razlike u prosječnim rezultatima / rangovima**		
	Shapiro-Wilk	*Shapiro-Wilk*	*F*	*t (10)*	*Mann-Whitney U*
Koncentracija šećera (°Oe)	**0,912**	**0,552*****			**0,000****
Količina ukupnih kiselina (g/L)	**0,934**	**0,914**	**0,115**	**2,872***	
pH vrijednost	**0,805***	**0,818**			**3,000***
Sadržaj ukupnog dušika u listu (% na bazi suhe tvari)	**0,926**	**0,843**	**0,278**	**3,009***	
Broj grozdova	0,868	0,960	1,508	0,761	
Prinos po trsu (kg)	0,950	0,912	3,659	0,170	
Prosječna masa grozda (kg)	0,924	0,907	1,298	-0,360	
Masa orezane rozgve (kg)	0,921	0,895	2,558	1,252	
Broj mladica	0,918	0,848	5,907*	$t_{(5)}$=1,154	
Broj nodija	0,896	0,871	3,102	0,754	

*Bilješka: Shapiro-Wilk = iznos Shapiro-Wilk testovnog statistika, F = iznos Leveneovog testovnog statistika za testiranje homogenosti varijanci; $t_{(df)}$ = iznos t omjera s pripadnim stupnjevima slobode za testiranje statističke značajnosti razlike prosječnih rezultata; Mann-Whitney U = iznos Mann-Whitney U statistika za testiranje statističke značajnosti razlike rangova; *** p<0.001; ** p<0.01; *p<0.05*

Dodatno je za najprediktivniji vegetacijski indeks- NDRE u terminu snimanja u kolovozu (24.8.), izračunat i point biserijalni koeficijent korelacije (r_{pb}) s analiziranim varijablama koje ne odstupaju statistički značajno od normalne raspodjele te su rezultati prikazani u tablici 44. Iz rezultata je vidljivo kako su **količina ukupnih kiselina i sadržaj ukupnog**

dušika u listu statistički značajno negativno povezani s NDRE indeksom iz kolovoza, odnosno utvrđeno je da trsovi iz zone veće bujnosti imaju statistički značajno veću količinu ukupnih kiselina i veći sadržaj ukupnog dušika u listu na temelju NDRE indeksa iz kolovoza.

Tablica 44. Point biserijalni koeficijenti korelacije (r_{pb}) između vegetacijskog indeksa NDRE u terminu snimanja u kolovozu i analiziranih varijabli na ciljanim trsovima (n=12) sorte 'Pinot crni' u 2019. godini na lokaciji ŠEMBER

Analizirane varijable	r_{pb} (NDRE kolovoz)
Količina ukupnih kiselina	**-0,67***
Sadržaj ukupnog dušika u listu	**-0,69***
Broj grozdova	-0,23
Prinos po trsu	-0,05
Prosječna masa grozda	0,11
Masa rozgve	-0,37
Broj mladica	-0,38
Broj nodija	-0,23
Indeks Ravaz	-0,29

*Bilješka: *** p<0.001; ** p<0.01; * p<0.05*

Pokazatelji rodnosti

Rodni potencijal po trsu sorte 'Pinot crni' procijenjen je temeljem koeficijenata rodnosti za dvije zone- zonu manje i zonu veće bujnosti određene na temelju najprediktivnijeg vegetacijskog indeksa NDRE u terminu snimanja u kolovozu (24.8.). Koeficijenti potencijalne i relativne rodnosti (KpR, KrR) te Indeks Ravaz prikazani su u tablici 45. Prosječan broj grozdova po pupu ostavljenih rezom (KpR) za zonu veće bujnosti iznosi 1,81, a za zonu manje bujnosti iznosi 1,69 što čini prilično veliko opterećenje po trsu. No uobičajeno se rodnost procjenjuje na temelju Koeficijenta relativne rodnosti (KrR) odnosno broja grozdova po mladici te su ciljani trsovi sorte 'Pinot crni' iz obje zone bujnosti imali 1,8 grozdova po mladici te su svrstani u vrlo visoko rodne trsove (KrR > 1,5). Ravnoteža vegetativnog rasta i prinosa procjenjuje se uz pomoć Ravazovog indeksa kao omjera između prinosa i mase orezane rozgve, a vrijednosti indeksa između 5 i 10 govore o uravnoteženom vegetativnom rastu i prinosu trsa. Prema izračunatom Indeksu Ravaz ciljani trsovi iz obje zone bujnosti pokazuju uravnotežen vegetativni rast i prinos.

Tablica 45. Koeficijenti rodnosti i Indeks Ravaz za zonu manje i zonu veće bujnosti na temelju najprediktivnijeg vegetacijskog indeksa NDRE u terminu snimanja u kolovozu (24.8.). na ciljanim trsovima (n=12) sorte 'Pinot crni' u 2019. godini na lokaciji ŠEMBER

	Trsovi iz zone veće bujnosti (n=7)	**Trsovi iz zone manje bujnosti (n=5)**
KpR	1,81	1,69
KrR	1,85	1,89
Indeks Ravaz	5,85	6,93

KpR - koeficijent potencijalne rodnosti; KrR - koeficijent relativne rodnosti

4.4.2. Rezultati istraživanja u 2020. godini

4.4.2.1. Generirane karte bujnosti na lokaciji ŠEMBER u 2020. godini

Na slici 38 prikazane su zone manje (zelena) i veće bujnosti (crvena) vinograda sorte 'Pinot crni' prema NDVI indeksu na lokaciji Šember u tri termina snimanja u 2020. godini. Vrijednosti NDVI indeksa u prvom terminu snimanja (fenofaza 34) kreću se od 0,725-0,932 pri čemu medijan iznosi 0,891. U drugom terminu snimanja (fenofaza 36) vrijednosti NDVI indeksa kreću se od 0,526-0,908 pri čemu medijan iznosi 0,837. U trećem terminu snimanja (fenofaza 38) vrijednosti NDVI indeksa kreću se od 0,483-0,883 pri čemu medijan iznosi 0,789.

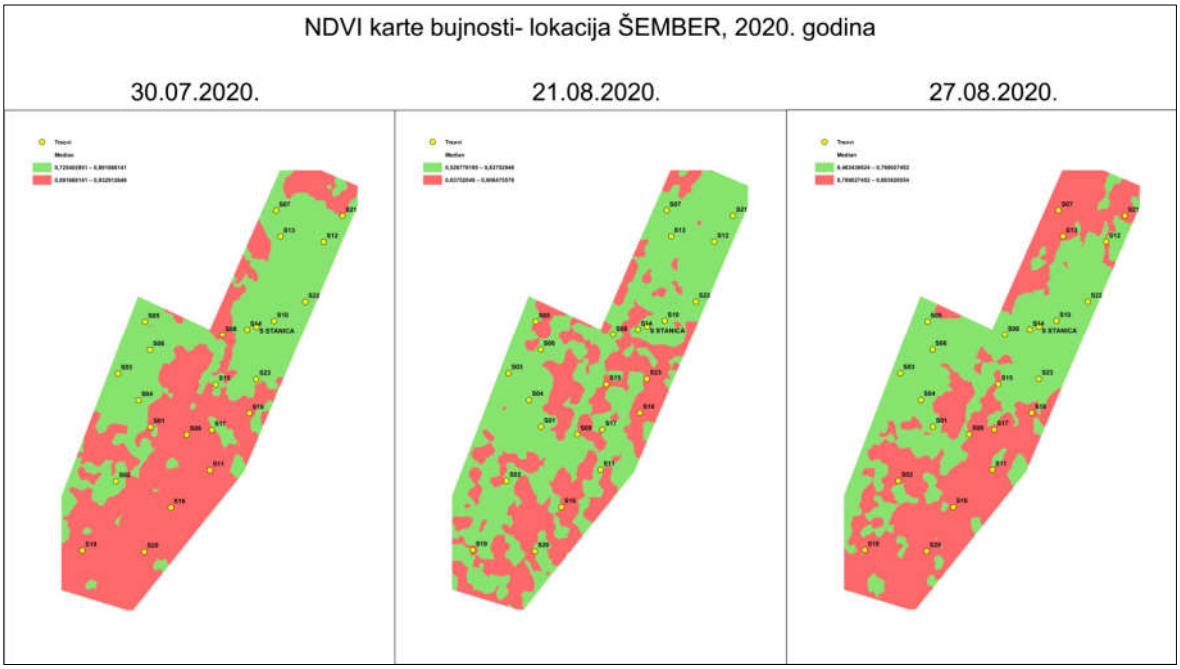

Slika 38. NDVI generirane karte bujnosti- lokacija ŠEMBER u 2020. godini

Na slici 39 prikazane su zone manje (zelena) i veće bujnosti (crvena) vinograda sorte 'Pinot crni' prema NDRE indeksu na lokaciji Šember u tri termina snimanja u 2020. godini. Vrijednosti NDRE indeksa u prvom terminu snimanja (fenofaza 34) kreću se od 0,316-0,484 pri čemu medijan iznosi 0,418. U drugom terminu snimanja (fenofaza 36) vrijednosti NDRE indeksa kreću se od 0,236-0,477 pri čemu medijan iznosi 0,391. U trećem terminu snimanja (fenofaza 38) vrijednosti NDRE indeksa kreću se od 0,226-0,448 pri čemu medijan iznosi 0,368.

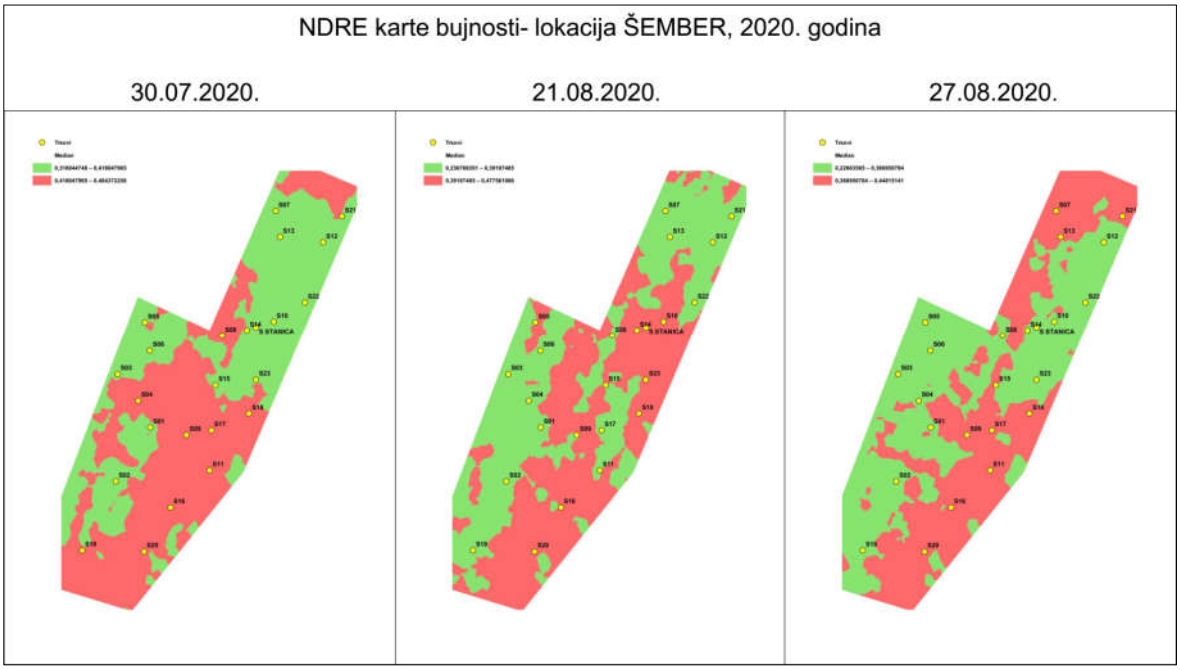

Slika 39. NDRE generirane karte bujnosti- lokacija ŠEMBER u 2020. godini

Na slici 40 prikazane su zone manje (zelena) i veće bujnosti (crvena) vinograda sorte 'Pinot crni' prema OSAVI indeksu na lokaciji Šember u tri termina snimanja u 2020. godini. Vrijednosti OSAVI indeksa u prvom terminu snimanja (fenofaza 34) kreću se od 0,423-0,668 pri čemu medijan iznosi 0,582. U drugom terminu snimanja (fenofaza 36) vrijednosti OSAVI indeksa kreću se od 0,400-0,700 pri čemu medijan iznosi 0,610. U trećem terminu snimanja (fenofaza 38) vrijednosti OSAVI indeksa kreću se od 0,353-0,677 pri čemu medijan iznosi 0,570.

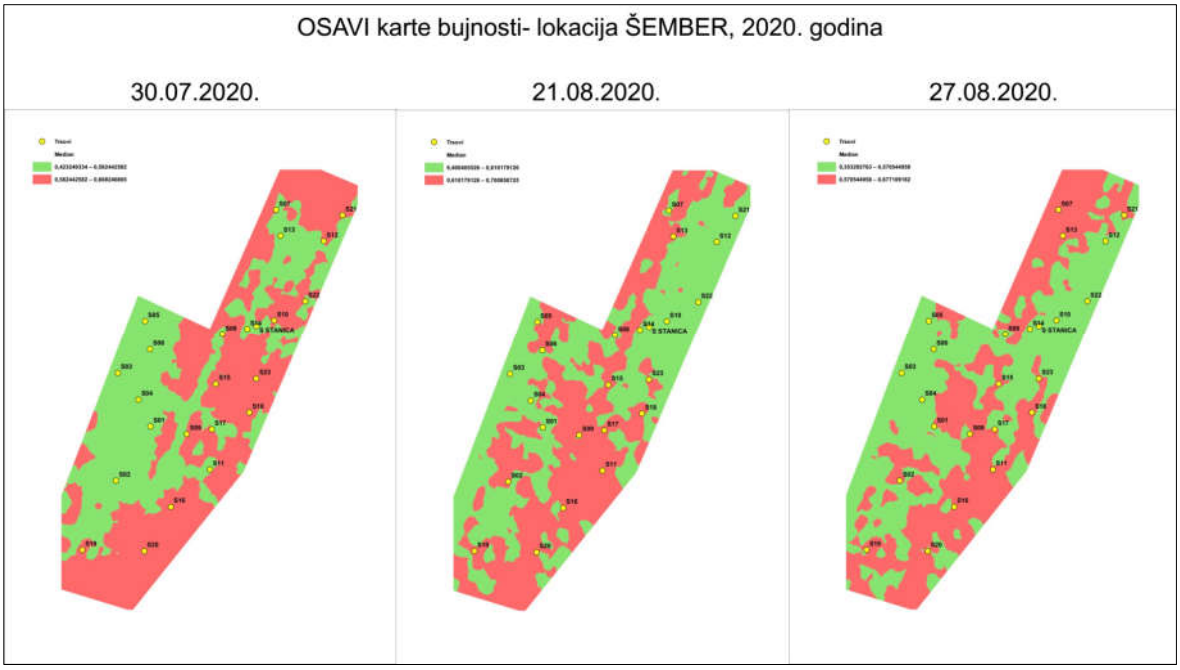

Slika 40. OSAVI generirane karte bujnosti- lokacija ŠEMBER u 2020. godini

4.4.2.2. Kvalitativno zoniranje na lokaciji ŠEMBER u 2020. godini

Prikupljanje podataka ručnim uzorkovanjem u 2020. godini zbog dostupnosti uzoraka grožđa provedeno je na 22 umjesto na 23 ciljana trsa. Prikupljeni podaci o kvalitativnim svojstvima grožđa sorte 'Pinot crni' (koncentracija šećera (°Oe), količina ukupnih kiselina (g/L) i pH vrijednost) na ciljanim trsovima (n=22) u 2020. godini podvrgnuti su postupku klasterizacije, koristeći *K means cluster* proceduru uz apriori zadani broj klastera koji iznosi dva. Na taj način dobivena su dva klastera koja se međusobno statistički značajno razlikuju prema koncentraciji šećera i pH vrijednosti, pri čemu su u prvom klasteru oni ciljani trsovi koji imaju manju koncentraciju šećera i manju pH vrijednost, dok su u drugom klasteru oni ciljani trsovi koji imaju veću koncentraciju šećera i veću pH vrijednost (tablica 46).

Tablica 46. Rezultat klasterizacije kvalitativnih svojstava grožđa sorte 'Pinot crni' na ciljanim trsovima (n=22) u 2020. godini na lokaciji ŠEMBER

Kvalitativna svojstva grožđa	***F*** $_{(1,20)}$	***Sig.***	**Prvi klaster (n=13)**	**Drugi klaster (n=9)**
			M ± SD	*M ± SD*
Koncentracija šećera (°Oe)	**40,046**	**0,000**	**84,15 ± 3,02**	**94,22 ± 4,47**
Ukupna kiselost (g/L)	4,063	0,057	7,69 ± 1,84	6,27 ± 1,23
pH vrijednost	**8,492**	**0,009**	**3,07 ± 0,11**	**3,21 ± 0,11**

Prema podacima iz tablice 46, trsovi iz prvog klastera (n=13) okarakterizirani su kao trsovi čije grožđe ima lošija kvalitativna svojstva, dok su oni iz drugog klastera (n=9) okarakterizirani kao trsovi čije grožđe ima bolja kvalitativna svojstva.

Kako bi se odredio najprediktivniji vegetacijski indeks s obzirom na kvalitativna svojstva grožđa, napravljena su preklapanja klasifikacijskih struktura: kvalitativne strukture trsova dobivene postupkom klasterizacije kvalitativnih svojstava grožđa s kvalitativnom strukturom trsova dobivenom na osnovu zoniranja uz pomoć vegetacijskih indeksa NDVI, NDRE i OSAVI na zone manje bujnosti (potencijalno bolja kvalitativna svojstva grožđa) i zone veće bujnosti (potencijalno lošija kvalitativna svojstva grožđa). Prema podacima iz tablice 47, može se zaključiti kako je **najprediktivniji vegetacijski indeks za kvalitativno zoniranje vinograda sorte 'Pinot crni' na lokaciji ŠEMBER u 2020. godini NDVI vegetacijski indeks s 86%-tnim preklapanjem kvalitativnih klasifikacijskih**

struktura u terminu snimanja u srpnju (30.7.), dok su najmanje prediktivni NDRE i NDVI indeksi u oba termina snimanja u kolovozu (21.8; 27.8.).

Tablica 47. Preklapanja kvalitativnih klasifikacijskih struktura dobivenih klasterizacijom i zoniranjem pomoću vegetacijskih indeksa na ciljanim trsovima (n=22) sorte 'Pinot crni' u 2020. godini na lokaciji ŠEMBER

Vegetacijski indeks	**NDRE**			**NDVI**			**OSAVI**		
Termin snimanja	Srpanj (30.7.)	Kolovoz I (21.8.)	Kolovoz II (27.8.)	**Srpanj (30.7.)**	Kolovoz I (21.8.)	Kolovoz II (27.8.)	Srpanj (30.7.)	Kolovoz I (21.8.)	Kolovoz II (27.8.)
Broj podjednako klasificiranih trsova	16	15	15	**19**	15	15	17	16	16
Udio podjednako klasificiranih trsova	73%	68%	68%	**86%**	68%	68%	77%	73%	73%

Na temelju najprediktivnijeg vegetacijskog indeksa- NDVI u terminu snimanja u srpnju (30.7.), ciljani trsovi (n=22) klasificirani su u dvije zone bujnosti – zonu veće i zonu manje bujnosti (slika 41) te su u tablici 48 prikazani odabrani deskriptivni statistički pokazatelji kvalitativnih svojstava grožđa i sastavnica prinosa na dvadeset dva ciljana trsa sorte 'Pinot crni' u 2020. godini.

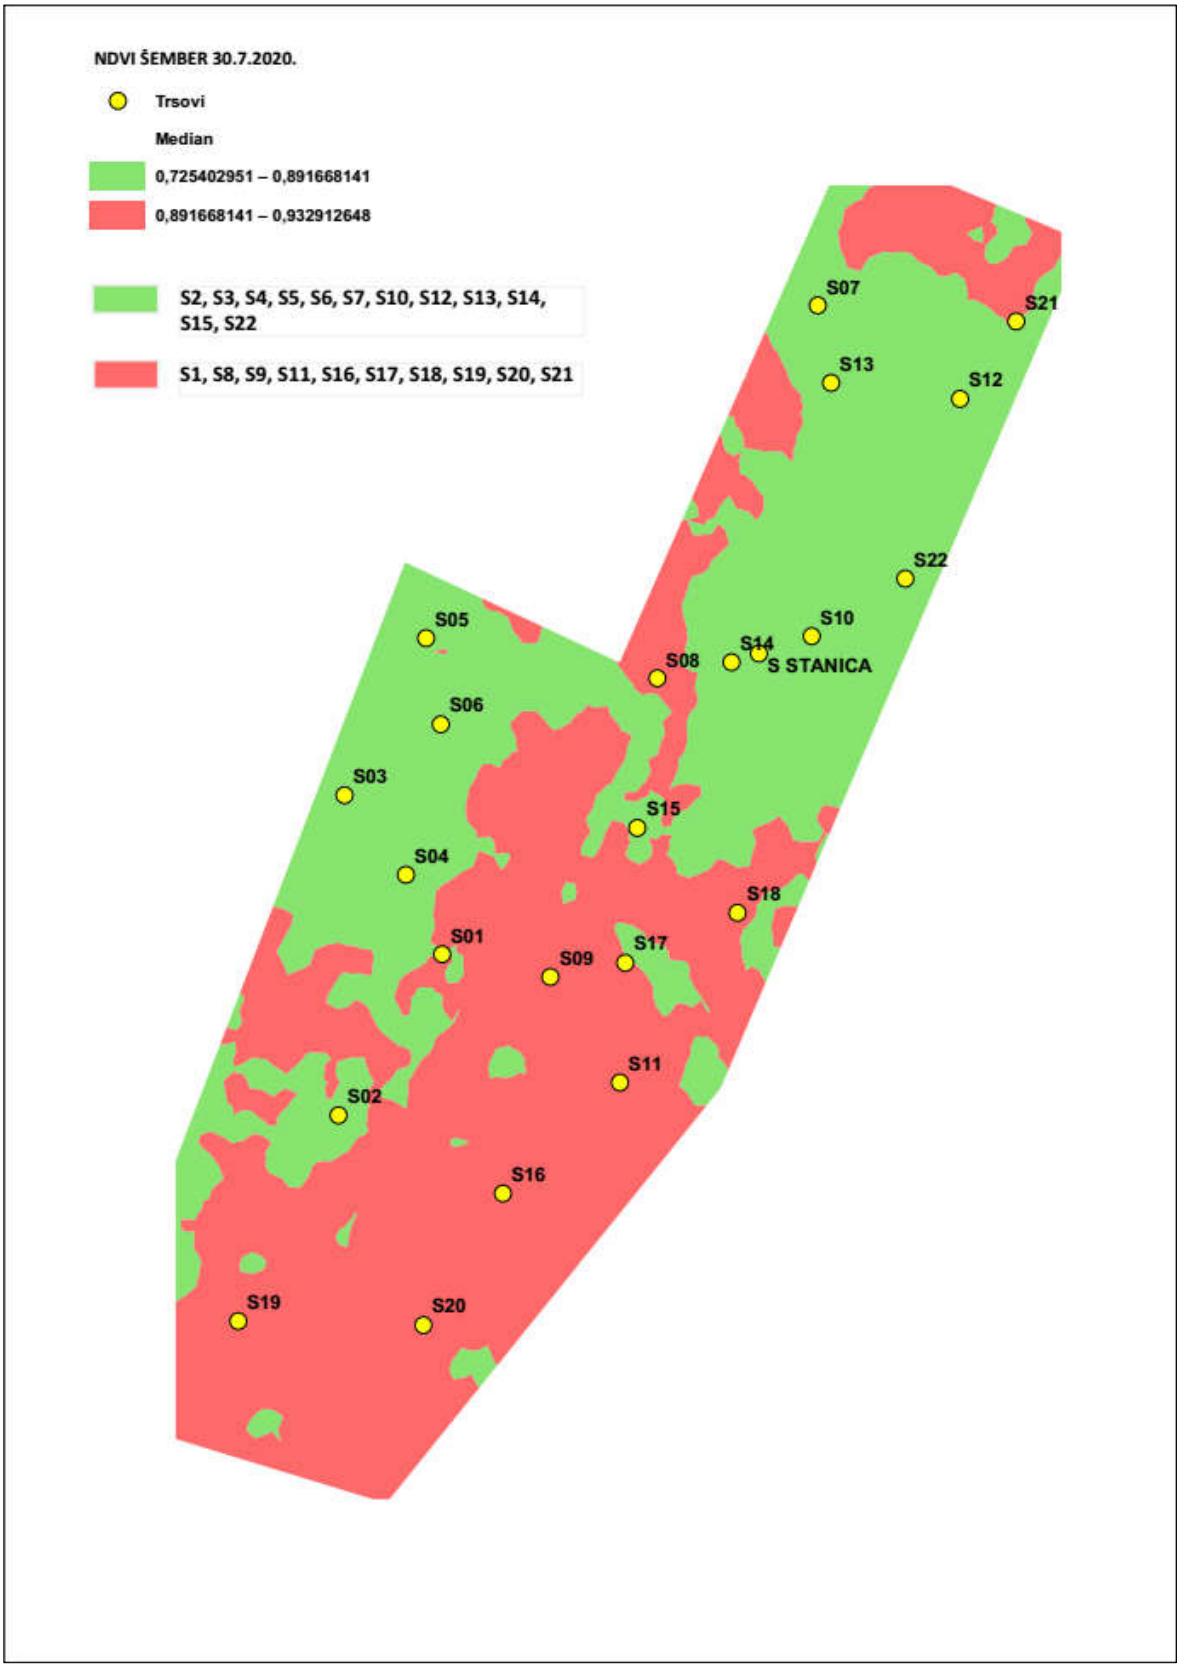

Slika 41. Generirana karta dviju zona bujnosti sorte 'Pinot crni' u 2020. godini na temelju najprediktivnijeg vegetacijskog indeksa NDVI u terminu snimanja u srpnju (30.7.) na lokaciji ŠEMBER s prikazom klasifikacije ciljanih trsova po zonama

Tablica 48. Odabrani deskriptivni statistički pokazatelji na ciljanim trsovima (n=22) sorte 'Pinot crni' u 2020. godini na lokaciji ŠEMBER klasificirani u dvije zone bujnosti na temelju NDVI indeksa iz srpnja

Analizirane varijable	Trsovi iz zone veće bujnosti (n=10)	Trsovi iz zone manje bujnosti (n=12)
	M ± SD (CV)	*M ± SD (CV)*
Koncentracija šećera (°Oe)	**83,40 ± 3,06 (3,67)**	**92,33 ± 5,12 (5,55)**
Količina ukupnih kiselina (g/L)	**8,05 ± 1,93 (23,93)**	**6,33 ± 1,12 (17,78)**
pH vrijednost	**3,05 ± 0,11 (3,54)**	**3,19 ± 0,11 (3,31)**
Sadržaj ukupnog dušika u listu (% na bazi suhe tvari)	**1,98 ± 0,10 (4,99)**	**1,86 ± 0,10 (5,14)**
Broj grozdova	19,00 ± 7,33 (38,59)	16,25 ± 4,39 (27,03)
Prinos po trsu (kg)	2,62 ± 1,05 (40,14)	2,14 ± 0,69 (32,22)
Prosječna masa grozda	0,14 ± 0,02 (11,89)	0,13 ± 0,04 (29,15)
Masa orezane rozgve	0,45 ± 0,13 (30,12)	0,38 ± 0,10 (27,07)
Broj mladica	11,80 ± 3,26 (27,62)	12,25 ± 1,60 (13,09)
Broj nodija	15,60 ± 2,01 (12,89)	14,50 ± 1,45 (9,97)

Bilješka: M = prosječna vrijednost; SD = standardna devijacija, CV = koeficijent varijacija

Na temelju najprediktivnijeg vegetacijskog indeksa NDVI u terminu snimanja u srpnju (30.7.), testirana je statistička značajnost razlika u izmjerenim kvalitativnim svojstvima grožđa i sastavnicama prinosa između dviju zona- zone manje i zone veće bujnosti u prosječnim rezultatima na analiziranim varijablama. Analizirane varijable odnose se na: koncentraciju šećera (°Oe), količinu ukupnih kiselina (g/L), pH vrijednost, sadržaj ukupnog dušika u listu (% na bazi suhe tvari), broj mladica, broj nodija, prinos po trsu (kg), broj grozdova, prosječnu masa grozda (kg), masu orezane rozgve (kg) te utvrđeno je kako se dvije zone bujnosti **razlikuju statistički značajno u prosječnim rezultatima u koncentraciji šećera** (homogene varijance, $t_{(20)}=-4,831$, $p<0,001$), **količini ukupne kiseline** (Mann-Whitney U= *19,000, p<0,01)*, **pH vrijednosti** (homogene varijance, $t_{(20)}=3,136$, $p<0,01$) te **sadržaju ukupnog dušika u listu** (homogene varijance, $t_{(20)}=2,914$, $p<0,01$); pri čemu trsovi iz zone manje bujnosti imaju veću koncentraciju šećera (M±SD= 92,33±5,12), manju količinu ukupne kiseline (M±SD= 6,33±1,12), veću pH vrijednost (M±SD= 3,19±0,11) te manji sadržaj ukupnog dušika u listu (M±SD= 1,86±0,10), dok

trsovi iz zone veće bujnosti imaju manju koncentraciju šećera (M±SD= 83,40±3,06), veću količinu ukupne kiseline (M±SD= 8,05±1,93), manju pH vrijednost (M±SD= 3,05±0,11) te veći sadržaj ukupnog dušika u listu (M±SD= 1,98±0,10). Rezultati testiranja prikazani su u tablici 49.

Tablica 49. Rezultat testiranja statističke značajnosti razlika između zone veće i manje bujnosti dobivenih na temelju NDVI indeksa iz srpnja u prosječnim rezultatima na analiziranim varijablama sorte 'Pinot crni' u 2020. godini na lokaciji ŠEMBER

Analizirane varijable	**Trsovi iz zone veće bujnosti (n=10)**	**Trsovi iz zone manje bujnosti (n=12)**	**Testiranje statističke značajnosti razlike u prosječnim rezultatima / rangovima**		
	Shapiro-Wilk	*Shapiro-Wilk*	*F*	*t* $_{(20)}$	*Mann-Whitney U*
Koncentracija šećera	**0,974**	**0,925**	**2,532**	**-4,831*****	
Količina ukupnih kiselina	**0,768****	**0,840***			**19,000****
pH vrijednost	**0,921**	**0,957**	**0,034**	**-3,136****	
Sadržaj ukupnog dušika u listu	**0,978**	**0,903**	**0,053**	**2,914****	
Broj grozdova	0,952	0,959	4,779*	$t_{(14)}$ = 1,040	
Prinos po trsu	0,971	0,965	2,330	1,292	
Prosječna masa grozda	0,985	0,939	5,968*	$t_{(15)}$ = 0,316	
Masa orezane rozgve	0,763**	0,941			41,500
Broj mladica	0,91	0,895	1,263	-0,422	
Broj nodija	0,915	0,969	2,477	1,491	

*Bilješka: Shapiro-Wilk = iznos Shapiro-Wilk testovnog statistika, F = iznos Leveneovog testovnog statistika za testiranje homogenosti varijanci; $t_{(df)}$ = iznos t omjera s pripadnim stupnjevima slobode za testiranje statističke značajnosti razlike prosječnih rezultata; Mann-Whitney U = iznos Mann-Whitney U statistika za testiranje statističke značajnosti razlike rangova; *** p<0.001; ** p<0.01; *p<0.05*

Dodatno je za najprediktivniji vegetacijski indeks- NDVI u terminu snimanja u srpnju (30.7.), izračunat i point biserijalni koeficijent korelacije (r_{pb}) s analiziranim varijablama koje ne odstupaju statistički značajno od normalne raspodjele te su rezultati prikazani u tablici 50. Iz rezultata je vidljivo kako su **koncentracija šećera i pH vrijednost statistički značajno pozitivno povezane s NDVI indeksom iz srpnja, a sadržaj ukupnog dušika u listu statistički je značajno negativno povezana s NDVI indeksom iz srpnja**,

odnosno utvrđeno je da trsovi iz zone manje bujnosti imaju statistički značajno veću koncentraciju šećera i pH vrijednost, a trsovi iz zone veće bujnosti imaju statistički značajno veći sadržaj ukupnog dušika u listu na temelju NDVI indeksa iz srpnja.

Tablica 50. Point biserijalni koeficijenti korelacije (r_{pb}) između vegetacijskog indeksa NDVI u terminu snimanja u srpnju i analiziranih varijabli na ciljanim trsovima (n=22) sorte 'Pinot crni' u 2020. godini na lokaciji ŠEMBER

Analizirane varijable	r_{pb} (NDVI srpanj)
Koncentracija šećera	**0,73*** **
pH vrijednost	**0,57** **
Sadržaj ukupnog dušika u listu	**-0,55** **
Broj grozdova	-0,24
Prinos po trsu	-0,28
Prosječna masa grozda	-0,07
Broj mladica	0,09
Broj nodija	-0,32
Indeks Ravaz	-0,11

*Bilješka: *** p<0.001; ** p<0.01; * p<0.05*

Pokazatelji rodnosti

Rodni potencijal po trsu sorte 'Pinot crni' procijenjen je temeljem koeficijenata rodnosti za dvije zone- zonu manje i zonu veće bujnosti određene na temelju najprediktivnijeg vegetacijskog indeksa NDVI u terminu snimanja u srpnju (30.7.). Koeficijenti potencijalne i relativne rodnosti (KpR, KrR) te Indeks Ravaz prikazani su u tablici 51. Prosječan broj grozdova po pupu ostavljenih rezom (KpR) za zonu veće i manje bujnosti je podjednak (1,22; 1,12). No uobičajeno se rodnost procjenjuje na temelju Koeficijenta relativne rodnosti (KrR) odnosno broja grozdova po mladici. U zoni veće bujnosti trsovi su imali 1,61 grozdova po mladici te su svrstani u vrlo visoko rodne trsove (KrR > 1,5). Trsovi iz zone manje bujnosti imali su 1,33 grozdova po mladici te su svrstani u visoko rodne trsove (KrR do 1,5). Ravnoteža vegetativnog rasta i prinosa procjenjuje se uz pomoć Ravazovog indeksa kao omjera između prinosa i mase orezane rozgve, a vrijednosti indeksa između 5 i 10 govore o uravnoteženom vegetativnom rastu i prinosu trsa. Prema izračunatom Indeksu Ravaz ciljani trsovi iz obje zone bujnosti pokazuju uravnotežen vegetativni rast i prinos iako se izračunate vrijednosti nalaze blizu donje granice vrijednosti indeksa.

Tablica 51. Koeficijenti rodnosti i Indeks Ravaz za zonu manje i zonu veće bujnosti na temelju najprediktivnijeg vegetacijskog indeksa NDVI u terminu snimanja u srpnju (30.7.), na ciljanim trsovima (n=22) sorte 'Pinot crni' u 2020. godini na lokaciji ŠEMBER

	Trsovi iz zone veće bujnosti (n=10)	**Trsovi iz zone manje bujnosti (n=12)**
KpR	1,22	1,12
KrR	1,61	1,33
Indeks Ravaz	5,87	5,65

KpR - koeficijent potencijalne rodnosti; KrR - koeficijent relativne rodnosti

4.5. Rezultati procjene ekonomske opravdanosti kvalitativnog zoniranja i selektivne berbe

4.5.1. Rezultati analize troškova kvalitativnog zoniranja i selektivne berbe

Cilj ovog istraživanja bio je utvrditi troškove koji imaju direktan utjecaj na kvalitativno zoniranje i selektivnu berbu kao što su trošak investicije u opremu, prikupljanje, pripremu i obradu podataka te sam trošak selektivne berbe, odnosno, u obzir nisu uzeti troškovi koji se odnose na sve uobičajene radne operacije u vinogradarskoj proizvodnji, nego isključivo na operacije snimanja bespilotnim letjelicama, kvalitativno zoniranje i selektivnu berbu. Podaci su prikupljeni istraživanjem tržišta, realni su i aktualni. Svi navedeni podaci o troškovima korišteni su za izračun ekonomske opravdanosti kvalitativnog zoniranja i selektivne berbe, zajedno s rezultatima analize tržišne cijene grožđa i vina te sa stvarnim prinosima i kvalitativnim parametrima izmjerenim na sve četiri lokacije- KOS, PUHELEK-PUREK, TOMAC i ŠEMBER.

Troškovi su podijeljeni na fiksne i varijabilne troškove pri čemu su svi varijabilni troškovi standardizirani na površinu 1ha, što je u izračunima ekonomske opravdanosti za pojedinu lokaciju u istraživanju prilagođeno stvarnoj površini vinograda na toj lokaciji.

U strukturi fiksnih troškova (tablica 52) vidljivo je da je najveće ulaganje nabava bespilotne letjelice i prateće opreme te osiguranje bespilotne letjelice koji čine 55% vrijednosti ulaganja. Slijedi nabava programskog paketa za obradu multispektralnih snimaka i prikupljenih podataka sa 21,7% vrijednosti ulaganja, dok 10,9% ulaganja čini nabava računala pogodnog za procesuiranje i obradu velike količine podataka. Nužne edukacije koje su potrebne za upravljanje bespilotnim letjelicama te edukacija za obradu prikupljenih podataka čine 12,4% vrijednosti ulaganja. Ukupno ulaganje od 92.200,00 kn predstavlja ulaganje proizvođača u osnovnu opremu i vlastitu edukaciju potrebnu za provedbu kvalitativnog zoniranja svojih vinogradarskih površina.

Tablica 52. Fiksni troškovi kvalitativnog zoniranja- nabava opreme

R.br.	Opis troška	Cijena (HRK)	Udjel (%)
1.	Nabava bespilotne letjelice		
	Bespilotna letjelica DJI Phantom 4 Multispectral[2]	42.000,00	45,5
	Dodatna baterija[2]	1.250,00	1,4
2.	Računalo za obradu podataka[3]	10.000,00	10,9
3.	Programski paket za obradu podataka (software) Pix4D[4]	20.000,00	21,7
4.	DPO Crew obuka za pilota drona- trodnevna[2]	3.950,00	4,3
5.	Edukacija za obradu podataka (Pix4D fields)[5]	7.500,00	8,1
6.	Osiguranje bespilotne letjelice[6]	7.500,00	8,1
7.	**UKUPNO**	**92.200,00**	**100,00**

Varijabilni troškovi podijeljeni su na varijabilne troškove koje nastaju kada proizvođač odluči sam nabaviti opremu te sam provoditi kvalitativno zoniranje i selektivnu berbu u vlastitom vinogradu (tablica 53) te na varijabilne troškove koji nastaju kada proizvođač odluči koristiti usluge specijalizirane tvrtke za snimanje bespilotnom letjelicom koja ujedno nudi i obradu i analizu prikupljenih podataka s dostavom izvješća i preporuka proizvođaču (tablica 54).

U strukturi varijabilnih troškova kvalitativnog zoniranja za utrošak vlastitog vremena (tablica 53) pod rednim brojevima 1.-5. procijenjeno je vrijeme potrebno za provedbu kvalitativnog zoniranja 1 ha vlastitih vinogradarskih površina od strane proizvođača te je za potrebe izračuna uzeta vrijednost satnice vlastitog rada vlasnika vinograda u iznosu od 50,00 kn/h. Pod rednim brojem 6. procijenjeno je vrijeme potrebno za berbu 1 ha vinograda vinskog grožđa u zoni B, regiji Središnja bregovita Hrvatska sa 5.500 trsova/ha, a prema Katalogu kalkulacija poljoprivredne proizvodnje, dok su pod rednim brojem 7. predviđeni dodatni troškovi koji se odnose na selektivnu berbu ili diferencijaciju grožđa prema kvaliteti (vlastita procjena). Prema rezultatima ovog istraživanja, vezano za termine prikupljanja podataka i broj potrebnih snimanja multispektralnim kamerama, poželjno je provesti tri snimanja u toku vegetacijske sezone kako bi se dobili kvalitetniji podaci za kvalitativno zoniranje vinograda i selektivnu berbu grožđa te su tako i formirani ukupni varijabilni troškovi za proizvođača, ali i za provedbu usluge specijalizirane tvrtke.

[2] *Izvor: M SAN Grupa d.d.- ponuda (travanj, 2022)*
[3] *Izvor: www.ekupi.hr (travanj, 2022)*
[4] *Izvor: https://www.pix4d.com/pricing/pix4dfields (travanj, 2022)*
[5] *Izvor: https://training.pix4d.com/ (travanj, 2022)*
[6] *Izvor: komercijalna osiguravajuća kuća (travanj, 2022)*

Tablica 53. Varijabilni troškovi kvalitativnog zoniranja 1 ha vinograda- utrošak vlastitog vremena

R.br.	Opis troška	Potrebno sati	kn/h	Količina	Ukupno (kn)
1.	Ručno uzorkovanje na ciljanim trsovima	4	50,00	3	**600,00**
2.	Edukacija o primjeni bespilotnih letjelica	30	50,00	1	**1.500,00**
3.	Edukacija o obradi prikupljenih podataka	40	50,00	1	**2.000,00**
4.	Provedba snimanja bespilotnom letjelicom	3	50,00	3	**450,00**
5.	Obrada podataka i kreiranje kvalitativnih zona u vinogradu	3	50,00	3	**450,00**
6.	Selektivna berba prema kvalitativnim zonama[7]	220	25,00	1	**5.500,00**
7.	Dodatni troškovi selektivne berbe	50	25,00	1	**1.250,00**
					11.750,00

Prema navedenim troškovima u tablicama 52 i 53, ukupan trošak početnog investicijskog ulaganja pojedinog proizvođača u potrebnu opremu za kvalitativno zoniranje te vlastitu edukaciju, ali i samu provedbu kvalitativnog zoniranja i selektivne berbe prelazi 100.000,00 kuna, odnosno iznosi 103.950,00 kuna u prvoj godini provedbe.

U strukturi varijabilnog troška komercijalne usluge specijalizirane tvrtke (tablica 54) navedena su dva tipa usluga- snimanje bespilotnom letjelicom i prikupljanje podataka te usluga obrade i analize podataka s izradom izvješća i preporuka tri puta u toku vegetacijske sezone.

Tablica 54. Varijabilni troškovi kvalitativnog zoniranja- korištenje komercijalne usluge

Opis troška	Jedinica	Cijena (s PDV)	Količina	Ukupno (kn)
USLUGA specijalizirana tvrtka - snimanje bespilotnom letjelicom i prikupljanje podataka	1 ha	3.000,00	3	**9.000,00**
USLUGA specijalizirana tvrtka- obrada i analiza podataka, dostava izvješća i preporuka	1 ha	3.000,00	3	**9.000,00**
				18.000,00

[7] *Izvor: Katalog kalkulacija poljoprivredne proizvodnje, 2019.* https://www.savjetodavna.hr/wp-content/uploads/2020/06/Katalog-kalkulacija-2019.-godina.pdf

U slučaju korištenja oba tipa komercijalne usluge, proizvođač neće imati fiksne troškove nabave opreme kao ni varijabilne troškove utroška svog vremena naveden u tablicama 52 i 53 za kvalitativno zoniranje vinograda, osim troška selektivne berbe i dodatnog troška selektivne berbe (redni brojevi 6. i 7. u tablici 53) prema kvalitativnim zonama.

4.5.2. Rezultati analize tržišnih cijena grožđa i vina sorte 'Kraljevina' i 'Pinot crni'

Provedenim anketnim istraživanjem željelo se ustanoviti koliko su iznosile prosječne tržišne cijene grožđa sorte 'Kraljevina' i sorte 'Pinot crni' u desetogodišnjem periodu, odnosno, u razdoblju od 2011. do 2020. godine na odabranom području istraživanja. Analiza ostalih prikupljenih podataka kroz anketno istraživanje nije prikazana s obzirom na to da rezultati nisu relevantni za analizu tržišnih cijena grožđa i vina u ovom istraživanju.
S obzirom na pravni status ispitanih u odnosu na gospodarstvo, svi sudionici istraživanja nositelji su gospodarstava o kojima su anketirani, dok je s obzirom na spolnu strukturu ispitanih, istraživačkim uzorkom obuhvaćeno osam muških ispitanika te dvije ženske ispitanice. S obzirom na pravni status vinogradarskog gospodarstva, istraživačkim je uzorkom obuhvaćeno sedam gospodarstava registriranih kao obrt te tri gospodarstva registrirana kao OPG. S obzirom na lokaciju gospodarstva/vinogradarske proizvodnje, polovica uzorkom obuhvaćenih vinograda (n=5) smještena su u vinogorju Zelina i svi posjeduju vinograde zasađene sortom 'Kraljevina', dok su tri vinograda zasađena Pinotom crnim smještena su u vinogorju Plešivica-Okić, jedan u vinogorju Samobor te jedan u vinogorju Sveta Jana. Površina vinograda zasađenih sortom 'Kraljevina', kreće se u rasponu od 0,3 do 1,1 ha, pri čemu je prosječna površina 0,68 ha (M ± SD = 0,68 ± 0,30), dok se površina vinograda zasađenih sortom 'Pinot crni' kreće u rasponu od 0,2 do 1,1 ha, pri čemu je prosječna površina 0,54 ha (M ± SD = 0,54 ± 0,36). S obzirom na diferencijaciju grožđa prema kvaliteti, odnosno odvajanje grožđa lošije i bolje kvalitete u berbi prema kvalitativnim parametrima koncentracije šećera i količine ukupnih kiselina, šest ispitanih vinogradara koristi određene tehnike odvajanja i sortiranja grožđa prema kvaliteti (npr. berba s različitih položaja/vinograda na kojima se uzgajaju iste sorte, berba iste sorte u dva termina, otkup potrebnog sortnog grožđa) i to dva proizvođača sorte 'Kraljevina' (n=2) i četiri proizvođača sorte 'Pinot crni' (n=4), dok ostalih četvero to ne čini.
Prosječna tržišna cijena grožđa sorte 'Kraljevina' u promatranom desetogodišnjem periodu, iznosila je 3,22 kn/kg (M ± SD = 3,22 ± 0,53); dok je prosječna tržišna cijena grožđa sorte 'Pinot crni' u istom periodu iznosila 5,79 kn/kg (M ± SD = 5,79 ± 0,69). Pri tome, i u ukupnom uzorku (n=10) odnosno na svim uzorkom obuhvaćenim vinogradarskim gospodarstvima, kao i u poduzorku vinograda zasađenih sortom 'Kraljevina' te vinograda zasađenih sortom 'Pinot crni', vidljiv je dugoročni trend porasta tržišnih cijena grožđa. Pri

tome, tržišne cijene grožđa sorte 'Kraljevina' bile su u porastu od 2012. do 2015. godine, od 2015. do 2019. godine cijene su bile stabilne, da bi 2020. godine porasle; dok su tržišne cijene grožđa sorte 'Pinot crni' bile u porastu od 2011. do 2014. godine, od 2014. do 2018. godine cijene su bile stabilne, da bi 2019. godine porasle. Nadalje, obzirom na dvije uzorkom obuhvaćene sorte grožđa, prosječna tržišna cijena grožđa sorte 'Kraljevina' u analiziranom desetogodišnjem periodu bila je manja, dok je prosječna tržišna cijena grožđa sorte 'Pinot crni' u istom periodu bila veća. Pri tome, najveća apsolutna razlika u tržišnim cijenama grožđa između sorti 'Kraljevina' i 'Pinot crni' detektirana je 2014. godine (2,8 kn/kg), dok je najmanja apsolutna razlika u tržišnim cijenama grožđa između sorti 'Kraljevina' i 'Pinot crni' detektirana 2011. godine (2,2 kn/kg). Prema iznosima koeficijenata varijacija, prosječne tržišne cijene sorte 'Kraljevina' u većoj su mjeri varirale tijekom analiziranog desetogodišnjeg perioda. Pri tome, prosječna tržišna cijena grožđa sorte 'Kraljevina' u relativno najvećoj je mjeri povećana 2014. godine u odnosu na 2013. godinu; dok je prosječna tržišna cijena grožđa sorte 'Pinot crni' u relativno najvećoj mjeri povećana 2013. godine u odnosu na 2012. godinu. U tablici 55 prikazani su odabrani deskriptivni statistički pokazatelji prosječnih tržišnih cijena grožđa sorti 'Kraljevina' i 'Pinot crni' u analiziranom desetogodišnjem periodu od 2011.- 2020. godine. Također, podaci o prosječnim tržišnim cijenama grožđa sorte 'Kraljevina' i sorte 'Pinot crni' u periodu 2011.- 2020. godine prikazani su i u grafičkom obliku (grafikon 5).

Tablica 55. Odabrani deskriptivni statistički pokazatelji prosječnih tržišnih cijena grožđa sorte 'Kraljevina' i sorte 'Pinot crni' u analiziranom desetogodišnjem periodu

Analizirana godina	**Svi (n=10)**		**'Kraljevina' (n=5)**		**'Pinot crni' (n=5)**	
	Prosječna vrijednost	**Verižni indeksi**	**Prosječna vrijednost**	**Verižni indeksi**	**Prosječna vrijednost**	**Verižni indeksi**
2011. godina	3,80	-	2,70	-	4,90	-
2012. godina	3,95	103,95	2,70	100,00	5,20	106,12
2013. godina	4,25	107,59	2,90	107,41	5,60	107,69
2014. godina	4,60	108,24	3,20	110,34	6,00	107,14
2015. godina	4,70	102,17	3,40	106,25	6,00	100,00
2016. godina	4,70	100,00	3,40	100,00	6,00	100,00
2017. godina	4,70	100,00	3,40	100,00	6,00	100,00
2018. godina	4,70	100,00	3,40	100,00	6,00	100,00
2019. godina	4,75	101,06	3,40	100,00	6,10	101,67
2020. godina	4,90	103,16	3,70	108,82	6,10	100,00
Prosječna vrijednost	4,50		3,22		5,79	
Koeficijent varijacija	31,73		16,35		11,97	

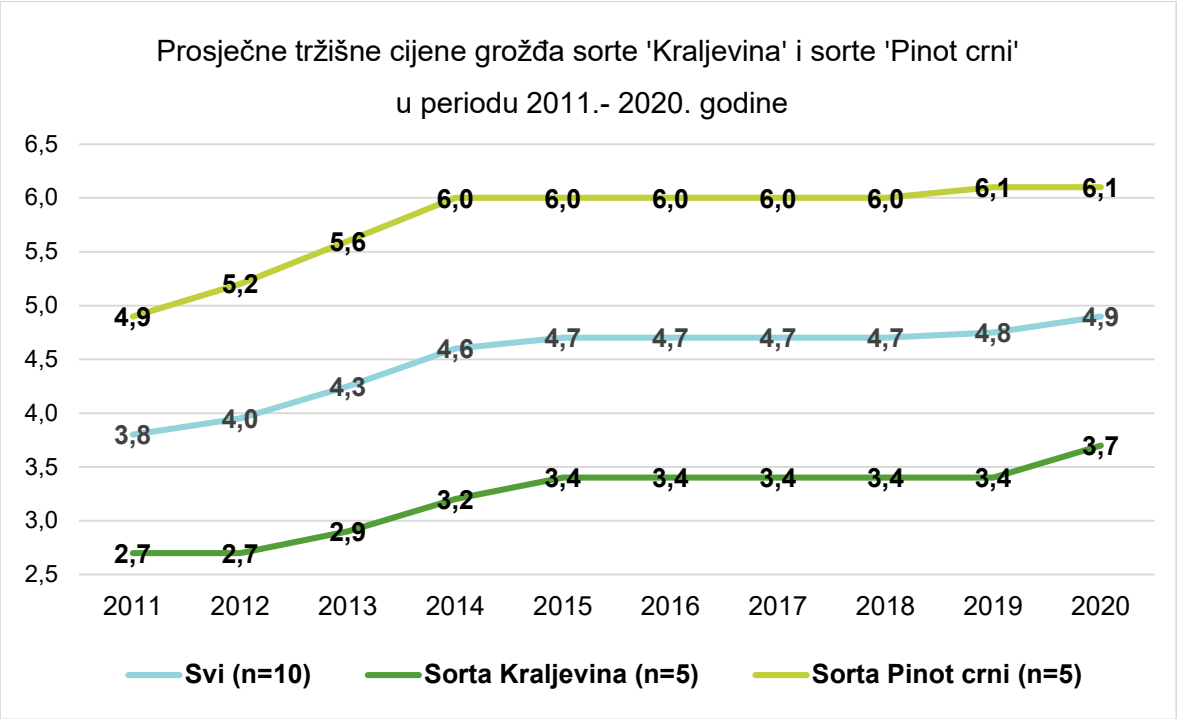

Grafikon 5. Prosječne tržišne cijene grožđa sorte 'Kraljevina' i sorte 'Pinot crni' u periodu 2011.- 2020. godine

Za usporedbu tržišnih cijena grožđa sorata 'Kraljevina' i 'Pinot crni' dobivenih anketnim ispitivanjem s prosječnim proizvođačkim cijenama vinskog grožđa u Republici Hrvatskoj, napravljeno je istraživanje desk-metodom kroz analizu dostupnih statističkih podataka iz europske baze podataka EUROSTAT o cijenama vinskog grožđa za razdoblje od 2011.-2020. godine na području Republike Hrvatske (grafikon 6). Iz podataka je vidljivo kako je prisutan različit trend u kretanju prosječnih cijena vinskog grožđa na razini Republike Hrvatske od kretanja prosječnih cijena sorata 'Kraljevina' i 'Pinot crni' u istom razdoblju. To se može objasniti kvalitativnom različitošću sorata i njihovom potencijalu za proizvodnju kvalitetnih i vrhunskih vina, koji značajno varira između sorata te se na taj način formira i cijena vinskog grožđa na tržištu Republike Hrvatske, ali i europskom i svjetskom tržištu. 'Pinot crni', kao sorta visokog kvalitativnog potencijala za proizvodnju vina, postiže uglavnom veće prodajne cijene grožđa od prosječnih, dok 'Kraljevina', kao autohtona sorta i sorta nižeg kvalitativnog potencijala za proizvodnju vina, postiže niže prodajne cijene grožđa od prosječnih u promatranom razdoblju. No, kada se usporedi prosječna tržišna cijena vinskog grožđa u Republici Hrvatskoj u desetogodišnjem razdoblju (5,03 kn) sa prosječnom cijenom vinskog grožđa u analiziranom uzorku vinskog grožđa sorti 'Kraljevina' i 'Pinot crni' (4,50 kn) vidljiva je postotna razlika u cijeni od svega 11,7% po kilogramu grožđa, odnosno 0,53 kn/kg. Važno je naglasiti kako u prosječnu cijenu vinskog

grožđa u Republici Hrvatskoj u izračun ulaze i cijene visoko kvalitetnog grožđa (npr. sorte 'Plavac mali') koje u berbi dostižu i 30 kn/kg.

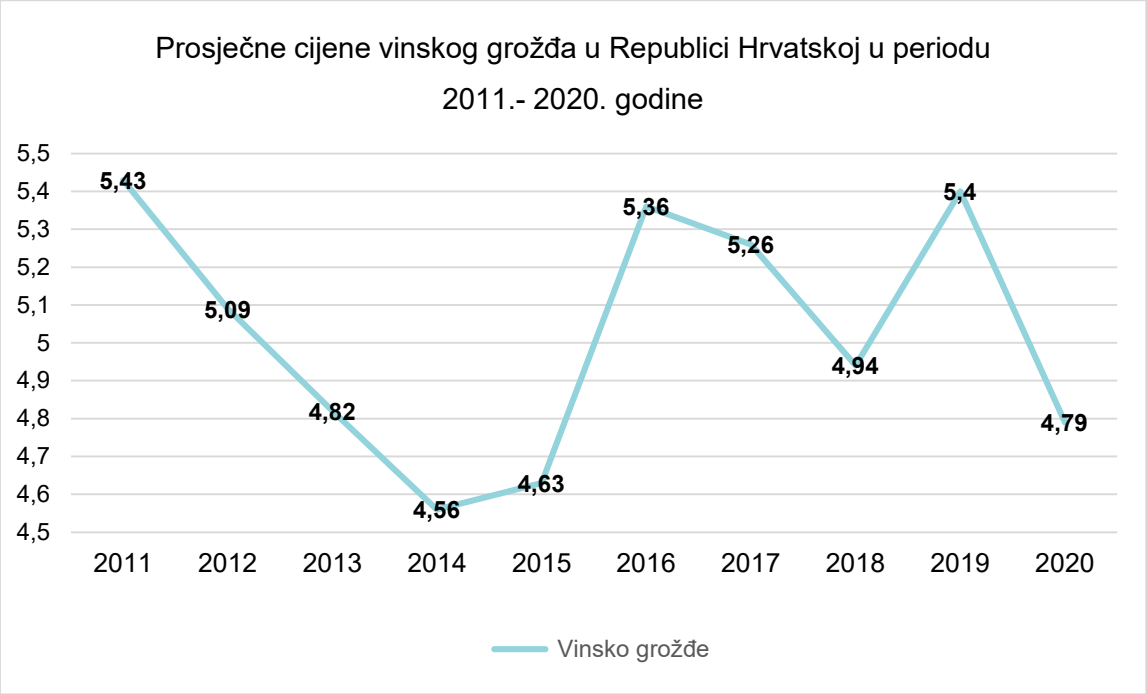

Grafikon 6. Prosječne proizvođačke cijene vinskog grožđa u Republici Hrvatskoj u periodu 2011.- 2020. godine

Prema uvriježenoj praksi otkupa vinskog grožđa od strane velikih vinarija u Republici Hrvatskoj, cijena vinskog grožđa formira se na osnovu koncentracije šećera u grožđu (°Oe), pri čemu se za svaki dodatni °Oe cijena grožđa povećava za 0,05 kn/kg. I u ovom istraživanju primijenjen je taj model povećanja cijene grožđa prema koncentraciji šećera pri selektivnoj berbi, odnosno izračun cijene grožđa koja bi potencijalno mogla biti ostvarena selektivnom berbom na temelju kvalitativnih zona određenih uz pomoć najprediktivnijeg vegetacijskog indeksa, baziran je na stvarnom povećanju cijene grožđa za 0,05 kn/kg vezanom uz koncentraciju šećera na svim analiziranim lokacijama.

Tržišne (maloprodajne) cijene vina sorata 'Kraljevina' i 'Pinot crni' prikupljene su istraživanjem tržišta u Internet trgovinama specijaliziranih prodavaonica vina te su preuzete stvarne cijene mirnih i/ili pjenušavih vina za sva četiri proizvođača u ovom istraživanju (tablica 56).

Tablica 56. Tržišne maloprodajne cijene odabranih vina sorte 'Kraljevina' i 'Pinot crni' za sva četiri proizvođača

Vino	Pakiranje	Cijena (kn/butelja)
'Kraljevina' Kos[8]	0,75 l	35,00
'Kraljevina' Puhelek- Purek[9]	0,75 l	57,00
Pjenušac Kraljica Puhelek- Purek[9]	0,75 l	100,00
'Pinot crni' Šember Vučjak[10]	0,75 l	150,00
Pjenušac Šember Rose[10]	0,75 l	120,00
'Pinot crni' Tomac[10]	0,75 l	145,00
Pjenušac Tomac Rose[10]	0,75 l	125,00

Bilješka: Maloprodajne cijene su zaokružene na prvi sljedeći cijeli broj zbog pojednostavljenja izračuna i prikaza cijena

Iz maloprodajnih cijena je vidljivo kako tri proizvođača (PUHELEK- PUREK, TOMAC i ŠEMBER) imaju više tipova vina na tržištu, osim proizvođača KOS koji ima samo jedan tip vina sorte 'Kraljevina'.

Za potrebe izračuna prihoda od prodaje vina proizvođača KOS koji bi nastali proizvodnjom različitih tipova vina na osnovu selektivne berbe korištena je prosječna tržišna cijena vina sorte 'Kraljevina' ostalih proizvođača iz vinogorja Zelina, čija vina su dostupna u Internet trgovinama specijaliziranih prodavaonica vina (tablica 57).
Za potrebe izračuna prihoda od prodaje vina proizvođača TOMAC i ŠEMBER koji bi nastali proizvodnjom jednog tipa vina umjesto dva različita tipa vina, korištena je prosječna tržišna cijena vina sorte 'Pinot crni' ostalih proizvođača iz podregije Plešivica čija vina su dostupna u Internet trgovinama specijaliziranih prodavaonica vina (tablica 57).

[8] *Izvor: Dobra vina (travanj, 2022)*
[9] *Izvor: Miva galerija vina (travanj, 2022)*
[10] *Izvor: Vrutak (travanj, 2022)*

Tablica 57. Prosječna tržišna cijena vina sorte 'Kraljevina' i sorte 'Pinot crni' ostalih proizvođača iz vinogorja Zelina i podregije Plešivica

	Tržišna cijena vina sorte 'Kraljevina' (kn/butelji)	Tržišna cijena vina sorte 'Pinot crni' (kn/butelji)
'Kraljevina' Jarec-Kure[11]	52,00	
'Kraljevina' Kos- Jurišić[12]	30,00	
'Kraljevina' Puhelek- Purek[13]	57,00	
'Pinot crni' Ledić[11]		35,00
'Pinot crni' Filipec[11]		80,00
'Pinot crni' Braje[11]		85,00
'Pinot crni' Šoškić[11]		102,00
PROSJEČNA TRŽIŠNA CIJENA	**46,33**	**75,50**

Bilješka: Maloprodajne cijene su zaokružene na prvi sljedeći cijeli broj zbog pojednostavljenja izračuna i prikaza cijena

Za potrebe ostalih izračuna prihoda od prodaje vina koji bi nastali proizvodnjom različitih tipova vina na osnovu selektivne berbe, korištene su cijene navedene u tablici 57, koje pokazuju kako je u vinogradarskoj proizvodnji od iste sorte moguće napraviti dva ili više tipova vina. Navedeni proizvođači koji već proizvode dva tipa vina ne koriste iste položaje i vinograde za proizvodnju oba tipa vina već koriste grožđe iz različitih vinograda i s različitih položaja te vrše i otkup grožđa od ostalih proizvođača iz vinogorja Plešivica- Okić i vinogorja Zelina. Ovim istraživanjem željelo se pokazati kako je iz svakog vinograda i sa svakog položaja moguća proizvodnja više tipova vina, ovisno o kvalitativnom zoniranju i selektivnoj berbi čime je moguće dodatno unaprijediti kvalitetu i/ili količinu određenog tipa vina.

4.5.3. Rezultati analize mogućih prihoda nakon selektivne berbe grožđa

Ovim istraživanjem analizirani su prihodi koje je moguće ostvariti temeljem razlike u cijeni grožđa sukladno kvalitativnim zonama u vinogradu određenim na temelju najprediktivnijeg vegetacijskog indeksa za sve četiri lokacije u ovom istraživanju- KOS, PUHELEK-PUREK, TOMAC i ŠEMBER.

[11] *Izvor: Vrutak (travanj, 2022)*
[12] *Izvor: Indeks dostave (travanj, 2022)*
[13] *Izvor: Miva galerija vina (travanj, 2022)*

Prihodi su izračunati na temelju stvarnih prinosa u berbi grožđa sorata 'Kraljevina' i 'Pinot crni' ostvarenih u obje istraživane godine 2019. i 2020., osim na lokaciji PUHELEK-PUREK gdje je analiza prihoda provedena samo za 2020. godinu. Za izračun prihoda bez selektivne berbe korištena je anketnim istraživanjem dobivena prosječna godišnja cijena grožđa za sortu 'Kraljevina' (2019.- 3,40 kn/kg; 2020.- 3,70 kn/kg) i sortu 'Pinot crni' (2019. i 2020.- 6,10 kn/kg). Za izračun mogućih prihoda nakon selektivne berbe na temelju najprediktivnijeg vegetacijskog indeksa za pojedinu lokaciju, korištene su iste prosječne godišnje cijene grožđa u godini istraživanja za zone veće bujnosti i grožđe manje koncentracije šećera, dok je cijena za grožđe iz zone manje bujnosti i veće koncentracije šećera uvećana za 0,05 kn/kg za svaki dodatni °Oe prema razlici prosječnih vrijednosti koncentracije šećera u zoni veće i manje bujnosti na temelju najprediktivnijeg vegetacijskog indeksa za obje godine istraživanja. Postotak površine zone manje i zone veće bujnosti dobiven je na temelju izračuna u ArcGis programskom paketu pri obradi i izradi karti bujnosti te je postotak površine zone služio za određivanje mogućeg prinosa u zoni manje i zoni veće bujnosti. Stvarni prihodi, kao i prihodi koje je moguće ostvariti temeljem razlike u cijeni grožđa sukladno kvalitativnim zonama u vinogradu određenim na temelju najprediktivnijeg vegetacijskog indeksa prikazani su u tablicama 58 (lokacija KOS), 59 (lokacija PUHELEK- PUREK), 60 (lokacija TOMAC) i 61 (lokacija ŠEMBER). U tablicama je dodatno prikazano i moguće ukupno povećanje prihoda u postotnom udjelu u odnosu na prihode bez provedbe kvalitativnog zoniranja i selektivne berbe.

Tablica 58. Analiza mogućeg povećanja prihoda od proizvodnje grožđa sorte 'Kraljevina' na lokaciji KOS u 2019. i 2020. godini uz provedbu kvalitativnog zoniranja i selektivne berbe

Godina	**2019**	**2020**
Površina (ha)	0,47	0,47
Količina ubranog grožđa (kg)	7.000	6.700
Prosječna cijena grožđa (kn/kg)	3,40	3,70
Ukupan prihod bez selektivne berbe (kn)	**23.800,00**	**24.790,00**
Udio površine zone manje bujnosti (%)	51,67	49,19
Udio površine zone veće bujnosti (%)	48,33	50,81
Cijena grožđa iz zone manje bujnosti (kn/kg)	3,65	4,2
Cijena grožđa iz zone veće bujnosti (kn/kg)	3,4	3,7
Ukupan prihod iz zone manje bujnosti (kn)	13.200,77	13.841,65
Ukupan prihod iz zone veće bujnosti (kn)	11.503,40	12.596,16
Ukupan prihod nakon selektivne berbe (kn)	**24.704,16**	**26.437,82**
Moguće povećanje ukupnog prihoda nakon selektivne berbe (kn)	**904,16 (3,80%)**	**1.647,82 (6,65%)**

Tablica 59. Analiza mogućeg povećanja prihoda od proizvodnje grožđa sorte 'Kraljevina' na lokaciji na lokaciji PUHELEK- PUREK u 2020. godini uz provedbu kvalitativnog zoniranja i selektivne berbe

Godina	**2020**
Površina (ha)	0,93
Količina ubranog grožđa (kg)	13.400
Prosječna cijena grožđa (kn/kg)	3,70
Ukupan prihod bez selektivne berbe (kn)	**49.580,00**
Udio površine zone manje bujnosti (%)	62,77
Udio površine zone veće bujnosti (%)	37,23
Cijena grožđa iz zone manje bujnosti (kn/kg)	4,35
Cijena grožđa iz zone veće bujnosti (kn/kg)	3,70
Ukupan prihod iz zone manje bujnosti (kn)	36.591,25
Ukupan prihod iz zone veće bujnosti (kn)	18.456,41
Ukupan prihod nakon selektivne berbe (kn)	**55.047,66**
Moguće povećanje ukupnog prihoda nakon selektivne berbe (kn)	**5.467,66 (11,03%)**

Tablica 60. Analiza mogućeg povećanja prihoda od proizvodnje grožđa sorte 'Pinot crni' na lokaciji TOMAC u 2019. i 2020. godini uz provedbu kvalitativnog zoniranja i selektivne berbe

Godina	**2019**	**2020**
Površina (ha)	0,33	0,33
Količina ubranog grožđa (kg)	1.800	1.900
Prosječna cijena grožđa (kn/kg)	6,10	6,10
Ukupan prihod bez selektivne berbe (kn)	**10.980,00**	**11.590,00**
Udio površine zone manje bujnosti (%)	61,97	54,33
Udio površine zone veće bujnosti (%)	38,03	45,67
Cijena grožđa iz zone manje bujnosti (kn/kg)	6,35	6,40
Cijena grožđa iz zone veće bujnosti (kn/kg)	6,10	6,10
Ukupan prihod iz zone manje bujnosti (kn)	7.082,68	6.606,38
Ukupan prihod iz zone veće bujnosti (kn)	4.176,17	5.293,29
Ukupan prihod nakon selektivne berbe (kn)	**11.258,85**	**11.899,67**
Moguće povećanje ukupnog prihoda nakon selektivne berbe (kn)	**278,85 (2,48%)**	**309,67 (2,60%)**

Tablica 61. Analiza mogućeg povećanja prihoda od proizvodnje grožđa sorte 'Pinot crni' na lokaciji ŠEMBER u 2019. i 2020. godini uz provedbu kvalitativnog zoniranja i selektivne berbe

Godina	2019	2020
Površina (ha)	0,65	0,65
Količina ubranog grožđa (kg)	6.570	4.815
Prosječna cijena grožđa (kn/kg)	6,10	6,10
Ukupan prihod bez selektivne berbe (kn)	**40.077,00**	**29.371,50**
Udio površine zone manje bujnosti (%)	49,47	47,00
Udio površine zone veće bujnosti (%)	50,53	53,00
Cijena grožđa iz zone manje bujnosti (kn/kg)	6,50	6,55
Cijena grožđa iz zone veće bujnosti (kn/kg)	6,10	6,10
Ukupan prihod iz zone manje bujnosti (kn)	21.127,63	14.821,82
Ukupan prihod iz zone veće bujnosti (kn)	20.249,54	15.567,97
Ukupan prihod nakon selektivne berbe (kn)	**41.377,16**	**30.389,79**
Moguće povećanje ukupnog prihoda nakon selektivne berbe (kn)	**1.300,16 (3,24%)**	**1.018,29 (3,47%)**

Iz navedenih tablica vidljivo je da je na sve četiri lokacije došlo do povećanja mogućih ukupnih prihoda od proizvodnje grožđa uz provedbu kvalitativnog zoniranja i selektivne berbe. Isto tako, vidljivo je i da se moguće povećanje prihoda kreće na razini 2,48% - 11,03% od ukupnih prihoda koji su ostvareni bez provedbe selektivne berbe. Povećanje mogućih ukupnih prihoda ovisno je o površini samog vinograda, količini ubranog grožđa, a ponajviše o udjelu površine zone manje ili veće bujnosti dobivene na temelju najprediktivnijeg indeksa te o razlici u koncentraciji šećera između te dvije zone. Stoga je vidljivo da je najveće povećanje mogućih prihoda ostvareno na lokaciji PUHELEK-PUREK (tablica 59) u vinogradu površine 0,93 ha, gdje je udio zone manje bujnosti veći od 62%, a razlika u koncentraciji šećera između dviju kvalitativnih zona je najveća i iznosi 13 °Oe. Najmanje povećanje mogućih ukupnih prihoda vidljivo je na lokaciji TOMAC (tablica 60) u vinogradu površine 0,33 ha, koji je ujedno i najmanji vinograd u ovom istraživanju te bez obzira na relativno veliku razliku u udjelu površine zone manje bujnosti (posebice u 2019. godini), mala razlika u koncentraciji šećera između dviju kvalitativnih zona (svega 5°Oe u 2019. godini) smanjila je utjecaj kvalitativnog zoniranja na moguće povećanje ukupnih prihoda nakon selektivne berbe. Na druge dvije lokacije (KOS, ŠEMBER) također je vidljivo kako su relativno male razlike u udjelima površine zone manje ili veće bujnosti te male razlike u koncentraciji šećera između dviju kvalitativnih zona, utjecale i na manje moguće povećanje ukupnih prihoda nakon selektivne berbe,

osim na lokaciji KOS u 2020. godini gdje je razlika u koncentraciji šećera između dviju kvalitativnih zona od 10°Oe utjecala na moguće povećanje ukupnih prihoda nakon selektivne berbe za 6,65%. Temeljem svega navedenoga, veće površine vinograda koje pokazuju veću varijabilnost u bujnosti i kvalitativnim svojstvima grožđa, odnosno imaju veći udio površine zone manje bujnosti s većom koncentracijom šećera, imaju i veće moguće povećanje ukupnih prihoda nakon selektivne berbe zbog više cijene grožđa s većom koncentracijom šećera.

4.5.4. Rezultati analize mogućih prihoda od proizvodnje vina na osnovu selektivne berbe grožđa

Ovim istraživanjem analizirani su prihodi koje je moguće ostvariti proizvodnjom različitih tipova vina iz istog vinograda sukladno kvalitativnim zonama u vinogradu određenim na temelju najprediktivnijeg vegetacijskog indeksa za sve četiri lokacije u ovom istraživanju- KOS, PUHELEK- PUREK, TOMAC i ŠEMBER.

Na temelju ostvarenog prinosa, odnosno ukupne količine ubranog grožđa na pojedinoj lokaciji izračunata je moguća proizvodnja vina i to uz randman za proizvodnju vina od 70%, sukladno Katalogu kalkulacija poljoprivredne proizvodnje za vina sa ZOI u zoni B, u regiji Središnja bregovita Hrvatska. Dobivena moguća količina litara proizvedenog vina preračunata je na broj proizvedenih butelja dijeljenjem sa 0,75, jer svi proizvođači plasiraju vina na tržište u buteljama zapremine 0,75 litara. Potom je ukupan broj butelja podijeljen sukladno postotku površine zone manje i zone veće bujnosti na temelju najprediktivnijeg vegetacijskog indeksa, kako bi se dobio broj butelja koje je moguće proizvesti od grožđa iz zone manje i zone veće bujnosti. Na taj način omogućen je izračun mogućih prihoda od proizvodnje dva tipa vina na temelju kvalitativnog zoniranja i selektivne berbe grožđa iz dvije različite kvalitativne zone. Cijene vina uz obrazloženje formiranja cijena koje su korištene za izračun mogućih prihoda navedene su u poglavlju 4.5.2.

Moguće povećanje prihoda uz proizvodnju različitih tipova vina sukladno kvalitativnim zonama i selektivnoj berbi prikazani su u tablicama 62 (lokacija KOS), 63 (lokacija PUHELEK- PUREK), 64 (lokacija TOMAC) i 65 (lokacija ŠEMBER). Dodatno je izračunat i postotni udio mogućeg povećanja prihoda od proizvodnje dva tipa vina u odnosu na prihode od proizvodnje vina bez provedbe kvalitativnog zoniranja i selektivne berbe, odnosno proizvodnje jednog tipa vina na određenoj lokaciji.

Tablica 62. Analiza mogućeg povećanja prihoda od proizvodnje vina sorte 'Kraljevina' na lokaciji KOS u 2019. i 2020. godini uz provedbu kvalitativnog zoniranja i selektivne berbe

Godina	**2019**	**2020**
Površina (ha)	0,47	0,47
Količina ubranog grožđa (kg)	7.000	6.700
Količina proizvedenog vina (l)	4900	4690
Količina proizvedenih butelja (kom)	6533	6253
Prosječna cijena vina (kn/butelji)	35,00	35,00
Ukupan prihod od proizvodnje vina bez selektivne berbe (kn)	**228.666,67**	**218.866,67**
Udio površine zone manje bujnosti (%)	51,67	49,19
Udio površine zone veće bujnosti (%)	48,33	50,81
Količina proizvedenih butelja iz zone manje bujnosti (kom)	3376	3076
Količina proizvedenih butelja iz zone veće bujnosti (kom)	3158	3177
Cijena vina iz zone manje bujnosti (kn/butelji)	46,33	46,33
Cijena vina iz zone veće bujnosti (kn/butelji)	35,00	35,00
Ukupan prihod iz zone manje bujnosti (kn)	156.388,68	142.507,49
Ukupan prihod iz zone veće bujnosti (kn)	110.522,83	111.209,38
Ukupan prihod nakon selektivne berbe (kn)	**266.911,51**	**253.716,87**
Moguće povećanje ukupnog prihoda od proizvodnje vina nakon selektivne berbe (kn)	**38.244,85 (14,32%)**	**34.850,20 (13,74%)**

Tablica 63. Analiza mogućeg povećanja prihoda od proizvodnje vina sorte 'Kraljevina' na lokaciji PUHELEK- PUREK u 2020. godini uz provedbu kvalitativnog zoniranja i selektivne berbe

Godina	**2020**
Površina (ha)	0,93
Količina ubranog grožđa (kg)	13.400
Količina proizvedenog vina (l)	9380
Količina proizvedenih butelja (kom)	12507
Prosječna cijena vina (kn/butelji)	57,00
Ukupan prihod od proizvodnje vina bez selektivne berbe (kn)	**712.880,00**
Udio površine zone manje bujnosti (%)	62,77
Udio površine zone veće bujnosti (%)	37,23
Količina proizvedenih butelja iz zone manje bujnosti (kom)	7851
Količina proizvedenih butelja iz zone veće bujnosti (kom)	4656
Cijena vina iz zone manje bujnosti (kn/butelji)	57,00
Cijena vina iz zone veće bujnosti (kn/butelji)	100,00
Ukupan prihod iz zone manje bujnosti (kn)	447.506,81
Ukupan prihod iz zone veće bujnosti (kn)	465.567,00
Ukupan prihod nakon selektivne berbe (kn)	**913.073,81**
Moguće povećanje ukupnog prihoda od proizvodnje vina nakon selektivne berbe (kn)	**200.193,81 (21,93%)**

Tablica 64. Analiza mogućeg povećanja prihoda od proizvodnje vina sorte 'Pinot crni' na lokaciji TOMAC u 2019. i 2020. godini uz provedbu kvalitativnog zoniranja i selektivne berbe

Godina	**2019**	**2020**
Površina (ha)	0,33	0,33
Količina ubranog grožđa (kg)	1.800	1.900
Količina proizvedenog vina (l)	1260	1330
Količina proizvedenih butelja (kom)	1680	1773
Prosječna cijena vina (kn/butelji)	75,50	75,50
Ukupan prihod od proizvodnje vina bez selektivne berbe (kn)	**126.840,00**	**133.886,67**
Udio površine zone manje bujnosti (%)	61,97	54,33
Udio površine zone veće bujnosti (%)	38,03	45,67
Količina proizvedenih butelja iz zone manje bujnosti (kom)	1041	963
Količina proizvedenih butelja iz zone veće bujnosti (kom)	639	810
Cijena vina iz zone manje bujnosti (kn/butelji)	145,00	145,00
Cijena vina iz zone veće bujnosti (kn/butelji)	125,00	125,00
Ukupan prihod iz zone manje bujnosti (kn)	150.948,43	139.697,47
Ukupan prihod iz zone veće bujnosti (kn)	79.872,04	101.237,82
Ukupan prihod nakon selektivne berbe (kn)	**230.820,47**	**240.935,28**
Moguće povećanje ukupnog prihoda od proizvodnje vina nakon selektivne berbe (kn)	**103.980,47 (45,05%)**	**107.048,62 (44,43%)**

Tablica 65. Analiza mogućeg povećanja prihoda od proizvodnje vina sorte 'Pinot crni' na lokaciji ŠEMBER u 2019. i 2020. godini uz provedbu kvalitativnog zoniranja i selektivne berbe

Godina	**2019**	**2020**
Površina (ha)	0,65	0,65
Količina ubranog grožđa (kg)	6.570	4.815
Količina proizvedenog vina (l)	4599	3371
Količina proizvedenih butelja (kom)	6132	4494
Prosječna cijena vina (kn/butelji)	75,50	75,50
Ukupan prihod od proizvodnje vina bez selektivne berbe (kn)	**462.966,00**	**339.297,00**
Udio površine zone manje bujnosti (%)	49,47	47,00
Udio površine zone veće bujnosti (%)	50,53	53,00
Količina proizvedenih butelja iz zone manje bujnosti (kom)	3034	2112
Količina proizvedenih butelja iz zone veće bujnosti (kom)	3098	2382
Cijena vina iz zone manje bujnosti (kn/butelji)	150,00	150,00
Cijena vina iz zone veće bujnosti (kn/butelji)	120,00	120,00
Ukupan prihod iz zone manje bujnosti (kn)	455.056,54	316.802,29
Ukupan prihod iz zone veće bujnosti (kn)	371.794,77	285.838,17
Ukupan prihod nakon selektivne berbe (kn)	**826.851,31**	**602.640,46**
Moguće povećanje ukupnog prihoda od proizvodnje vina nakon selektivne berbe (kn)	**363.885,31 (44,00%)**	**263.343,46 (43,70%)**

Iz navedenih tablica vidljivo je da je na sve četiri lokacije došlo do povećanja mogućih ukupnih prihoda od proizvodnje vina nakon selektivne berbe. Isto tako, vidljivo je i da se moguće povećanje prihoda za 13,74% - 45,05% od ukupnih prihoda od proizvodnje vina koje se može ostvariti bez provedbe selektivne berbe. Povećanje mogućih ukupnih prihoda ovisno je ponajviše o sorti grožđa te o tipu vina koje se proizvodi. Stoga je vidljivo da je najmanje povećanje prihoda ostvareno na lokaciji KOS gdje je uz selektivnu berbu moguće proizvesti dva tipa mirnih vina sorte 'Kraljevina' pri čemu bi jedno bilo više kakvoće i višeg cjenovnog ranga. Općenito, manje je postotno povećanje prihoda od proizvodnje dva tipa vina vidljivo kod vina sorte 'Kraljevina', što je i odraz stanja na tržištu

vina na kojem je vino sorte 'Pinot crni' cjenjenije kao sortno vino te postiže značajno veće cijene na tržištu. Na lokaciji PUHELEK- PUREK uočena je inverzija u cijeni vina, odnosno vina iz zone veće bujnosti imaju veću tržišnu cijenu jer se radi o pjenušavom vinu od sorte 'Kraljevina', koje na tržištu postiže veće cijene od mirnog vina, a za proizvodnju pjenušavih vina pogodne su površine veće bujnosti zbog manje koncentracije šećera i većeg sadržaja ukupnih kiselina u grožđu, što čini kvalitetniju sirovinu za proizvodnju baznog vina za pjenušce. Nadalje, najveće postotno povećanje prihoda od proizvodnje dva tipa vina vidljivo je kod vina sorte 'Pinot crni' na obje istraživane lokacije (TOMAC i ŠEMBER) jer su obje zone bujnosti pogodne za proizvodnju visoko kvalitetnih vina i to mirnog vina iz zone manje bujnosti te pjenušavog vina iz zone veće bujnosti. Oba tipa vina na tržištu postižu visoke cijene po butelji što čini kvalitativno zoniranje i selektivnu berbu postupcima kojima se taj učinak može maksimizirati, odnosno iz svakog vinograda i sa svakog položaja moguće je iskoristiti maksimalne kvalitativne potencijale sorte uz selektivnu berbu grožđa za proizvodnju različitih tipova vina.

4.5.5. Rezultati analize financijskih kriterija i procjena opravdanosti ulaganja u kvalitativno zoniranje i selektivnu berbu

U ovom istraživanju korištene su metode financijskog odlučivanja koje su odabrane zbog mogućnosti procjene opravdanosti ulaganja u kvalitativno zoniranje i selektivnu berbu. Korištene su temeljene metode (metoda čiste sadašnje vrijednosti (NPV) i metoda interne stope profitabilnosti (IRR)), dodatne metode (metoda razdoblja povrata (t_p) i metoda diskontiranog razdoblja povrata) te posebna metoda (metoda modificirane interne stope profitabilnosti (mIRR)).

Koristeći analizu mogućeg povećanja prihoda od proizvodnje vina uz provedbu kvalitativnog zoniranja i selektivne berbe i analizu fiksnih i varijabilnih troškova za svaku lokaciju u istraživanju, izrađen je račun dobiti i gubitka koji obuhvaća petogodišnje razdoblje efektuiranja projekta (2019. do 2023. godine), osim na lokaciji PUHELEK-PUREK gdje je razdoblje efektuiranja projekta od 2020. do 2024. godine. Dodatno je za lokaciju KOS izrađen račun dobiti i gubitka te analiza financijskih kriterija za desetogodišnje razdoblje efektuiranja projekta (2019. do 2028. godine). Računi dobiti i gubitka kao i izračuni financijskih kriterija napravljeni su za dva moguća scenarija: A-proizvođač sam provodi kvalitativno zoniranje i selektivnu berbu u vlastitom vinogradu i B-proizvođač koristi usluge specijalizirane tvrtke za snimanje bespilotnom letjelicom i obradu i analizu prikupljenih podataka dok selektivnu berbu provodi sam. U oba scenarija korišteni su iznosi mogućeg povećanja prihoda od proizvodnje vina u prve dvije godine efektuiranja projekta (2019. i 2020.), dok su za ostale tri godine (2021., 2022. i 2023.),

odnosno na lokaciji KOS i za preostalih pet godina (2024.- 2028.), korišteni prosječni iznosi prihoda prve dvije godine efektuiranja projekta. Na lokaciji PUHELEK- PUREK su za svih pet godina efektuiranja projekta korišteni iznosi mogućeg povećanja prihoda od proizvodnje vina iz 2020. godine. U scenariju A korištena je godišnja amortizacijska stopa od 20% za nabavu bespilotne letjelice, nabavu računala i nabavu programskog paketa za obradu podataka kako bi navedena oprema bila amortizirana u razdoblju efektuiranja projekta. Na lokaciji KOS u desetogodišnjoj analizi pretpostavljeno je da je oprema, nabavljena na početku efektuiranja projekta, amortizirana u petogodišnjem razdoblju te je pretpostavljeno da je bilo potrebno nabaviti novu opremu (bespilotnu letjelicu, dodatnu bateriju i računalo) na kraju pete godine efektuiranja projekta (2023. godine) pri čemu je trošak te opreme diskontiran na sadašnju vrijednost uz diskontnu stopu od 10%. Izračuni za razdoblje 2024.- 2028. obuhvaćaju amortizirani iznos troška novo nabavljene opreme uz godišnju amortizacijsku stopu od 20%. Za potrebe izračuna neto dobiti korištena je stopa poreza na dobit od 10%, uz pretpostavku da su proizvođači obveznici poreza na dobit.

Prihodi se odnose isključivo na iznos mogućeg povećanja ukupnog prihoda od proizvodnje vina nakon selektivne berbe, odnosno uključuju samo novostvoreni prihod koji je moguće ostvariti uz proizvodnju i prodaju različitih tipova vina sukladno kvalitativnim zonama i selektivnoj berbi. Ovaj pristup korišten je kako bi se pokazalo može li ulaganje u provedbu kvalitativnog zoniranja i selektivne berbe biti pokriveno prihodima koji bi bili ostvareni nakon provedenog ulaganja. Rashodi se u scenariju A odnose na fiksne i varijabilne troškove, pri čemu fiksni troškovi uključuju nabavu opreme (kroz prikaz amortiziranih troškova), potrebnu edukaciju i osiguranje bespilotne letjelice, dok varijabilni troškovi uključuju utrošak vlastitog vremena i trošak provedbe selektivne berbe. U scenariju B rashodi se sastoje od varijabilnih troškova korištenja usluge specijalizirane tvrtke i troška provedbe selektivne berbe. Svi varijabilni troškovi u oba scenarija prilagođeni su stvarnoj površini vinograda na određenoj lokaciji, a preračunati su prema podacima iz tablice 54 u kojoj su navedeni svi varijabilni troškovi standardizirani na površinu od 1 ha.

Pri izračunu financijskih kriterija korišteni su iznosi primitaka, izdataka i poreza pri čemu primitke čine mogući prihodi od proizvodnje vina uz provedbu kvalitativnog zoniranja i selektivne berbe, a izdatke čine varijabilni troškovi selektivne berbe i godišnje osiguranje bespilotne letjelice (osim za prvu godinu efektuiranja projekta kada je trošak osiguranja uračunat u početno ulaganje). Ulaganje u scenariju A čine troškovi nabave opreme (sukladno tablici 52), dok ulaganje u scenariju B čini trošak korištenja usluge specijalizirane tvrtke (sukladno tablici 54) za snimanje bespilotnom letjelicom i obradu i analizu prikupljenih podataka, ali sveden na sadašnju vrijednost investicije uz diskontnu

stopu od 10%, odnosno na trenutnu vrijednost ukupnog iznosa niza budućih ulaganja u razdoblju efektuiranja projekta za korištenje usluge specijalizirane tvrtke. Dodatno, u scenariju A za potrebe desetogodišnjeg izračuna financijskih kriterija na lokaciji KOS, pretpostavljeno je dodatno ulaganje u novu opremu na kraju pete godine efektuiranja projekta, a iznos je također diskontiran na sadašnju vrijednost uz diskontnu stopu od 10%. Pri izračunu diskontiranog razdoblja povrata korištena je diskontna stopa od 10%, dok je pri izračunu mIRR korištena stopa reinvestiranja od 12%. U nastavku su prikazane tablice računa dobiti i gubitka te izračuni financijskih kriterija za scenarij A i scenarij B za sve četiri lokacije istraživanja.

Tablica 66. Račun dobiti i gubitka za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Kraljevina' na lokaciji KOS (0,47 ha) u razdoblju od 2019.- 2023. godine za scenarije A i B

		SCENARIJ A					SCENARIJ B				
	GODINA	**2019**	**2020**	**2021**	**2022**	**2023**	**2019**	**2020**	**2021**	**2022**	**2023**
A	**PRIHODI**	**38.244,85**	**34.850,20**	**36.547,52**	**36.547,52**	**36.547,52**	**38.244,85**	**34.850,20**	**36.547,52**	**36.547,52**	**36.547,52**
B	**RASHODI**										
1.	Ručno uzorkovanje na ciljanim trsovima	282,00	282,00	282,00	282,00	282,00	0,00	0,00	0,00	0,00	0,00
2.	Edukacija o primjeni bespilotnih letjelica	1.500,00	1.500,00	1.500,00	1.500,00	1.500,00	0,00	0,00	0,00	0,00	0,00
3.	Edukacija o obradi prikupljenih podataka	2.000,00	2.000,00	2.000,00	2.000,00	2.000,00	0,00	0,00	0,00	0,00	0,00
4.	Provedba snimanja bespilotnom letjelicom	450,00	450,00	450,00	450,00	450,00	0,00	0,00	0,00	0,00	0,00
5.	Obrada podataka	450,00	450,00	450,00	450,00	450,00	0,00	0,00	0,00	0,00	0,00
6.	Selektivna berba	2.585,00	2.585,00	2.585,00	2.585,00	2.585,00	2.585,00	2.585,00	2.585,00	2.585,00	2.585,00
7.	Dodatni troškovi selektivne berbe	587,50	587,50	587,50	587,50	587,50	587,50	587,50	587,50	587,50	587,50
	UKUPNO VARIJABILNI TROŠKOVI	7.854,50	7.854,50	7.854,50	7.854,50	7.854,50	3.172,50	3.172,50	3.172,50	3.172,50	3.172,50
8.	Bespilotna letjelica DJI Phantom 4 Multispectral	8.400,00	8.400,00	8.400,00	8.400,00	8.400,00	0,00	0,00	0,00	0,00	0,00
9.	Dodatna baterija	1.250,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
10.	Računalo	2.000,00	2.000,00	2.000,00	2.000,00	2.000,00	0,00	0,00	0,00	0,00	0,00

11.	Programski paket Pix4D	4.000,00	4.000,00	4.000,00	4.000,00	4.000,00	0,00	0,00	0,00	0,00	0,00
12.	DPO Crew obuka za pilota drona- trodnevna	3.950,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
13.	Edukacija (Pix4D fields)	7.500,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
14.	Osiguranje bespilotne letjelice	7.500,00	7.500,00	7.500,00	7.500,00	7.500,00	0,00	0,00	0,00	0,00	0,00
	UKUPNO FIKSNI TROŠKOVI	34.600,00	21.900,00	21.900,00	21.900,00	21.900,00	0,00	0,00	0,00	0,00	0,00
	USLUGA SPECIJALIZIRANE TVRTKE	0,00	0,00	0,00	0,00	0,00	18.000,00	18.000,00	18.000,00	18.000,00	18.000,00
B	**UKUPNO RASHODI**	**42.454,50**	**29.754,50**	**29.754,50**	**29.754,50**	**29.754,50**	**21.172,50**	**21.172,50**	**21.172,50**	**21.172,50**	**21.172,50**
C	**BRUTO DOBIT**	**-4.209,65**	**5.095,70**	**6.793,02**	**6.793,02**	**6.793,02**	**17.072,35**	**13.677,70**	**15.375,02**	**15.375,02**	**15.375,02**
	POREZ NA DOBIT (10%)	0,00	509,57	679,30	679,30	679,30	1.707,23	1.367,77	1.537,50	1.537,50	1.537,50
D	**NETO DOBIT**	**-4.209,65**	**4.586,13**	**6.113,72**	**6.113,72**	**6.113,72**	**15.365,11**	**12.309,93**	**13.837,52**	**13.837,52**	**13.837,52**

Tablica 67. Izračun financijskih kriterija za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Kraljevina' na lokaciji KOS (0,47 ha) u razdoblju od 2019.- 2023. godine za scenarije A i B

	SCENARIJ A						SCENARIJ B					
GODINA	**2018**	**2019**	**2020**	**2021**	**2022**	**2023**	**2018**	**2019**	**2020**	**2021**	**2022**	**2023**
Primici		38.244,85	34.850,20	36.547,52	36.547,52	36.547,52		38.244,85	34.850,20	36.547,52	36.547,52	36.547,52
Izdaci		7.854,50	15.354,50	15.354,50	15.354,50	15.354,50		3.172,50	3.172,50	3.172,50	3.172,50	3.172,50
Porez		0,00	509,57	679,30	679,30	679,30		1.707,23	1.367,77	1.537,50	1.537,50	1.537,50
Ulaganje	-92.200,00						-68.234,16					
NNT	-92.200,00	30.390,35	18.986,13	20.513,72	20.513,72	20.513,72	-68.234,16	33.365,11	30.309,93	31.837,52	31.837,52	31.837,52
Kumulativni NNT	-92.200,00	-61.809,65	-42.823,52	-22.309,80	-1.796,08	18.717,64	-68.234,16	-34.869,05	-4.559,12	27.278,40	59.115,93	90.953,45
Disk. NNT	-92.200,00	27.627,59	15.691,02	15.412,26	14.011,15	12.737,41	-68.234,16	30.331,92	25.049,53	23.920,00	21.745,46	19.768,60
Kum. Disk. NNT	-92.200,00	-64.572,41	-48.881,39	-33.469,13	-19.457,98	-6.720,58	-68.234,16	-37.902,24	-12.852,71	11.067,29	32.812,75	52.581,34
NPV	**-6.720,58**						**52.581,34**					
IRR	**6,92%**						**37,24%**					
Razdoblje povrata	**2023 (5. godina)**						**2021 (3. godina)**					
Diskontirano razdoblje povrata	**-**						**2021 (3. godina)**					
MIRR	**9,28%**						**24,31%**					

U tablici 66 prikazan je račun dobiti i gubitka za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Kraljevina' na lokaciji KOS (0,47 ha) u razdoblju od 2019.- 2023. godine za scenarije A i B. Iz računa dobiti i gubitka vidljivo je da je u scenariju A (proizvođač sam provodi kvalitativno zoniranje i selektivnu berbu u vlastitom vinogradu) u prvoj godini efektuiranja projekta (2019.) u kojoj je izvršeno ulaganje od 92.200,00 kn ostvaren gubitak u iznosu od 4.209,65 kn, dok je u narednim godinama efektuiranja projekta ostvarena neto dobit u iznosu od 4.586,13 kn (2020.) i 6.113,72 kn (2021.- 2023.) U scenariju B (proizvođač koristi usluge specijalizirane tvrtke za snimanje bespilotnom letjelicom i obradu i analizu prikupljenih podataka dok selektivnu berbu provodi sam) ostvarena je neto dobit u svim godinama efektuiranja projekta i to u iznosu od 15.365,11 kn (2019.); 12.309,93 kn (2020.) te 13.837,52 kn (2021.-2023.).

U tablici 67 prikazani su izračuni financijskih kriterija za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Kraljevina' na lokaciji KOS (0,47 ha) u razdoblju od 2019.- 2023. godine za scenarije A i B. Prema financijskom kriteriju čiste sadašnje vrijednosti (NPV) u scenariju A može se zaključiti kako ulaganje nije isplativo jer je vrijednost negativna. Interna stopa profitabilnosti (IRR) iznosi 6,92%, dok modificirana interna stopa profitabilnosti (mIRR) iznosi 9,28% te se može zaključiti kako ulaganje u scenariju A nije isplativo jer je IRR niža od diskontne stope (10%), a mIRR niža od stope reinvestiranja (12%) odnosno IRR je niža od potrebne stope povrata ulaganja, a mIRR je niža od potrebne granične stope povrata ulaganja. Isto tako, vidljivo je da je razdoblje povrata ulaganja u scenariju A tek u zadnjoj godini efektuiranja projekta (2023.) dok se diskontirano razdoblje povrata nije dogodilo u traženom petogodišnjem razdoblju efektuiranja projekta odnosno diskontirani čisti novčani tokovi nisu pokrili vrijednost ulaganja u traženom razdoblju te se može zaključiti kako ovo ulaganje nije isplativo u scenariju A. U scenariju B, prema svim financijskim kriterijima ulaganje je isplativo (NPV je pozitivna, IRR (37,24%) je veća su od diskontne stope, mIRR (24,31%) je veća od stope reinvestiranja), dok je razdoblje povrata ulaganja ostvareno u trećoj godini efektuiranja projekta kao i diskontirano razdoblje povrata. Može se zaključiti kako se na lokaciji KOS ulaganje u kvalitativno zoniranje i selektivnu berbu u kojem proizvođač sam provodi kvalitativno zoniranje i selektivnu berbu ne isplati u petogodišnjem razdoblju procjene isplativosti projekta, dok se ulaganje u kojem proizvođač koristi usluge specijalizirane tvrtke za snimanje bespilotnom letjelicom i obradu i analizu prikupljenih podataka, a pritom sam provodi selektivnu berbu isplati prema svim financijskim kriterijima, a povrat ulaganja može se očekivati u trećoj godini.

S obzirom na dobivene rezultate pri izračunima financijskih kriterija za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Kraljevina' na lokaciji KOS (0,47 ha) u razdoblju od 2019.- 2023. godine za scenarije A i B, vidljivo je da je petogodišnje

razdoblje efektuiranja projekta nedostatno za kvalitetnu procjenu ulaganja te je napravljena dodatna analiza računa dobiti i gubitka kao i izračun financijskih kriterija za desetogodišnje razdoblje efektuiranja projekta (2019.- 2028. godina) uz pretpostavku nabave nove opreme (bespilotne letjelice, dodatne baterije i računala) na kraju pete godine efektuiranja projekta (u 2023. godini) pri čemu je trošak te opreme diskontiran na sadašnju vrijednost uz diskontnu stopu od 10%. Naime, kako je već ranije navedeno, povećanje mogućih ukupnih prihoda ovisno je ponajviše o sorti grožđa te o tipu vina koje se proizvodi. Kod sorte 'Kraljevina' na lokaciji KOS vidljivo je najmanje povećanje prihoda od proizvodnje vina uz selektivnu berbu te je time i samoj investiciji potreban duži vremenski period kako bi pokazala svoju isplativost. Stoga je za lokaciju KOS napravljena dodatna analiza za desetogodišnji period efektuiranja projekta.

Tablica 68. Račun dobiti i gubitka za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Kraljevina' na lokaciji KOS (0,47 ha) u razdoblju od 2019.- 2028. godine za scenarij A

		SCENARIJ A									
	GODINA	**2019**	**2020**	**2021**	**2022**	**2023**	**2024**	**2025**	**2026**	**2027**	**2028**
A	**PRIHODI**	**38.244,85**	**34.850,20**	**36.547,52**	**36.547,52**	**36.547,52**	**36.547,52**	**36.547,52**	**36.547,52**	**36.547,52**	**36.547,52**
B	**RASHODI**										
1.	Ručno uzorkovanje na ciljanim trsovima	282,00	282,00	282,00	282,00	282,00	282,00	282,00	282,00	282,00	282,00
2.	Edukacija o primjeni bespilotnih letjelica	1.500,00	1.500,00	1.500,00	1.500,00	1.500,00	1.500,00	1.500,00	1.500,00	1.500,00	1.500,00
3.	Edukacija o obradi prikupljenih podataka	2.000,00	2.000,00	2.000,00	2.000,00	2.000,00	2.000,00	2.000,00	2.000,00	2.000,00	2.000,00
4.	Provedba snimanja bespilotnom letjelicom	450,00	450,00	450,00	450,00	450,00	450,00	450,00	450,00	450,00	450,00
5.	Obrada podataka	450,00	450,00	450,00	450,00	450,00	450,00	450,00	450,00	450,00	450,00
6.	Selektivna berba	2.585,00	2.585,00	2.585,00	2.585,00	2.585,00	2.585,00	2.585,00	2.585,00	2.585,00	2.585,00
7.	Dodatni troškovi selektivne berbe	587,50	587,50	587,50	587,50	587,50	587,50	587,50	587,50	587,50	587,50
	UKUPNO VARIJABILNI TROŠKOVI	7.854,50	7.854,50	7.854,50	7.854,50	7.854,50	7.854,50	7.854,50	7.854,50	7.854,50	7.854,50
8.	Bespilotna letjelica DJI Phantom 4 Multispectral	8.400,00	8.400,00	8.400,00	8.400,00	8.400,00	5.215,74	5.215,74	5.215,74	5.215,74	5.215,74
9.	Dodatna baterija	1.250,00	0,00	0,00	0,00	776,15	0,00	0,00	0,00	0,00	0,00
10.	Računalo	2.000,00	2.000,00	2.000,00	2.000,00	2.000,00	1.241,84	1.241,84	1.241,84	1.241,84	1.241,84
11.	Programski paket Pix4D	4.000,00	4.000,00	4.000,00	4.000,00	4.000,00	0,00	0,00	0,00	0,00	0,00

12.	DPO Crew obuka za pilota drona- trodnevna	3.950,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
13.	Edukacija (Pix4D fields)	7.500,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
14.	Osiguranje bespilotne letjelice	7.500,00	7.500,00	7.500,00	7.500,00	7.500,00	7.500,00	7.500,00	7.500,00	7.500,00	7.500,00
	UKUPNO FIKSNI TROŠKOVI	34.600,00	21.900,00	21.900,00	21.900,00	22.676,15	13.957,58	13.957,58	13.957,58	13.957,58	13.957,58
B	**UKUPNO RASHODI**	**42.454,50**	**29.754,50**	**29.754,50**	**29.754,50**	**30.754,50**	**21.812,08**	**21.812,08**	**21.812,08**	**21.812,08**	**21.812,08**
C	**BRUTO DOBIT**	**-4.209,65**	**5.095,70**	**6.793,02**	**6.793,02**	**6.016,87**	**14.735,44**	**14.735,44**	**14.735,44**	**14.735,44**	**14.735,44**
	POREZ NA DOBIT (10%)	0,00	509,57	679,30	679,30	601,69	1.473,54	1.473,54	1.473,54	1.473,54	1.473,54
D	**NETO DOBIT**	**-4.209,65**	**4.586,13**	**6.113,72**	**6.113,72**	**5.415,19**	**13.261,90**	**13.261,90**	**13.261,90**	**13.261,90**	**13.261,90**

Tablica 69. Izračun financijskih kriterija za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Kraljevina' na lokaciji KOS (0,47 ha) u razdoblju od 2019.- 2028. godine za scenarij A

	SCENARIJ A										
GODINA	**2018**	**2019**	**2020**	**2021**	**2022**	**2023**	**2024**	**2025**	**2026**	**2027**	**2028**
Primici		38.244,85	34.850,20	36.547,52	36.547,52	36.547,52	36.547,52	36.547,52	36.547,52	36.547,52	36.547,52
Izdaci		7.854,50	15.354,50	15.354,50	15.354,50	48.418,56	15.354,50	15.354,50	15.354,50	15.354,50	15.354,50
Porez		0,00	509,57	679,30	679,30	601,69	1.473,54	1.473,54	1.473,54	1.473,54	1.473,54
Ulaganje	-92.200,00										
NNT	-92.200,00	30.390,35	18.986,13	20.513,72	20.513,72	-12.472,72	19.719,48	19.719,48	19.719,48	19.719,48	19.719,48
Kumulativni NNT	-92.200,00	-61.809,65	-42.823,52	-22.309,80	-1.796,08	-14.268,80	5.450,68	25.170,16	44.889,64	64.609,12	84.328,60
Disk. NNT	-92.200,00	27.627,59	15.691,02	15.412,26	14.011,15	-7.744,58	11.131,13	10.119,21	9.199,28	8.362,98	7.602,71
Kum. Disk. NNT	-92.200,00	-64.572,41	-48.881,39	-33.469,13	-19.457,98	-27.202,56	-16.071,43	-5.952,22	3.247,06	11.610,05	19.212,76
NPV	**19.212,76**										
IRR	**15,15%**										
Razdoblje povrata	**2024 (6. godina)**										
Diskontirano razdoblje povrata	**2026 (8. godina)**										
MIRR	**13,10%**										

U tablici 68 prikazan je račun dobiti i gubitka za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Kraljevina' na lokaciji KOS (0,47 ha) u razdoblju od 2019.- 2028. godine za scenarij A, pri čemu je amortizacijsko razdoblje za opremu nabavljenu na početku projekta (bespilotna letjelica, računalo te programski paket) završeno u petogodišnjem periodu, a novo amortizacijsko razdoblje odnosi se na novo nabavljenu opremu (bespilotna letjelica i računalo) na kraju pete godine.

Iz desetogodišnjeg računa dobiti i gubitka vidljivo je da je u scenariju A (proizvođač sam provodi kvalitativno zoniranje i selektivnu berbu u vlastitom vinogradu) u prvoj godini efektuiranja projekta (2019.) u kojoj je izvršeno ulaganje od 92.200,00 kn ostvaren gubitak u iznosu od 4.209,65 kn, dok je u narednim godinama efektuiranja projekta ostvarena neto dobit u iznosu od 4.586,13 kn (2020.), 6.113,72 kn (2021.- 2022.), 5.415,19 kn (2023.) te 13.261,90 kn u posljednjih pet godina (2024.- 2028.). Iako je nabavljena nova oprema na kraju pete godine, nije došlo do pada neto dobiti.

U tablici 69 prikazan je izračun financijskih kriterija za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Kraljevina' na lokaciji KOS (0,47 ha) u razdoblju od 2019.- 2028. godine za scenarij A. Prema svim financijskim kriterijima ulaganje je isplativo (NPV je pozitivna, IRR (15,15%) je veća su od diskontne stope, mIRR (13,10%) je veća od stope reinvestiranja, razdoblje povrata ulaganja ostvareno je u šestoj godini efektuiranja projekta dok je diskontirano razdoblje povrata ostvareno u osmoj godini. Može se zaključiti kako se na lokaciji KOS ulaganje u kvalitativno zoniranje i selektivnu berbu u kojem proizvođač sam provodi kvalitativno zoniranje i selektivnu berbu isplati u desetogodišnjem razdoblju procjene isplativosti projekta, a povrat ulaganja i uz dodatne investicije u opremu, može se očekivati u šestoj godini dok je diskontirano razdoblje povrata ulaganja u osmoj godini.

Tablica 70. Račun dobiti i gubitka za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Kraljevina' na lokaciji KOS (0,47 ha) u razdoblju od 2019.- 2028. godine za scenarij B

		SCENARIJ B									
	GODINA	**2019**	**2020**	**2021**	**2022**	**2023**	**2024**	**2025**	**2026**	**2027**	**2028**
A	**PRIHODI**	**38.244,85**	**34.850,20**	**36.547,52**	**36.547,52**	**36.547,52**	**36.547,52**	**36.547,52**	**36.547,52**	**36.547,52**	**36.547,52**
B	**RASHODI**										
1.	Ručno uzorkovanje na ciljanim trsovima	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
2.	Edukacija o primjeni bespilotnih letjelica	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
3.	Edukacija o obradi prikupljenih podataka	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
4.	Provedba snimanja bespilotnom letjelicom	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
5.	Obrada podataka	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
6.	Selektivna berba	2.585,00	2.585,00	2.585,00	2.585,00	2.585,00	2.585,00	2.585,00	2.585,00	2.585,00	2.585,00
7.	Dodatni troškovi selektivne berbe	587,50	587,50	587,50	587,50	587,50	587,50	587,50	587,50	587,50	587,50
	UKUPNO VARIJABILNI TROŠKOVI	3.172,50	3.172,50	3.172,50	3.172,50	3.172,50	3.172,50	3.172,50	3.172,50	3.172,50	3.172,50
8.	Bespilotna letjelica DJI Phantom 4 Multispectral	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
9.	Dodatna baterija	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
10.	Računalo	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00

11.	Programski paket Pix4D	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
12.	DPO Crew obuka za pilota drona- trodnevna	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
13.	Edukacija (Pix4D fields)	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
14.	Osiguranje bespilotne letjelice	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
	UKUPNO FIKSNI TROŠKOVI	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
	USLUGA SPECIJALIZIRANE TVRTKE	18.000,00	18.000,00	18.000,00	18.000,00	18.000,00	18.000,00	18.000,00	18.000,00	18.000,00	18.000,00
B	**UKUPNO RASHODI**	**21.172,50**	**21.172,50**	**21.172,50**	**21.172,50**	**21.172,50**	**21.172,50**	**21.172,50**	**21.172,50**	**21.172,50**	**21.172,50**
C	**BRUTO DOBIT**	**17.072,35**	**13.677,70**	**15.375,02**	**15.375,02**	**15.375,02**	**15.375,02**	**15.375,02**	**15.375,02**	**15.375,02**	**15.375,02**
	POREZ NA DOBIT (10%)	1.707,23	1.367,77	1.537,50	1.537,50	1.537,50	1.537,50	1.537,50	1.537,50	1.537,50	1.537,50
D	**NETO DOBIT**	**15.365,11**	**12.309,93**	**13.837,52**	**13.837,52**	**13.837,52**	**13.837,52**	**13.837,52**	**13.837,52**	**13.837,52**	**13.837,52**

Tablica 71. Izračun financijskih kriterija za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Kraljevina' na lokaciji KOS (0,47 ha) u razdoblju od 2019.- 2028. godine za scenarij B

	SCENARIJ B										
GODINA	**2018**	**2019**	**2020**	**2021**	**2022**	**2023**	**2024**	**2025**	**2026**	**2027**	**2028**
Primici		38.244,85	34.850,20	36.547,52	36.547,52	36.547,52	36.547,52	36.547,52	36.547,52	36.547,52	36.547,52
Izdaci		3.172,50	3.172,50	3.172,50	3.172,50	3.172,50	3.172,50	3.172,50	3.172,50	3.172,50	3.172,50
Porez		1.707,23	1.367,77	1.537,50	1.537,50	1.537,50	1.537,50	1.537,50	1.537,50	1.537,50	1.537,50
Ulaganje	-110.602,21										
NNT	-110.602,21	33.365,11	30.309,93	31.837,52	31.837,52	31.837,52	31.837,52	31.837,52	31.837,52	31.837,52	31.837,52
Kumulativni NNT	-110.602,21	-77.237,10	-46.927,16	-15.089,64	16.747,88	48.585,40	80.422,92	112.260,45	144.097,97	175.935,49	207.773,01
Disk. NNT	-110.602,21	30.331,92	25.049,53	23.920,00	21.745,46	19.768,60	17.971,45	16.337,68	14.852,44	13.502,22	12.274,74
Kum. Disk. NNT	-110.602,21	-80.270,29	-55.220,76	-31.300,76	-9.555,30	10.213,30	28.184,75	44.522,43	59.374,87	72.877,09	85.151,83
NPV	**85.151,83**										
IRR	**25,99%**										
Razdoblje povrata	**2022 (4. godina)**										
Diskontirano razdoblje povrata	**2023 (5. godina)**										
MIRR	**17,59%**										

Desetogodišnja analiza i račun dobiti i gubitka u scenariju B (proizvođač koristi usluge specijalizirane tvrtke za snimanje bespilotnom letjelicom i obradu i analizu prikupljenih podataka dok selektivnu berbu provodi sam) pokazuju kako je ostvarena neto dobit u svim godinama efektuiranja projekta i to u iznosu od 15.365,11 kn (2019.); 12.309,93 kn (2020.) te 13.837,52 kn (2021.- 2028.) što je vidljivo u tablici 70.
U tablici 71 prikazan je izračun financijskih kriterija za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Kraljevina' na lokaciji KOS (0,47 ha) u razdoblju od 2019.- 2028. godine za scenarij B. Prema svim financijskim kriterijima ulaganje je isplativo (NPV je pozitivna, IRR (25,99%) je veća od diskontne stope, mIRR (17,59%) je veća od stope reinvestiranja), dok je razdoblje povrata ostvareno u četvrtoj godini, a diskontirano razdoblje povrata u petoj godini efektuiranja projekta. Može se zaključiti kako se na lokaciji KOS ulaganje u kvalitativno zoniranje i selektivnu berbu isplati prema svim financijskim kriterijima u desetogodišnjem razdoblju, pri čemu ulaganje u scenariju B u kojem proizvođač koristi usluge specijalizirane tvrtke za snimanje bespilotnom letjelicom i obradu i analizu prikupljenih podataka, proizvođaču donosi veću profitabilnost, a time i veću neto dobit.

Na ostale tri promatrane lokacije (PUHELEK- PUREK, ŠEMBER i TOMAC) petogodišnje razdoblje efektuiranja projekta bilo je zadovoljavajuće za kvalitetnu procjenu investicije za ulaganje u kvalitativno zoniranje i selektivnu berbu putem financijskih kriterija te su rezultati prikazani u tablicama 72-77.

Tablica 72. Račun dobiti i gubitka za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Kraljevina' na lokaciji PUHELEK- PUREK (0,93 ha) u razdoblju od 2020.- 2024. godine za scenarije A i B

		SCENARIJ A					SCENARIJ B				
	GODINA	**2020**	**2021**	**2022**	**2023**	**2024**	**2020**	**2021**	**2022**	**2023**	**2024**
A	**PRIHODI**	**200.193,81**	**200.193,81**	**200.193,81**	**200.193,81**	**200.193,81**	**200.193,81**	**200.193,81**	**200.193,81**	**200.193,81**	**200.193,81**
B	**RASHODI**										
1.	Ručno uzorkovanje na ciljanim trsovima	558,00	558,00	558,00	558,00	558,00	0,00	0,00	0,00	0,00	0,00
2.	Edukacija o primjeni bespilotnih letjelica	1.500,00	1.500,00	1.500,00	1.500,00	1.500,00	0,00	0,00	0,00	0,00	0,00
3.	Edukacija o obradi prikupljenih podataka	2.000,00	2.000,00	2.000,00	2.000,00	2.000,00	0,00	0,00	0,00	0,00	0,00
4.	Provedba snimanja bespilotnom letjelicom	450,00	450,00	450,00	450,00	450,00	0,00	0,00	0,00	0,00	0,00
5.	Obrada podataka	450,00	450,00	450,00	450,00	450,00	0,00	0,00	0,00	0,00	0,00
6.	Selektivna berba	5.115,00	5.115,00	5.115,00	5.115,00	5.115,00	5.115,00	5.115,00	5.115,00	5.115,00	5.115,00
7.	Dodatni troškovi selektivne berbe	1.162,50	1.162,50	1.162,50	1.162,50	1.162,50	1.162,50	1.162,50	1.162,50	1.162,50	1.162,50
	UKUPNO VARIJABILNI TROŠKOVI	11.235,00	11.235,00	11.235,00	11.235,00	11.235,00	6.277,50	6.277,50	6.277,50	6.277,50	6.277,50
8.	Bespilotna letjelica DJI Phantom 4 Multispectral	8.400,00	8.400,00	8.400,00	8.400,00	8.400,00	0,00	0,00	0,00	0,00	0,00
9.	Dodatna baterija	1.250,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
10.	Računalo	2.000,00	2.000,00	2.000,00	2.000,00	2.000,00	0,00	0,00	0,00	0,00	0,00

11.	Programski paket Pix4D	4.000,00	4.000,00	4.000,00	4.000,00	4.000,00	0,00	0,00	0,00	0,00	0,00
12.	DPO Crew obuka za pilota drona- trodnevna	3.950,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
13.	Edukacija (Pix4D fields)	7.500,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
14.	Osiguranje bespilotne letjelice	7.500,00	7.500,00	7.500,00	7.500,00	7.500,00	0,00	0,00	0,00	0,00	0,00
	UKUPNO FIKSNI TROŠKOVI	34.600,00	21.900,00	21.900,00	21.900,00	21.900,00	0,00	0,00	0,00	0,00	0,00
	USLUGA SPECIJALIZIRANE TVRTKE	0,00	0,00	0,00	0,00	0,00	18.000,00	18.000,00	18.000,00	18.000,00	18.000,00
B	**UKUPNO RASHODI**	**45.835,50**	**33.135,50**	**33.135,50**	**33.135,50**	**33.135,50**	24.277,50	24.277,50	24.277,50	24.277,50	24.277,50
C	**BRUTO DOBIT**	**154.358,31**	**167.058,31**	**167.058,31**	**167.058,31**	**167.058,31**	**175.916,31**	**175.916,31**	**175.916,31**	**175.916,31**	**175.916,31**
	POREZ NA DOBIT (10%)	15.435,83	16.705,83	16.705,83	16.705,83	16.705,83	**17.591,63**	**17.591,63**	**17.591,63**	**17.591,63**	**17.591,63**
D	**NETO DOBIT**	**138.922,48**	**150.352,48**	**150.352,48**	**150.352,48**	**150.352,48**	**158.324,68**	**158.324,68**	**158.324,68**	**158.324,68**	**158.324,68**

Tablica 73. Izračun financijskih kriterija za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Kraljevina' na lokaciji PUHELEK- PUREK (0,93 ha) u razdoblju od 2020.- 2024. godine za scenarije A i B

	SCENARIJ A						SCENARIJ B					
GODINA	**2019**	**2020**	**2021**	**2022**	**2023**	**2024**	**2019**	**2020**	**2021**	**2022**	**2023**	**2024**
Primitci		200.193,81	200.193,81	200.193,81	200.193,81	200.193,81		200.193,81	200.193,81	200.193,81	200.193,81	200.193,81
Izdaci		11.235,50	18.735,50	18.735,50	18.735,50	18.735,50		6.277,50	6.277,50	6.277,50	6.277,50	6.277,50
Porez		15.435,83	16.705,83	16.705,83	16.705,83	16.705,83		17.591,63	17.591,63	17.591,63	17.591,63	17.591,63
Ulaganje	-92.200,00						-68.234,16					
NNT	-92.200,00	173.522,48	164.752,48	164.752,48	164.752,48	164.752,48	-68.234,16	176.324,68	176.324,68	176.324,68	176.324,68	176.324,68
Kumulativni NNT	-92.200,00	81.322,48	246.074,96	410.827,44	575.579,92	740.332,40	-68.234,16	108.090,52	284.415,20	460.739,88	637.064,56	813.389,24
Disk. NNT	-92.200,00	157.747,71	136.159,07	123.780,98	112.528,16	102.298,33	-68.234,16	160.295,16	145.722,88	132.475,34	120.432,13	109.483,75
Kum. Disk. NNT	-92.200,00	65.547,71	201.706,78	325.487,76	438.015,92	540.314,25	-68.234,16	92.061,00	237.783,88	370.259,22	490.691,35	600.175,10
NPV	**540.314,25**						**600.175,10**					
IRR	**183,88%**						**257,97%**					
Razdoblje povrata	**2020 (1. godina)**						**2020 (1. godina)**					
Diskontirano razdoblje povrata	**2020 (1. godina)**						**2020 (1. godina)**					
MIRR	**62,99%**						**75,01%**					

U tablici 72 prikazan je račun dobiti i gubitka za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Kraljevina' na lokaciji PUHELEK- PUREK (0,93 ha) u razdoblju od 2020.- 2024. godine za scenarije A i B. Iz računa dobiti i gubitka u oba scenarija vidljivo je da je u svim godinama efektuiranja projekta ostvarena značajna neto dobit.

U tablici 73 prikazani su izračuni financijskih kriterija za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Kraljevina' na lokaciji PUHELEK- PUREK (0,93 ha) u razdoblju od 2020.- 2024. godine za scenarije A i B. Prema financijskom kriteriju čiste sadašnje vrijednosti (NPV) u oba scenarija može se zaključiti kako je ulaganje isplativo jer je vrijednost pozitivna. U scenariju A interna stopa profitabilnosti (IRR) iznosi 183,88%, a modificirana interna stopa profitabilnosti (mIRR) iznosi 62,99% te se može zaključiti kako je ulaganje u scenariju A isplativo jer je IRR viša od diskontne stope (10%), a mIRR viša od stope reinvestiranja (12%) odnosno IRR je viša od potrebne stope povrata ulaganja, a mIRR je viša od potrebne granične stope povrata ulaganja. Isto tako, vidljivo je da su razdoblje povrata i diskontirano razdoblje povrata ulaganja u scenariju A ostvareni već u prvoj godini efektuiranja projekta (2020.) te se može zaključiti kako je ovo ulaganje isplativo u scenariju A u najkraćem mogućem roku. I u scenariju B, prema svim financijskim kriterijima ulaganje je isplativo (NPV je pozitivna, IRR (257,97%) je veća od diskontne stope, mIRR (75,01%) je veća od stope reinvestiranja), dok je razdoblje povrata i diskontirano razdoblje povrata ostvareno već u prvoj godini efektuiranja projekta. Može se zaključiti kako se na lokaciji PUHELEK- PUREK ulaganje u kvalitativno zoniranje i selektivnu berbu isplati prema svim financijskim kriterijima u najkraćem mogućem roku (prva godina efektuiranja projekta), pri čemu ulaganje u scenariju B u kojem proizvođač koristi usluge specijalizirane tvrtke za snimanje bespilotnom letjelicom i obradu i analizu prikupljenih podataka, proizvođaču donosi veću profitabilnost, a time i veću neto dobit.

Tablica 74. Račun dobiti i gubitka za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Pinot crni' na lokaciji TOMAC (0,33 ha) u razdoblju od 2019.- 2023. godine za scenarije A i B

		SCENARIJ A					SCENARIJ B				
	GODINA	**2019**	**2020**	**2021**	**2022**	**2023**	**2019**	**2020**	**2021**	**2022**	**2023**
A	**PRIHODI**	**103.980,47**	**107.048,62**	**105.514,54**	**105.514,54**	**105.514,54**	**103.980,47**	**107.048,62**	**105.514,54**	**105.514,54**	**105.514,54**
B	**RASHODI**										
1.	Ručno uzorkovanje na ciljanim trsovima	198,00	198,00	198,00	198,00	198,00	0,00	0,00	0,00	0,00	0,00
2.	Edukacija o primjeni bespilotnih letjelica	1.500,00	1.500,00	1.500,00	1.500,00	1.500,00	0,00	0,00	0,00	0,00	0,00
3.	Edukacija o obradi prikupljenih podataka	2.000,00	2.000,00	2.000,00	2.000,00	2.000,00	0,00	0,00	0,00	0,00	0,00
4.	Provedba snimanja bespilotnom letjelicom	450,00	450,00	450,00	450,00	450,00	0,00	0,00	0,00	0,00	0,00
5.	Obrada podataka	450,00	450,00	450,00	450,00	450,00	0,00	0,00	0,00	0,00	0,00
6.	Selektivna berba	1.815,00	1.815,00	1.815,00	1.815,00	1.815,00	1.815,00	1.815,00	1.815,00	1.815,00	1.815,00
7.	Dodatni troškovi selektivne berbe	412,50	412,50	412,50	412,50	412,50	412,50	412,50	412,50	412,50	412,50
	UKUPNO VARIJABILNI TROŠKOVI	6.825,50	6.825,50	6.825,50	6.825,50	6.825,50	2.227,50	2.227,50	2.227,50	2.227,50	2.227,50
8.	Bespilotna letjelica DJI Phantom 4 Multispectral	8.400,00	8.400,00	8.400,00	8.400,00	8.400,00	0,00	0,00	0,00	0,00	0,00
9.	Dodatna baterija	1.250,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
10.	Računalo	2.000,00	2.000,00	2.000,00	2.000,00	2.000,00	0,00	0,00	0,00	0,00	0,00
11.	Programski paket Pix4D	4.000,00	4.000,00	4.000,00	4.000,00	4.000,00	0,00	0,00	0,00	0,00	0,00

12.	DPO Crew obuka za pilota drona- trodnevna	3.950,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
13.	Edukacija (Pix4D fields)	7.500,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
14.	Osiguranje bespilotne letjelice	7.500,00	7.500,00	7.500,00	7.500,00	7.500,00	0,00	0,00	0,00	0,00	0,00
	UKUPNO FIKSNI TROŠKOVI	34.600,00	21.900,00	21.900,00	21.900,00	21.900,00	0,00	0,00	0,00	0,00	0,00
	USLUGA SPECIJALIZIRANE TVRTKE	0,00	0,00	0,00	0,00	0,00	18.000,00	18.000,00	18.000,00	18.000,00	18.000,00
B	**UKUPNO RASHODI**	**41.425,50**	**28.725,50**	**28.725,50**	**28.725,50**	**28.725,50**	**20.227,50**	**20.227,50**	**20.227,50**	**20.227,50**	**20.227,50**
C	**BRUTO DOBIT**	**62.554,97**	**78.323,12**	**76.789,04**	**76.789,04**	**76.789,04**	**83.752,97**	**86.821,12**	**85.287,04**	**85.287,04**	**85.287,04**
	POREZ NA DOBIT (10%)	6.255,50	7.832,31	7.678,90	7.678,90	7.678,90	8.375,30	8.682,11	8.528,70	8.528,70	8.528,70
D	**NETO DOBIT**	**56.299,48**	**70.490,80**	**69.110,14**	**69.110,14**	**69.110,14**	**75.377,68**	**78.139,00**	**76.758,34**	**76.758,34**	**76.758,34**

Tablica 75. Izračun financijskih kriterija za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Pinot crni' na lokaciji TOMAC (0,33 ha) u razdoblju od 2019.- 2023. godine za scenarije A i B

	SCENARIJ A						SCENARIJ B					
GODINA	**2018**	**2019**	**2020**	**2021**	**2022**	**2023**	**2018**	**2019**	**2020**	**2021**	**2022**	**2023**
Primici		103.980,47	107.048,62	105.514,54	105.514,54	105.514,54		103.980,47	107.048,62	105.514,54	105.514,54	105.514,54
Izdaci		6.825,50	14.325,50	14.325,50	14.325,50	14.325,50		2.227,50	2.227,50	2.227,50	2.227,50	2.227,50
Porez		6.255,50	7.832,31	7.678,90	7.678,90	7.678,90		8.375,30	8.682,11	8.528,70	8.528,70	8.528,70
Ulaganje	-92.200,00						-68.234,16					
NNT	-92.200,00	90.899,48	84.890,80	83.510,14	83.510,14	83.510,14	-68.234,16	93.377,68	96.139,00	94.758,34	94.758,34	94.758,34
Kumulativni NNT	-92.200,00	-1.300,52	83.590,28	167.100,42	250.610,56	334.120,70	-68.234,16	25.143,51	121.282,52	216.040,86	310.799,20	405.557,54
Disk. NNT	-92.200,00	82.635,89	70.157,69	62.742,40	57.038,55	51.853,23	-68.234,16	84.888,80	79.453,72	71.193,34	64.721,22	58.837,47
Kum. Disk. NNT	-92.200,00	-9.564,11	60.593,58	123.335,98	180.374,53	232.227,76	-68.234,16	16.64,63	98.108,36	163.301,70	232.022,92	290.860,40
NPV	**232.227,76**						**290.860,40**					
IRR	**91,23%**						**136,31%**					
Razdoblje povrata	**2020 (2. godina)**						**2019 (1. godina)**					
Diskontirano razdoblje povrata	**2020 (2. godina)**						**2019 (1. godina)**					
MIRR	**42,62%**						**54,56%**					

U tablici 74 prikazan je račun dobiti i gubitka za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Pinot crni' na lokaciji TOMAC (0,33 ha) u razdoblju od 2019.- 2023. godine za scenarije A i B. Iz računa dobiti i gubitka u oba scenarija vidljivo je da je u svim godinama efektuiranja projekta ostvarena neto dobit.

U tablici 75 prikazani su izračuni financijskih kriterija za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Pinot crni' na lokaciji TOMAC (0,33 ha) u razdoblju od 2019.- 2023. godine za scenarije A i B. Prema financijskom kriteriju čiste sadašnje vrijednosti (NPV) u oba scenarija može se zaključiti kako je ulaganje isplativo jer je vrijednost pozitivna. U scenariju A interna stopa profitabilnosti (IRR) iznosi 91,23%, a modificirana interna stopa profitabilnosti (mIRR) iznosi 42,62% te se može zaključiti kako je ulaganje u scenariju A isplativo jer je IRR viša od diskontne stope (10%), a mIRR viša od stope reinvestiranja (12%) odnosno IRR je viša od potrebne stope povrata ulaganja, a mIRR je viša od potrebne granične stope povrata ulaganja. Isto tako, vidljivo je da su razdoblje povrata i diskontirano razdoblje povrata ulaganja u scenariju A ostvareni u drugoj godini efektuiranja projekta (2020.) te se može zaključiti kako je ovo ulaganje isplativo u scenariju A. I u scenariju B, prema svim financijskim kriterijima ulaganje je isplativo (NPV je pozitivna, IRR (136,31%) je veća su od diskontne stope, mIRR (54,56%) je veća od stope reinvestiranja), dok je razdoblje povrata ostvareno već u prvoj godini efektuiranja projekta, a diskontirano razdoblje povrata u drugoj godini efektuiranja projekta. Može se zaključiti kako se na lokaciji TOMAC ulaganje u kvalitativno zoniranje i selektivnu berbu isplati prema svim financijskim kriterijima u vrlo kratkom roku (druga godina efektuiranja projekta), pri čemu ulaganje u scenariju B u kojem proizvođač koristi usluge specijalizirane tvrtke za snimanje bespilotnom letjelicom i obradu i analizu prikupljenih podataka, proizvođaču donosi veću profitabilnost, a time i veću neto dobit.

Tablica 76. Račun dobiti i gubitka za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Pinot crni' na lokaciji ŠEMBER (0,65 ha) u razdoblju od 2019.- 2023. godine za scenarije A i B

		SCENARIJ A					SCENARIJ B				
	GODINA	**2019**	**2020**	**2021**	**2022**	**2023**	**2019**	**2020**	**2021**	**2022**	**2023**
A	**PRIHODI**	**363.885,31**	**263.343,46**	**313.614,38**	**313.614,38**	**313.614,38**	**363.885,31**	**263.343,46**	**313.614,38**	**313.614,38**	**363.885,31**
B	**RASHODI**										
1.	Ručno uzorkovanje na ciljanim trsovima	390,00	390,00	390,00	390,00	390,00	0,00	0,00	0,00	0,00	0,00
2.	Edukacija o primjeni bespilotnih letjelica	1.500,00	1.500,00	1.500,00	1.500,00	1.500,00	0,00	0,00	0,00	0,00	0,00
3.	Edukacija o obradi prikupljenih podataka	2.000,00	2.000,00	2.000,00	2.000,00	2.000,00	0,00	0,00	0,00	0,00	0,00
4.	Provedba snimanja bespilotnom letjelicom	450,00	450,00	450,00	450,00	450,00	0,00	0,00	0,00	0,00	0,00
5.	Obrada podataka	450,00	450,00	450,00	450,00	450,00	0,00	0,00	0,00	0,00	0,00
6.	Selektivna berba	3.575,00	3.575,00	3.575,00	3.575,00	3.575,00	3.575,00	3.575,00	3.575,00	3.575,00	3.575,00
7.	Dodatni troškovi selektivne berbe	812,50	812,50	812,50	812,50	812,50	812,50	812,50	812,50	812,50	812,50
	UKUPNO VARIJABILNI TROŠKOVI	9.177,50	9.177,50	9.177,50	9.177,50	9.177,50	4.387,50	4.387,50	4.387,50	4.387,50	4.387,50
8.	Bespilotna letjelica DJI Phantom 4 Multispectral	8.400,00	8.400,00	8.400,00	8.400,00	8.400,00	0,00	0,00	0,00	0,00	0,00
9.	Dodatna baterija	1.250,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
10.	Računalo	2.000,00	2.000,00	2.000,00	2.000,00	2.000,00	0,00	0,00	0,00	0,00	0,00

11.	Programski paket Pix4D	4.000,00	4.000,00	4.000,00	4.000,00	4.000,00	0,00	0,00	0,00	0,00	0,00
12.	DPO Crew obuka za pilota drona- trodnevna	3.950,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
13.	Edukacija (Pix4D fields)	7.500,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
14.	Osiguranje bespilotne letjelice	7.500,00	7.500,00	7.500,00	7.500,00	7.500,00	0,00	0,00	0,00	0,00	0,00
	UKUPNO FIKSNI TROŠKOVI	34.600,00	21.900,00	21.900,00	21.900,00	21.900,00	0,00	0,00	0,00	0,00	0,00
	USLUGA SPECIJALIZIRANE TVRTKE	0,00	0,00	0,00	0,00	0,00	18.000,00	18.000,00	18.000,00	18.000,00	18.000,00
B	**UKUPNO RASHODI**	**43.777,50**	**31.077,50**	**31.077,50**	**31.077,50**	**31.077,50**	**22.387,50**	**22.387,50**	**22.387,50**	**22.387,50**	**22.387,50**
C	**BRUTO DOBIT**	**320.107,81**	**232.265,96**	**282.536,88**	**282.536,88**	**282.536,88**	**341.497,81**	**240.955,96**	**291.226,88**	**291.226,88**	**291.226,88**
	POREZ NA DOBIT (10%)	32.010,78	23.226,60	28.253,69	28.253,69	28.253,69	34.149,78	24.095,60	29.122,69	29.122,69	29.122,69
D	**NETO DOBIT**	**288.097,03**	**209.039,36**	**254.283,20**	**254.283,20**	**254.283,20**	**307.348,03**	**216.860,36**	**262.104,20**	**262.104,20**	**262.104,20**

Tablica 77. Izračun financijskih kriterija za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Pinot crni' na lokaciji ŠEMBER (0,65 ha) u razdoblju od 2019.- 2023. godine za scenarije A i B

	SCENARIJ A						SCENARIJ B					
GODINA	**2018**	**2019**	**2020**	**2021**	**2022**	**2023**	**2018**	**2019**	**2020**	**2021**	**2022**	**2023**
Primici		363.885,31	263.343,46	313.614,38	313.614,38	313.614,38		363.885,31	263.343,46	313.614,38	313.614,38	313.614,38
Izdaci		9.177,50	16.677,50	16.677,50	16.677,50	16.677,50		4.387,50	4.387,50	4.387,50	4.387,50	4.387,50
Porez		32.010,78	23.226,60	28.253,69	28.253,69	28.253,69		34.149,78	24.095,60	29.122,69	29.122,69	29.122,69
Ulaganje	-92.200,00						-68.234,16					
NNT	-92.200,00	322.697,03	223.439,36	268.683,20	268.683,20	268.683,20	-68.234,16	325.348,03	234.860,36	280.104,20	280.104,20	280.104,20
Kumulativni NNT	-92.200,00	230.497,03	453.936,39	722.619,59	991.302,78	1.259.985,98	-68.234,16	257.113,87	491.974,23	772.078,42	1.052.182,62	1.332.286,81
Disk. NNT	-92.200,00	293.360,93	184.660,63	201.865,66	183.514,24	166.831,12	-68.234,16	295.770,93	194.099,47	210.446,43	191.314,93	173.922,67
Kum. Disk. NNT	-92.200,00	201.160,93	385.821,56	587.687,23	771.201,46	938.032,59	-68.234,16	227.536,77	421.636,25	632.082,67	823.397,61	997.320,27
NPV	**938.032,59**						**997.320,27**					
IRR	**327,28%**						**454,99%**					
Razdoblje povrata	**2019 (1. godina)**						**2019 (1. godina)**					
Diskontirano razdoblje povrata	**2019 (1. godina)**						**2019 (1. godina)**					
MIRR	**79,71%**						**92,14%**					

U tablici 76 prikazan je račun dobiti i gubitka za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Pinot crni' na lokaciji ŠEMBER (0,65 ha) u razdoblju od 2019.-2023. godine za scenarije A i B. Iz računa dobiti i gubitka u oba scenarija vidljivo je da je u svim godinama efektuiranja projekta ostvarena značajna neto dobit.
U tablici 77 prikazani su izračuni financijskih kriterija za ulaganje u kvalitativno zoniranje i selektivnu berbu sorte 'Pinot crni' na lokaciji ŠEMBER (0,65 ha) u razdoblju od 2019.-2023. godine za scenarije A i B. Prema financijskom kriteriju čiste sadašnje vrijednosti (NPV) u oba scenarija može se zaključiti kako je ulaganje isplativo jer je vrijednost pozitivna. U scenariju A interna stopa profitabilnosti (IRR) iznosi 327,28%, a modificirana interna stopa profitabilnosti (mIRR) iznosi 79,71% te se može zaključiti kako je ulaganje u scenariju A isplativo jer je IRR višestruko viša od diskontne stope (10%), a mIRR viša od stope reinvestiranja (12%) odnosno IRR je viša od potrebne stope povrata ulaganja, a mIRR je viša od potrebne granične stope povrata ulaganja. Isto tako, vidljivo je da su razdoblje povrata i diskontirano razdoblje povrata ulaganja u scenariju A ostvareni u već u prvoj godini efektuiranja projekta (2019.) te se može zaključiti kako je ovo ulaganje isplativo u scenariju A. I u scenariju B, prema svim financijskim kriterijima ulaganje je isplativo (NPV je pozitivna, IRR (454,99%) je veća su od diskontne stope, mIRR (92,14%) je veća od stope reinvestiranja), dok je razdoblje povrata i diskontirano razdoblje povrata ostvareno već u prvoj godini efektuiranja projekta. Može se zaključiti kako se na lokaciji ŠEMBER ulaganje u kvalitativno zoniranje i selektivnu berbu isplati prema svim financijskim kriterijima u najkraćem mogućem roku (prva godina efektuiranja projekta), pri čemu ulaganje u scenariju B u kojem proizvođač koristi usluge specijalizirane tvrtke za snimanje bespilotnom letjelicom i obradu i analizu prikupljenih podataka, proizvođaču donosi veću profitabilnost, a time i veću neto dobit.

Iz svih navedenih izračuna vidljivo kako su svi financijski kriteriji pokazali da korištenje kvalitativnog zoniranja i selektivne berbe za proizvodnju dva različita tipa vina iz istog vinograda, uz korištenje kvalitativnog zoniranja i selektivne berbe, može dovesti do povećanja financijske koristi za vinogradara, osim na lokaciji KOS u scenariju A u petogodišnjem razdoblju efektuiranja projekta, gdje financijski kriteriji ne opravdavaju ulaganje u kupnju opreme i provedbu kvalitativnog zoniranja i selektivne berbe od strane proizvođača.

5. RASPRAVA

5.1. Primjena vegetacijskih indeksa za kvalitativno zoniranje vinograda

Dvogodišnje istraživanje mogućnosti primjene tri različita vegetacijska indeksa- NDVI, NDRE i OSAVI za kvalitativno zoniranje vinograda pokazalo je kako su vegetacijski indeksi učinkovit alat za procjenu bujnosti i varijabilnosti u vinogradu te kako uspješno opisuju i povezuju određene karakteristike vinove loze, kao što su sastavnice prinosa i kvalitativna svojstva grožđa, s rezultatima spektralnih mjerenja.

Pri utvrđivanju povezanosti vegetacijskih indeksa (NDVI, NDRE, OSAVI) i bujnosti utvrđeno je da podaci prikupljeni ručnim uzorkovanjem koji mogu biti prediktori bujnosti u vinogradu (broj mladica, broj nodija, masa orezane rozgve (kg)) nisu dostatni za utvrđivanje povezanosti vegetacijskih indeksa u različitim fenofazama razvoja vinove loze i bujnosti. Naime, vegetacijske indekse potrebno je promatrati kao pokazatelje fotosintetski aktivne vegetacije (Lamb i sur., 2004; Fiorillo i sur., 2012) prisutne u određenoj fenofazi razvoja vinove loze koji govore o strukturnim i biokemijskim parametrima trsa (Fiorillo i sur., 2012) te mogu detektirati varijabilnost mnogih svojstava vinove loze unutar vinograda. Nadalje, da bi se procijenila varijabilnost vegetativnih parametara, odnosno bujnosti unutar vinograda potrebno je mjerenje više sastavnica vinove loze koje utječu na vegetativni rast i razvoj trsa (indeks lisne površine, promjer poprečnog presjeka mladica, porast mladica, vodni potencijal lista, potencijalna izložena lisna površina, dostupnost vode i hranjiva i sl.) što u svojim istraživanjima potvrđuju Santesteban i sur. (2013), Bonilla i sur. (2015), Gatti i sur. (2017), Reynolds i sur. (2018), Ferrer i sur. (2020) i mnogi drugi. Samim time, u ovom istraživanju klasterizacija ciljanih trsova na osnovu mjerenih vegetativnih parametara nije rezultirala zadovoljavajućim klasterima jer broj mladica i broj nodija korelira s opterećenjem trsa u rezidbi što je prilično uniformno u svakom vinogradu u kojem je provedeno istraživanje, a takav rezultat potvrđuju i Gatti i sur. (2017). Tek daljnji vegetativni i generativni razvoj vinove loze u toku vegetacije može pokazati razlike u bujnosti koje ovise i o mnoštvu drugih čimbenika (temperatura, vlaga, dostupnost hranjiva, zdravstveno stanje i sl.). Također, potrebno je ručna mjerenja vegetativnih parametara povezati s terminima u kojima se vrše spektralna mjerenja, što proizlazi iz dosadašnjih istraživanja (Fiorillo i sur., 2012; Santesteban i sur., 2013; Bonilla i sur. 2015; Reynolds i sur. 2018; i dr.) u kojima su mjerenja više sastavnica vinove loze koje utječu na vegetativni rast i razvoj trsa provedena u terminu bliskom spektralnim mjerenjima. Stoga, na osnovu nekoliko mjerenih vegetativnih parametara u

fenofazi koja se ne poklapa s fenofazama provedenih snimanja nije bilo moguće potvrditi postojanje razlike u povezanosti vegetacijskih indeksa i bujnosti u različitim fenofazama razvoja vinove loze te su potrebna dodatna istraživanja, analize i mjerenja više sastavnica vinove loze koje utječu na vegetativni rast i razvoj, a time i na povezanost bujnosti s rezultatima spektralnih mjerenja. No, utvrđeno je su kako vegetacijski indeksi relevantni pokazatelji vegetativnog stanja vinove loze i dobri prediktori bujnosti u određenoj fenofazi razvoja te kako je moguće uspješno generirati različite karte bujnosti u svim fenofazama razvoja koje su pogodne za kvalitativno zoniranje vinograda kod obje istraživane sorte vinove loze. To potvrđuje većina dosadašnjih istraživanja, dok Fiorillo i sur. (2012) zaključuju kako su podaci prikupljeni zračnim snimanjima (NDVI) relevantni za karakterizaciju prostorne varijabilnosti fotosintetski aktivne biomase, a razlike u fotosintetski aktivnoj biomasi su povezane s razlikama u mjerenim kvalitativnim parametrima grožđa što ih dovodi do zaključka kako su vegetacijski indeksi pogodni za razlikovanje klasa grožđa za selektivnu berbu, odnosno za kvalitativno zoniranje vinograda.

Pri utvrđivanju povezanosti zona različite bujnosti sa sastavnicama prinosa i kvalitativnim svojstvima grožđa utvrđene su određene razlike u učinkovitosti procjene povezanosti bujnosti ovisno o korištenom vegetacijskom indeksu, ali i o terminu prikupljanja podataka multispektralnim kamerama.

5.1.1. OSAVI

OSAVI kao najmanje korišten vegetacijski indeks u dosadašnjim istraživanjima i u ovom se istraživanju pokazao najmanje prediktivan za određivanje zona bujnosti i kvalitativno zoniranje vinograda. Naime, pri statističkom preklapanju klasifikacijskih struktura: kvalitativne strukture trsova dobivene postupkom klasterizacije kvalitativnih svojstava grožđa s kvalitativnom strukturom trsova dobivenom na osnovu zoniranja uz pomoć vegetacijskog indeksa OSAVI na zone manje bujnosti (potencijalno bolja kvalitativna svojstva grožđa) i zone veće bujnosti (potencijalno lošija kvalitativna svojstva grožđa) OSAVI niti u jednom terminu prikupljanja podataka multispektralnim kamerama kao niti na jednoj lokaciji provedbe istraživanja, nije bio najprediktivniji vegetacijski indeks za određivanje zona bujnosti i kvalitativno zoniranje vinograda. Dobiveni rezultati u skladu su s dosadašnjim istraživanjima gdje je OSAVI uglavnom korišten za procjenu sadržaja dušika u vinovoj lozi (Kidman i sur., 2017) kao odgovarajućeg indeksa za ciljanu primjenu dušičnih gnojiva. Nadalje, u istraživanju autora Soubry i sur. (2016) kombinirani indeks TCARI/OSAVI pokazao je najbolju korelaciju sa svojstvima kakvoće (koncentracija

šećera, pH) i vodnim stresom za procjenu zrelosti grožđa i vodnog stresa te na taj način omogućavao izbor optimalnog datuma berbe s obzirom na vodni stres. OSAVI u dosadašnjim istraživanjima nije bio isključivo korišten kao vegetacijski indeks za procjenu bujnosti vinove loze, a sukladno rezultatima provedenog istraživanja njegovo korištenje ne bi dalo odgovarajuće rezultate kojima bi se uspješno povezala bujnost vinograda i kvalitativni sastav grožđa kao osnove za kvalitativno zoniranje i selektivnu berbu. Tome u prilog govore postoci preklapanja kvalitativnih struktura izmjerenih na svim lokacijama i u svim terminima snimanja koji su se kretali od najnižeg preklapanja svih klasifikacijskih struktura uopće- 36% (lokacija KOS, rujan 2020. godine) -77% (lokacija ŠEMBER, srpanj 2020. godine), no i tako visok postotak na toj lokaciji i u tom terminu bio je niži od najprediktivnijeg vegetacijskog indeksa NDVI za tu lokaciju (srpanj 2020. godine, 86%-tno preklapanje klasifikacijskih struktura). Ono što bi se još moglo razmatrati i dalje istraživati pri primjeni OSAVI vegetacijskog indeksa za određivanje zona bujnosti i kvalitativno zoniranje vinograda jest sama obrada i priprema snimki dobivenih multispektralnim kamerama. Naime, OSAVI kao vegetacijski indeks prilagođen tlu, koji eliminira utjecaj tla na analizu vegetacije (analizu sadržaja dušika i klorofila te procjenu količine nadzemnog pokrova) i koji u svom izračunu koristi faktor prilagodbe tlu (L=0.16) (Xue i Su, 2017., Fern i sur., 2018) možda nije najprikladniji za korištenje na obrađenim snimkama u kojima je provedena segmentacija (izdvajanje) redova vinove loze od tla i na kojima su na taj način već odvojeni podaci vegetacije vinove loze od tla. Istraživači koji su ga koristili u svojim istraživanjima za vinovu lozu (Soubry i sur., 2016., Kidman i sur., 2017.) nisu provodili segmentaciju redova u svojim istraživanjima. Zaključno, OSAVI vegetacijski indeks svoju primjenu može naći za određivanje sadržaja dušika u vinovoj lozi kao odgovarajući indeks za ciljanu primjenu dušičnih gnojiva u vinogradarstvu (Kidman i sur., 2017), kao vegetacijski indeks koji minimizira utjecaj visoke varijabilnosti tla na analizu vegetacije (Fern i sur., 2018.) kada se koriste snimke na kojima nije provedeno segmentiranje (izdvajanje) redova u vinogradu. Ovaj zaključak nalazi svoje opravdanje i u samoj biti korištenja vegetacijskih indeksa, jer su određeni vegetacijski indeksi vezani za određene karakteristike vegetacije i svaki od njih ima svoju kombinaciju refleksije u različitim spektralnim kanalima kako bi otkrio pojedine, specifične karakteristike vegetacije (Tsouros i sur., 2019).

5.1.2. NDVI

NDVI kao najviše korišten vegetacijski indeks u dosadašnjim istraživanjima i u ovom istraživanju pokazao se najprediktivnijim vegetacijskim indeksom za određivanje zona bujnosti i kvalitativno zoniranje vinograda. Naime, pri statističkom preklapanju

klasifikacijskih struktura: kvalitativne strukture trsova dobivene postupkom klasterizacije kvalitativnih svojstava grožđa s kvalitativnom strukturom trsova dobivenom na osnovu zoniranja uz pomoć vegetacijskog indeksa NDVI na zone manje bujnosti (potencijalno bolja kvalitativna svojstva grožđa) i zone veće bujnosti (potencijalno lošija kvalitativna svojstva grožđa) NDVI je u četiri analizirana slučaja prediktivnosti (od ukupno sedam), na četiri lokacije provedbe istraživanja, bio najprediktivniji vegetacijski indeks za određivanje zona bujnosti i kvalitativno zoniranje vinograda. U 2019. godini NDVI je bio najprediktivniji vegetacijski indeks na lokaciji TOMAC u terminu snimanja u rujnu 2019. godine odnosno u fenofazi 38 (tehnološka zrelost grožđa), dok je u 2020. godini bio najprediktivniji vegetacijski indeks na tri lokacije i dva termina prikupljanja podataka multispektralnim kamerama: KOS (kolovoz, fenofaza 36- srednje vrijednosti šećera), PUHELEK- PUREK (kolovoz, fenofaza 36- srednje vrijednosti šećera) i ŠEMBER (srpanj, fenofaza 34- početak nakupljanja šećera). Kako je većina dosadašnjih istraživanja provedena uglavnom s jednim terminom prikupljanja podataka multispektralnim kamerama i/ili satelitskim snimkama (najčešće u terminu koji odgovara fenofazi 34- početak nakupljanja šećera, odnosno nakon šare) i na osnovu toga su rađena istraživanja vezana uz određivanje zona bujnosti i kvalitativno zoniranje vinograda pomoću NDVI indeksa (Johnson i sur., 2012., Martínez-Casasnovas i sur., 2012., Filippetti i sur., 2013., Santesteban i sur., 2013., Urretavizcaya i sur., 2014., Bonilla i sur., 2015., Candiago i sur., 2015., Ortega-Blu i Molina-Roco, 2016., Gatti i sur., 2017., Matese i sur., 2017., Reynolds i sur., 2018., Ferrer i sur., 2020.) može se reći kako su dobiveni rezultati u skladu s dosad objavljenim istraživanjima, ali i kako naglašavaju potrebu daljnjeg istraživanja prediktivnosti NDVI indeksa za određivanje zona bujnosti i kvalitativno zoniranje vinograda u odnosu na termin snimanja. Lamb i sur. (2004), Fiorillo i sur. (2012), Ledderhof i sur. (2016), Padua i sur. (2019), Pastonchi i sur. (2020), Oldoni i sur. (2021) svoja istraživanja su provodili u više različitih termina prikupljanja podataka multispektralnim kamerama i/ili satelitskim snimkama tijekom vegetacije. Fiorillo i sur. (2012) su nakon provedenih snimanja u tri termina u periodu lipanj- kolovoz, zaključili kako su termini prikupljanja podataka u ranijoj fazi dozrijevanja grožđa (fenofaza 34- početak nakupljanja šećera i ranije) pokazali najbolju sposobnost razlikovanja kvalitativnih zona u odnosu na mjerene parametre kakvoće grožđa, što je potvrđeno i na lokaciji ŠEMBER u 2020. godini. Nadalje, Oldoni i sur. (2021) proveli su istraživanje koje je imalo za cilj utvrditi je li korištenje NDVI indeksa u kasnijim fazama dozrijevanja grožđa (u fenofazi 36- srednje vrijednosti šećera i u fenofazi 38- tehnološka zrelost grožđa) opravdano za kvalitativno zoniranje vinograda. Zaključili kako su NDVI karte napravljene u kasnijim fazama dozrijevanja grožđa i u normalnim klimatskim uvjetima (bez kišnih ekstrema) korisne za kvalitativno zoniranje vinove loze i omogućavaju selektivnu berbu, što je potvrđeno i na

lokacijama TOMAC (2019. godine), KOS (2020. godine) i PUHELEK- PUREK (2020. godine). Nemogućnost točnog određivanja najpogodnijeg termina prikupljanja podataka multispektralnim kamerama u svom su radu objavili Ledderhof i sur. (2016). Naime, istraživanja provedena na Pinotu crnom, s ukupno četiri različita termina snimanja multispektralnim kamerama (29.5., 1.7., 29.7., 21.8.) pokazala su mogućnost određivanja zona bujnosti i kvalitativnog zoniranja vinograda temeljem NDVI indeksa, ali nisu pronašli idealan termin snimanja koji bi najbolje predvidio bujnost i kvalitativna svojstva grožđa u berbi, što je potvrđeno i kroz ovo istraživanje. Zaključno, NDVI indeks pokazao se kao vrlo kvalitetan alat za određivanje zona bujnosti i kvalitativno zoniranje vinograda, dok je potrebno daljnje istraživanje idealnog termina prikupljanja podataka multispektralnim kamerama za određivanje zona bujnosti i kvalitativno zoniranje ovisno o klimatskim uvjetima u vegetacijskim sezonama, ali i prostornoj varijabilnosti zona bujnosti. S tim u vezi, vegetacijske sezone u ovom istraživanju bile su klimatski povoljne za uzgoj vinove loze u oba vinogorja, posebice u vinogorju Plešivica-Okić gdje nije bilo većih odstupanja klimatskih prilika od prijašnjih mjerenja, no vidljiv je različit raspored i količina oborina u oba vinogorja, posebice u vinogorju Zelina, gdje je u obje vegetacijske godine bilo više oborina od prosjeka. Prema Mirošević i sur. (2009) količina oborina u vegetaciji (IV.-IX.) je 485 mm, iz čega se može zaključiti kako su obje vegetacijske godine imale veće količine oborina u odnosu na prijašnja mjerenja (2019. godine- 629,30 mm, 2020. godine- 519,30 mm), a posebice 2019. godina kada je u vegetaciji palo 110 mm više kiše nego u 2020. godini. Količina oborina možebitno je utjecala i na samu bujnost vegetacije, potičući porast mladica i lisne mase vinove loze, a time i bujnost. Međutim, raspored oborina tijekom vegetacije bio je različit- najviše oborina palo je svibnju (175,50 mm), a 2020. godine u srpnju (187,50 mm). Nepovoljniji raspored oborina u 2019. godini, zajedno s većom količinom oborina u rujnu (137,80 mm) uzrokovao je nešto lošije zdravstveno stanje grožđa zbog prisutnosti gljivičnih bolesti, prvenstveno sive plijesni (*Botrytis cinerea*). Različiti klimatski uvjeti u vegetacijskim sezonama možebitni su uzrok nemogućnosti određivanja idealnog termina prikupljanja podataka multispektralnim kamerama za određivanje zona bujnosti i kvalitativno zoniranje, kao što u svojim radovima navode Ledderhof i sur. (2016) i Oldoni i sur. (2021). Određivanje idealnog termina prikupljanja podataka ovisi i o prostornoj varijabilnosti bujnosti u vinogradu te su potrebna dodatna istraživanja vezana uz stabilnost/varijabilnost zona bujnosti u vinogradu, koje također zahtijevaju višegodišnja praćenja istog vinograda kako bi se dobili što stabilniji obrasci prostorne varijabilnosti i time povećala točnost određivanja kvalitativnih zona i samog idealnog termina snimanja. To u svom istraživanju potvrđuju Bonilla i sur. (2014) gdje je korištenje NDVI indeksa za zoniranje dalo 45%-tnu godišnju točnost predviđenih kvalitativnih zona u svakoj od četiri godine istraživanja. Autori dalje zaključuju kako se

četverogodišnjom provedbom zoniranja točnost određivanja zona bujnosti povećala na 65%. Iste rezultate potvrđuju i Kazmierski i sur. (2011) koji su godišnju stabilnost NDVI zona bujnosti u desetogodišnjem istraživanju potvrdili u periodu od 3-5 godina (ovisno o starosti vinograda). Ledderhof i sur. (2015) istraživanjem na Pinotu crnom također su zaključili kako iz jednogodišnjeg istraživanja nije moguće dobiti vremenski stabilne obrasce varijabilnosti vinograda. Iz toga se može zaključiti kako je potrebno višegodišnje praćenje vinograda i određivanje kvalitativnih zona bujnosti putem NDVI indeksa u više različitih termina snimanja kako bi rezultati utvrđenih kvalitativnih zona bili pouzdaniji za praktično korištenje. Osim toga potrebno je pratiti i interakciju klimatskih uvjeta i karakteristika tla, dubine tla, raspoloživih hranjiva, dostupnosti vode te načina obrade i uzdržavanja vinograda kako u svojim istraživanjima navode Bramley i Hamilton (2004), Tisseyre i sur. (2008) i Bramley (2010). S tim u vezi, dva istraživana vinograda u kojima se nalazi sorta 'Pinot crni' različita su prema načinu uzdržavanja vinograda (biodinamika/konvencionalno), različita su u površini vinograda (0,33 ha/0,65 ha), starosti nasada (22 god/16 god) te podlozi na kojoj je podignut nasad (SO4/K5BB). No, sve navedene činjenice ostavljaju prostora za dodatno istraživanje utjecaja navedenih faktora na prostornu stabilnost/varijabilnost bujnosti, kao i nalaženje idealnog termina snimanja i optimalnog broja godina za povećanje točnosti utvrđivanja zona bujnosti i kvalitativnih zona putem NDVI indeksa kod sorte 'Pinot crni', kao što u svom istraživanju navodi i Ledderhof i sur. (2015). Još je možebitno važno za razmotriti i dalje istražiti utjecaj agrotehničkih mjera na prostornu stabilnost/varijabilnost zona bujnosti kao što je npr. korištenje biodinamičkog pristupa pri uzdržavanju vinograda (lokacija TOMAC) te se može postaviti pitanje imaju li različite korištene travne smjese ili druge metode obrade vinograda značajan utjecaj na termin snimanja, kvalitativno zoniranje i prostornu stabilnost/varijabilnost zona bujnosti pri uniformnom uzdržavanju vinograda npr. biodinamičkim pristupom. Zaključno, prema svemu navedenom može se reći kako je za vinograde manjih površina potrebno višegodišnje snimanje i korištenje NDVI indeksa za određivanje zona bujnosti jer omogućava pronalaženje idealnog termina snimanja, povećava točnost utvrđivanja zona bujnosti, a time i kvalitativnih zona za praktičnu upotrebu, npr. za selektivnu berbu ili primjenu različitih agrotehničkih ili ampelotehničkih zahvata u određenim dijelovima vinograda tj. preciznog vinogradarstva.

Kvalitativno zoniranje vinograda na osnovu zona bujnosti uz korištenje NDVI indeksa te povezanosti dobivenih zona bujnosti s izmjerenim kvalitativnim svojstvima grožđa i sastavnicama prinosa na ciljanim trsovima, dosad je najviše je istraživano. Naime, dosadašnja istraživanja (Fiorillo i sur., 2012; Bonilla i sur., 2015; Ledderhof i sur., 2016; Gatti i sur., 2017; Ferrer i sur., 2020) potvrdila su definirane zone bujnosti putem mjerenja

na ciljanim trsovima, odnosno validirala su vegetacijske indekse kao indirektne prediktore kvalitativnih zona u vinogradu, što je potvrđeno i ovim istraživanjem. Tako je vegetacijski indeks NDVI na temelju zona manje i veće bujnosti uspješno detektirao i kvalitativne zone na sve četiri lokacije provedbe istraživanja u kojima je bio najprediktivniji vegetacijski indeks za određivanje zona bujnosti i kvalitativno zoniranje vinograda, ali u različitim terminima snimanja.

Na lokaciji TOMAC u 2019. godini dvije zone bujnosti dobivene na temelju NDVI indeksa u terminu snimanja u rujnu, odnosno u fenofazi 38 (tehnološka zrelost grožđa) razlikuju se statistički značajno u prosječnim rezultatima u koncentraciji šećera, količini ukupne kiseline te prinosu, pri čemu ciljani trsovi iz zone manje bujnosti imaju veću koncentraciju šećera, manju količinu ukupne kiseline te manji prinos dok ciljani trsovi iz zone veće bujnosti imaju manju koncentraciju šećera, veću količinu ukupne kiseline te veći prinos. Povezanost svih navedenih kvalitativnih svojstava sa zonama bujnosti potvrđena je i kroz istraživanja Johnson i sur. (2001), Urretavizcaya i sur. (2014), Ortega-Blu i Molina-Roco (2016), Gatti i sur. (2017), Reynolds i sur. (2018) i Ferrer i sur. (2020). Nadalje, kvalitativne zone dodatno su potvrđene i statistički značajnom pozitivnom povezanosti koncentracije šećera s NDVI indeksom iz rujna, dok su količina ukupnih kiselina, prinos po trsu i Indeks Ravaz statistički značajno negativno povezani s NDVI indeksom iz rujna, odnosno utvrđeno je da trsovi iz zone manje bujnosti imaju statistički značajno veću koncentraciju šećera, a trsovi iz zone veće bujnosti imaju statistički značajno veću količinu ukupnih kiselina, veći prinos po trsu i veći Indeks Ravaz na temelju NDVI indeksa iz rujna. Koeficijenti rodnosti su ciljane trsove u obje vegetacijske godine svrstali u visoko do vrlo visoko rodne trsove, s tim da su prosječni koeficijenti rodnosti ciljanih trsova iz definirane zone veće bujnosti bili veći, a u zoni manje bujnosti manji, čime se potvrđuje da i koeficijenti rodnosti uspješno detektiraju zone bujnosti u vinogradu.

Na lokaciji ŠEMBER u 2020. godini dvije zone bujnosti dobivene na temelju NDVI indeksa u terminu snimanja u srpnju, odnosno u fenofazi 34 (početak nakupljanja šećera) razlikuju se statistički značajno u prosječnim rezultatima u koncentraciji šećera, količini ukupne kiseline, pH vrijednosti te sadržaju ukupnog dušika u listu, pri čemu trsovi iz zone manje bujnosti imaju veću koncentraciju šećera, manju količinu ukupne kiseline, veću pH vrijednost te manji sadržaj ukupnog dušika u listu, dok trsovi iz zone veće bujnosti imaju manju koncentraciju šećera, veću količinu ukupne kiseline, manju pH vrijednost te veći sadržaj ukupnog dušika u listu. Povezanost navedenih kvalitativnih svojstava sa zonama bujnosti potvrđena je i kroz istraživanja Johnson i sur. (2001), Urretavizcaya i sur. (2014), Ortega-Blu i Molina-Roco (2016), Gatti i sur. (2017), Reynolds i sur. (2018) i Ferrer i sur. (2020). Nadalje, kvalitativne zone dodatno su potvrđene i statistički značajnom pozitivnom

povezanosti koncentracije šećera i pH vrijednosti s NDVI indeksom iz srpnja, dok je sadržaj ukupnog dušika u listu statistički značajno negativno povezan s NDVI indeksom iz srpnja, odnosno utvrđeno je da trsovi iz zone manje bujnosti imaju statistički značajno veću koncentraciju šećera i pH vrijednost, a trsovi iz zone veće bujnosti imaju statistički značajno veći sadržaj ukupnog dušika u listu na temelju NDVI indeksa iz srpnja. Veći sadržaj ukupnog dušika u zoni veće bujnosti također govori o sadržaju dušika kao potencijalnom prediktoru zona bujnosti jer je sadržaj dušika vezan uz snažniji vegetativni rast vinove loze. U ovom istraživanju NDVI indeks je uspješno detektirao veći sadržaj dušika u listu, dok je prema istraživanju Kidman i sur. (2017) upitna valjanost korištenja NDVI indeksa za procjenu sadržaja dušika u listu (u tom istraživanju veću točnost dao je vegetacijski indeks OSAVI). Prosječni koeficijenti rodnosti na ciljanim trsovima u obje vegetacijske godine iz definirane zone veće bujnosti bili su veći, a u zoni manje bujnosti manji, čime se potvrđuje da i koeficijenti rodnosti uspješno detektiraju zone bujnosti u vinogradu. Između dvije vegetacijske godine vidljiva je razlika u izračunatim vrijednostima koeficijenata rodnosti, pri čemu je 2019. godine bilo prilično veliko opterećenje po trsu u obje zone bujnosti i trsovi su svrstani u vrlo visoko rodne, dok je u 2020. godini smanjeno opterećenje po trsu i trsovi su bili visoko rodni. Koeficijent relativne rodnosti u zoni manje bujnosti uspješno je detektirao i manju rodnost ciljanih trsova u odnosu na ciljane trsove iz zone veće bujnosti.

Na lokaciji KOS u 2020. godini dvije zone bujnosti dobivene na temelju NDVI indeksa u terminu snimanja u kolovozu, odnosno u fenofazi 36 (srednje vrijednosti šećera) razlikuju se statistički značajno u prosječnim rezultatima u koncentraciji šećera, količini ukupne kiseline, broju grozdova te prinosu, pri čemu trsovi iz zone manje bujnosti imaju veću koncentraciju šećera, manju količinu ukupne kiseline, manji broj grozdova te manji prinos, dok trsovi iz zone veće bujnosti imaju manju koncentraciju šećera, veću količinu ukupne kiseline, veći broj grozdova te veći prinos. Povezanost navedenih kvalitativnih svojstava sa zonama bujnosti potvrđena je i kroz istraživanja Johnson i sur. (2001), Urretavizcaya i sur. (2014), Ortega-Blu i Molina-Roco (2016), Gatti i sur. (2017), Reynolds i sur. (2018) i Ferrer i sur. (2020). Povezanost navedenih sastavnica prinosa sa zonama bujnosti potvrđena je kroz istraživanja autora Martínez-Casasnovas i sur. (2012), Ledderhof i sur. (2016), Gatti i sur. (2017) i Oldoni i sur. (2021). Nadalje, kvalitativne zone dodatno su potvrđene i statistički značajnom pozitivnom povezanosti koncentracije šećera s NDVI indeksom iz kolovoza, a količina ukupnih kiselina, broj grozdova i prinos po trsu su statistički značajno negativno povezani s NDVI indeksom iz kolovoza, odnosno utvrđeno je da trsovi iz zone manje bujnosti imaju statistički značajno veću koncentraciju šećera, a trsovi iz zone veće bujnosti imaju statistički značajno veću količinu ukupnih kiselina, broj

grozdova i prinos po trsu na temelju NDVI indeksa iz kolovoza. Iste rezultate potvrđuje i Ledderhof i sur. (2015) u svom istraživanju. Oldoni i sur. (2021) dodatno potvrđuju i termin NDVI mapiranja nakon šare kao pogodan za određivanje kvalitativnih zona u vinogradu.
Koeficijenti rodnosti pokazali su određene razlike u dvije vegetacijske godine te su u 2019. godini ciljani trsovi iz zone veće bujnosti imali nešto niži koeficijent potencijalne rodnosti, odnosno nešto niže opterećenje u odnosu na zonu manje bujnosti, no tijekom vegetacije i pri mjerenju koeficijenta relativne rodnosti, trsovi su svrstani u visoko rodne, s većim koeficijentom relativne rodnosti od trsova iz zone manje bujnosti. Ove razlike mogu se objasniti specifičnostima lokacije KOS s obzirom na to da se radi o pokusnom vinogradu klonske selekcije u kojem se nalazi nekoliko desetaka različitih klonova sorte 'Kraljevina'. Osim toga, možebitni uzroci varijabilnosti rasta i razvoja trsova ovise i o načinu uzdržavanja vinograda u kojem je na jednom dijelu provođen projekt mikorizacije (Osrečak i sur., 2020) kojim je dokazan utjecaj lakšeg usvajanja vode, hranjivih tvari, makro i mikroelemenata iz tla, ali i znatno povećanje prinosa, uz istu ili čak povećanu kvalitetu grožđa. U 2020. godini ciljani trsovi iz zone manje bujnosti svrstani su u srednje rodne trsove, a trsovi iz zone veće bujnosti u visoko rodne, što pokazuje da su i koeficijenti rodnosti uspješno razdvojili ciljane trsove prema zoni bujnosti.

Na lokaciji PUHELEK- PUREK istraživanje je provedeno samo u dva termina u 2020. godini (fenofaza 36- srednje vrijednosti šećera i fenofazi 38- tehnološka zrelost grožđa) zbog navedenih tehničkih ograničenja. No, i na temelju tako prikupljenih podataka mogu se donijeti određeni zaključci koji koreliraju s ostalim dobivenim rezultatima i dosadašnjim istraživanjima. Dvije zone bujnosti dobivene na temelju NDVI indeksa u terminu snimanja u kolovozu, odnosno u fenofazi 36 (srednje vrijednosti šećera) razlikuju se statistički značajno u prosječnim rezultatima u koncentraciji šećera, količini ukupne kiseline, pH vrijednosti, broju grozdova te prinosu, pri čemu trsovi iz zone manje bujnosti imaju veću koncentraciju šećera, manju količinu ukupne kiseline, veću pH vrijednost, manji broj grozdova te manji prinos, dok trsovi iz zone veće bujnosti imaju manju koncentraciju šećera, veću količinu ukupne kiseline, manju pH vrijednost, veći broj grozdova te veći prinos. Povezanost navedenih kvalitativnih svojstava sa zonama bujnosti potvrđena je i kroz istraživanja Johnson i sur. (2001), Urretavizcaya i sur. (2014), Ortega-Blu i Molina-Roco (2016), Gatti i sur. (2017), Reynolds i sur. (2018) i Ferrer i sur. (2020). Povezanost navedenih sastavnica prinosa sa zonama bujnosti potvrđena je kroz istraživanja autora Martínez-Casasnovas i sur. (2012), Ledderhof i sur. (2016), Gatti i sur. (2017) i Oldoni i sur. (2021). Nadalje, kvalitativne zone dodatno su potvrđene i statistički značajnom pozitivnom povezanosti koncentracije šećera i pH vrijednosti s NDVI indeksom iz kolovoza, odnosno utvrđeno je da trsovi iz zone manje bujnosti imaju statistički značajno

veću koncentraciju šećera i pH vrijednost na temelju NDVI indeksa iz kolovoza. Iste rezultate potvrđuje i Ledderhof i sur. (2015) u svom istraživanju. Oldoni i sur. (2021) dodatno potvrđuju i termin NDVI mapiranja nakon šare kao pogodan za određivanje kvalitativnih zona u vinogradu. Prosječni koeficijenti rodnosti na ciljanim trsovima u 2020. godini iz definirane zone veće bujnosti bili su veći, a u zoni manje bujnosti manji, čime se potvrđuje da i koeficijenti rodnosti uspješno detektiraju zone bujnosti u vinogradu. Prosječan broj grozdova po pupu ostavljenih rezom (KpR) u zoni veće bujnosti iznosio je 1,33 grozda dok je u zoni manje bujnosti iznosio 0,93 što ukazuje na razliku u opterećenju između dviju zona bujnosti, što je potvrđeno i koeficijentom relativne rodnosti (KrR) odnosno brojem grozdova po mladici te su ciljani trsovi sorte 'Kraljevina' iz različitih zona bujnosti pokazali i različite koeficijente. U zoni veće bujnosti ciljani trsovi su svrstani u visoko rodne trsove, a trsovi iz zone manje bujnosti su svrstani u srednje rodne trsove.

Dodatno se može zaključiti kako je za sortu 'Kraljevina' u oba istraživana vinograda u 2020. godini najprediktivniji NDVI indeks u terminu snimanja u kolovozu, odnosno u fenofazi 36 (srednje vrijednosti šećera) te je jasno i statistički značajno razgraničio dvije zone bujnosti koje su se statistički značajno razlikovale u prosječnim rezultatima u koncentraciji šećera, količini ukupne kiseline, broju grozdova te prinosu. Osim toga sama prediktivnost vegetacijskog indeksa NDVI u oba vinograda u terminu snimanja u kolovozu bila je visoka (93%- lokacija KOS i 81%- lokacija PUHELEK- PUREK) što možebitno govori i o praktično korisnom terminu mapiranja nakon šare (Oldoni i sur. 2021) kao pogodnom za određivanje kvalitativnih zona za sortu 'Kraljevina' na temelju zona bujnosti određenih putem NDVI vegetacijskog indeksa.

Zaključno, na sve četiri lokacije i četiri termina u kojima je NDVI bio najprediktivniji indeks za kvalitativno zoniranje, pri preklapanju klasifikacijskih struktura: kvalitativne strukture trsova dobivene postupkom klasterizacije kvalitativnih svojstava grožđa s kvalitativnom strukturom trsova dobivenom na osnovu zoniranja uz pomoć vegetacijskog indeksa NDVI na zone manje bujnosti i zone veće bujnosti, postotak preklapanja iznosio je od 81% - 93% što ga čini najprediktivnijim vegetacijskim indeksom za kvalitativno zoniranje, sukladno ovom istraživanju, ali i dosadašnjim istraživanjima (Johnson i sur., 2001; Martínez-Casasnovas i sur., 2012; Fiorillo i sur., 2012; Filippetti i sur., 2013; Santesteban i sur., 2013; Urretavizcaya i sur., 2014; Bonilla i sur., 2015; Ortega-Blu i Molina-Roco, 2016; Ledderhof i sur., 2016; Gatti i sur., 2017; Matese i sur., 2017; Reynolds i sur., 2018; Padua i sur., 2019; Ferrer i sur., 2020; Pastonchi i sur., 2020; Oldoni i sur., 2021)

5.1.3. NDRE

NDRE, iako vrlo skromno korišten u dosadašnjim istraživanjima za određivanje zona bujnosti i kvalitativno zoniranje vinograda u ovom istraživanju pokazao se prediktivnim za određivanje zona bujnosti i kvalitativno zoniranje vinograda. Naime, pri statističkom preklapanju klasifikacijskih struktura: kvalitativne strukture trsova dobivene postupkom klasterizacije kvalitativnih svojstava grožđa s kvalitativnom strukturom trsova dobivenom na osnovu zoniranja uz pomoć vegetacijskog indeksa NDRE na zone manje bujnosti (potencijalno bolja kvalitativna svojstva grožđa) i zone veće bujnosti (potencijalno lošija kvalitativna svojstva grožđa) NDRE je u tri analizirana slučaja prediktivnosti (od ukupno sedam), na tri lokacije provedbe istraživanja (KOS, ŠEMBER, TOMAC), bio najprediktivniji vegetacijski indeks za određivanje zona bujnosti i kvalitativno zoniranje vinograda. U 2019. godini NDRE je bio najprediktivniji vegetacijski indeks na dvije lokacije- KOS u terminu snimanja u rujnu odnosno u fenofazi 38 (tehnološka zrelost grožđa) te ŠEMBER u terminu snimanja u kolovozu odnosno u fenofazi 36 (srednje vrijednosti šećera), dok je u 2020. godini bio najprediktivniji vegetacijski indeks na lokaciji TOMAC u drugom terminu snimanja u kolovozu odnosno u fenofazi 38 (tehnološka zrelost grožđa). NDRE vegetacijski indeks konstruiran je relativno nedavno (Buschmann i Nagel, 1993) i za izračun koristi mjerenje refleksije u rubnom crvenom dijelu (RE) i blisko infracrvenom (NIR) dijelu elektromagnetskog spektra te zbog toga ima smanjen efekt zasićenja zbog manje apsorpcije svjetlosti putem klorofila u rubnom crvenom dijelu spektra (RE) (Vicente i sur., 2017). Stoga je njegova praktična vrijednost dosad uočena za procjenu bujnosti na usjevima umjerene do velike biomase (Viña i Gitelson, 2005) te u kasnijim fenofazama praćenja varijabilnosti i bujnosti vinove loze (npr. u fenofazi dozrijevanja grožđa) (D`Urso i sur., 2018) što je potvrđeno i kroz ovo istraživanje, odnosno sva tri termina u kojima je NDRE bio najprediktivniji indeks za određivanje zona bujnosti i kvalitativno zoniranje su u fenofazi dozrijevanja grožđa.

Na lokaciji KOS u 2019. godini dvije zone bujnosti dobivene na temelju NDRE indeksa u terminu snimanja u rujnu, odnosno u fenofazi 38 (tehnološka zrelost grožđa) ne razlikuju se statistički značajno u prosječnim rezultatima u mjerenim kvalitativnim svojstvima grožđa i sastavnicama prinosa. Ovo je jedini termin i jedina lokacija u ovom istraživanju gdje se definirane zone bujnosti nisu statistički značajno razlikovale u prosječnim rezultatima u mjerenim parametrima. No, iako nisu statistički značajne razlike, zone veće i manje bujnosti pokazale su razlike u prosječnim vrijednostima koncentracije šećera, broja grozdova, broja mladica i broja nodija. No, uočena je pozitivna povezanost (iako nije statistički značajna) zone manje bujnosti i koncentracije šećera, ali i sadržaja ukupnog

dušika u listu, broja grozdova, mase orezane rozgve, broja mladica i broja nodija. U ovom slučaju su u zoni manje bujnosti ciljani trsovi imali veći sadržaj ukupnog dušika u listu, veći broj grozdova, neznatno veću masu orezane rozgve, veći broj mladica i veći broj nodija, što je posve izdvojen slučaj u cijelom istraživanju. Negativna povezanost, iako nije statistički značajna, uočena je za prinos po trsu te prosječnu masu grozda, odnosno trsovi iz zone veće bujnosti imali su veći prinos i neznatno veću masu grozda, što odgovara zoni veće bujnosti. Možebitni razlog za ovakva odstupanja jest sam vinograd na lokaciji KOS koji je pokusni vinograd klonske selekcije u kojem se nalazi nekoliko desetaka različitih klonova sorte 'Kraljevina' kao i provedba mikorizacije na toj lokaciji (Osrečak i sur., 2020) kojim je dokazan utjecaj lakšeg usvajanja vode, hranjivih tvari, makro i mikroelemenata iz tla, ali i znatno povećanje prinosa, uz istu ili čak povećanu kvalitetu grožđa. Interakcija vegetacijskih indeksa, sorte 'Kraljevina' i navedenih istraživanja (klonska selekcija, mikorizacija) nije istražena te se ne može sa sigurnošću tvrditi da interakcije nema te da NDRE nije prediktivan za kvalitativno zoniranje. S tim u vezi, NDRE je u ovom istraživanju uspješno detektirao zone bujnosti vezane uz apsorpciju svjetlosti putem klorofila, što je u svom radu potvrdio i Pourezza i sur. (2020), koji zaključuje kako je NDRE pokazao najbolju povezanost sa sadržajem dušika, dok Boiarskii i Hasegawa (2019) zaključuju kako je NDRE vrlo osjetljiv indeks za praćenje sadržaja klorofila. D`Urso i sur. (2018) zaključuju kako je NDRE najbolji pokazatelj za prepoznavanje jačih i zdravijih biljaka u kasnijim fazama, što se može povezati sa mikorizacijom na ovoj lokaciji.

Na lokaciji ŠEMBER u 2019. godini dvije zone bujnosti dobivene na temelju NDRE indeksa u kolovozu odnosno u fenofazi 36 (srednje vrijednosti šećera) razlikuju se statistički značajno u prosječnim rezultatima u koncentraciji šećera, količini ukupne kiseline, pH vrijednosti te sadržaju ukupnog dušika u listu, pri čemu trsovi iz zone manje bujnosti imaju veću koncentraciju šećera, manju količinu ukupne kiseline, veću pH vrijednost te manji sadržaj ukupnog dušika u listu, dok trsovi iz zone veće bujnosti imaju manju koncentraciju šećera, veću količinu ukupne kiseline, manju pH vrijednost te veći sadržaj ukupnog dušika u listu. Na ovoj lokaciji je NDRE indeks bio prediktivan za određivanje zona bujnosti i kvalitativno zoniranje. Nadalje, u 2019. godini, kao i u 2020. godini mjerenja na ciljanim trsovima statistički su se značajno razlikovala u prosječnim rezultatima u koncentraciji šećera, količini ukupne kiseline, pH vrijednosti te sadržaju ukupnog dušika u listu, NDRE vegetacijski indeks bio je dovoljno prediktivan za određivanje kvalitativnih zona kao i NDVI u 2020. godini, s nešto manjim postotkom (75%) preklapanja klasifikacijskih struktura od NDVI indeksa iz 2020. godine (86%). Ovdje je važno naglasiti i kako su termini snimanja, na osnovu kojih su određene zone bujnosti putem NDRE indeksa u 2019. i NDVI indeksa u 2020. godini različiti, odnosno NDRE

indeks uspješno je detektirao kvalitativne zone bujnosti u kasnijem terminu snimanja u fazi dozrijevanja grožđa (fenofazi 36- srednje vrijednosti šećera), što je u skladu s dosadašnjim istraživanjima (D`Urso i sur., 2018). Nadalje, kvalitativne zone dodatno su potvrđene i statistički značajnom negativnom povezanosti količine ukupnih kiselina i sadržaja ukupnog dušika u listu, odnosno utvrđeno je da trsovi iz zone veće bujnosti imaju statistički značajno veću količinu ukupnih kiselina i veći sadržaj ukupnog dušika u listu na temelju NDRE indeksa iz kolovoza.

Na lokaciji TOMAC u 2020. godini dvije zone bujnosti dobivene na temelju NDRE indeksa u drugom terminu snimanja u kolovozu, odnosno u fenofazi 38 (tehnološka zrelost grožđa) razlikuju se statistički značajno u prosječnim rezultatima u koncentraciji šećera i količini ukupne kiseline, pri čemu ciljani trsovi iz zone manje bujnosti imaju veću koncentraciju šećera i manju količinu ukupne kiseline dok ciljani trsovi iz zone veće bujnosti imaju manju koncentraciju šećera i veću količinu ukupne kiseline. Nadalje, kvalitativne zone dodatno su potvrđene i statistički značajnom pozitivnom povezanosti koncentracije šećera s NDRE indeksom iz drugog termina snimanja u kolovozu, dok je količina ukupnih kiselina statistički značajno negativno povezana s NDRE indeksom iz drugog termina snimanja u kolovozu, odnosno utvrđeno je da trsovi iz zone manje bujnosti imaju statistički značajno veću koncentraciju šećera, a trsovi iz zone veće bujnosti imaju statistički značajno veću količinu ukupnih kiselina na temelju NDRE indeksa iz drugog termina snimanja u kolovozu. I na ovoj lokaciji je NDRE indeks bio prediktivan za određivanje zona bujnosti i kvalitativno zoniranje. Nadalje, u 2019. godini, kao i u 2020. godini mjerenja na ciljanim trsovima statistički su se značajno razlikovala u prosječnim rezultatima u koncentraciji šećera i količini ukupne kiseline. NDRE vegetacijski indeks bio je dovoljno prediktivan za određivanje kvalitativnih zona kao i NDVI u 2019. godini, s gotovo istim postotkom (85%) preklapanja klasifikacijskih struktura kao i NDVI indeks iz 2019. godine (89%).
Zaključno, na lokacijama ŠEMBER i TOMAC vinogradi su zasađeni sortom 'Pinot crni', na obje lokacije NDRE indeks se pokazao kao najprediktivniji u kasnijim terminima snimanja, odnosno u fazi dozrijevanja grožđa (ŠEMBER- fenofaza 36- srednje vrijednosti šećera; TOMAC- fenofazi 38 (tehnološka zrelost grožđa), što je u skladu s istraživanjem D`Urso i sur. (2018). Na obje lokacije, razgraničenja dviju kvalitativnih zona bila su statistički značajna te se može reći kako je korištenje NDRE indeksa za određivanje kvalitativnih zona za sortu 'Pinot crni' dovoljno prediktivno za praktične svrhe provedbe selektivne berbe u vegetacijskoj sezoni u kojoj se prikupljaju podaci. I u ovom slučaju, bilo bi korisno provoditi višegodišnja praćenja i snimanja vinograda kako bi se povećala točnost predviđenih kvalitativnih zona te omogućila provedba preciznog vinogradarstva.

Zaključno, vegetacijski indeksi NDVI i NDRE su dobri prediktori za kvalitativno zoniranje vinograda na osnovu zona bujnosti te su dobar alat za procjenu varijabilnosti unutar vinograda, što potvrđuju i sva već navedena dosadašnja istraživanja. Nadalje, kvalitativno zoniranje na osnovu bujnosti vinograda, omogućava ciljano upravljanje proizvodnjom (engl. *site-specific management*) kao što su npr. navodnjavanje, gnojidba i zaštita vinograda te omogućava selektivnu berbu ovisno o kvaliteti grožđa i s tim povezano, proizvodnju različitih tipova vina kako bi se postigao veći profit u proizvodnji grožđa i vina (Hall i sur., 2002; Proffit, 2005; Bramley i sur., 2011a; Bramley i sur., 2011b; Bonilla i sur., 2015; Gatti i sur., 2017; Ferrer i sur., 2020).

Nadalje, s obzirom na mnoge izazove tijekom provedbe ovog opsežnog dvogodišnjeg istraživanja te prikupljanja i obrade podataka, kao prijedlozi za poboljšanje funkcionalnosti vegetacijskih indeksa, ali i buduća istraživanja može se navesti sljedeće:

- Potrebno je višegodišnje praćenje vinograda kako bi se povećala točnost kvalitativnih zona određenih putem vegetacijskih indeksa NDVI i NDRE
- Potrebno je višegodišnje praćenje određenog vinograda kako bi se definirao idealan termin ili termini prikupljanja podataka za kvalitativno zoniranje putem vegetacijskih indeksa NDVI i NDRE
- Potrebno je višegodišnje praćenje određenog vinograda s obzirom na klimatske uvjete vinogorja, sortu, podlogu, sastav tla, način uzdržavanja vinograda i sl. kako se bi se dodatno istražile interakcije navedenih faktora i određivanja zona bujnosti i kvalitativnih zona putem vegetacijskih indeksa NDVI i NDRE
- Potrebno je definirati odgovarajući način prikupljanja podataka multispektralnom kamerom (način snimanja, kut snimanja, visinu snimanja, potrebnu rezoluciju i sl.) kako bi snimke bile pogodne za obradu u različitim programskim paketima ili za automatiziranu obradu putem umjetne inteligencije
- Potrebno je višegodišnje praćenje vinograda manjih površina s izraženom prostornom varijabilnošću i specifičnim načinima uzdržavanja vinograda (biodinamika, mikorizacija i sl.) kako bi se odredila razina interakcije i utvrdila opravdanost korištenja vegetacijskih indeksa, kvalitativnog zoniranja i preciznog vinogradarstva.

5.2. Ekonomska opravdanost kvalitativnog zoniranja i selektivne berbe

Dvogodišnje istraživanje mogućnosti primjene vegetacijskih indeksa za kvalitativno zoniranje i selektivnu berbu grožđa na odabranim lokacijama istraživanja (KOS, PUHELEK- PUREK, TOMAC i ŠEMBER) upotpunjeno je i procjenom ekonomskih učinaka primjene novih tehnologija u vinogradarstvu, s ciljem prikaza troškova i prihoda te potencijalnih povećanja prihoda uz korištenje kvalitativnog zoniranja i selektivne berbe za proizvodnju grožđa i proizvodnju dva različita tipa vina iz istog vinograda. Ekonomska opravdanost do sada je minimalno istražena te je i to bio dodatni motiv za provedbu izračuna ekonomske opravdanosti u površinski manjim vinogradima (do 1 ha). S ciljem kvantificiranja stvarnih financijskih učinaka i donošenja odluka o ulaganjima u kvalitativno zoniranje i selektivnu berbu, provedena je analiza putem financijskih kriterija te su uočene određene razlike u ekonomskoj opravdanosti ulaganja u kvalitativno zoniranje i selektivnu berbu ovisno o sorti koja se uzgaja, prodajnoj cijeni vina, tipu vina koji se proizvodi i odabiru načina provedbe kvalitativnog zoniranja.

Iz analize mogućeg povećanja prihoda od proizvodnje grožđa na temelju kvalitativnog zoniranja i provedbe selektivne berbe, vidljivo je kako je moguće povećanje prihoda na sve četiri lokacije istraživanja bilo između 2,48% i 11,03% što su u svom istraživanju potvrdili i Bramley i sur. (2005b) za sortu 'Shiraz' u Australiji (3,2%, lokacija Padthaway i 12,5%, lokacija Margaret River). Dodatno, u svom daljnjem istraživanju Bramley i sur. (2011b) utvrdili su kako je selektivnom berbom moguće povećanje profita od cca 9% zbog razlike u otkupnoj cijeni grožđa za proizvođače grožđa koji prodaju grožđe velikim vinarijama. Moguća povećanja prihoda od proizvodnje i prodaje grožđa na sve četiri lokacije u istraživanju su vrlo mala i u apsolutnim iznosima (278,85 kn – 5.467,66 kn) zbog malih vinogradarskih površina, male količine ubranog grožđa i prije svega zbog male razlike u udjelu zone manje bujnosti i male razlike u kvaliteti grožđa između dvije zone bujnosti, te se može zaključiti kako se selektivna berba i prodaja grožđa ne preporučuje za male vinograde, posebno za male vinarije koje ostvaruju visoke prihode od prodaje vina. Nadalje, s obzirom na to da su vinogradari sa sve četiri lokacije istraživanja ujedno i proizvođači vina te ne prodaju grožđe, analiza mogućih prihoda od proizvodnje različitih tipova vina na osnovu kvalitativnog zoniranja i selektivne berbe može se smatrati relevantnijom.

Analiza mogućih povećanja prihoda od proizvodnje različitih tipova vina na osnovu kvalitativnog zoniranja i selektivne berbe pokazala je veće postotno povećanje prihoda, ali i veće apsolutne iznose mogućeg povećanja prihoda od prodaje različitih tipova vina proizvedenih iz istog vinograda. Sukladno dosadašnjim istraživanjima, proizvodnja dva

različita tipa vina na osnovu selektivne berbe može donijeti povećanje bruto vrijednosti proizvodnje grožđa u iznosu od gotovo 220.000,00 kn/ha (Bramley i sur., 2003), dok su izračuni u ovom istraživanju za lokaciju TOMAC i lokaciju ŠEMBER pokazali i veće moguće povećanje prihoda. Na lokaciji TOMAC, uz površinu vinograda od 0,33 ha, prosječno moguće povećanje ukupnih prihoda od proizvodnje vina nakon selektivne berbe iznosilo je gotovo 45%, odnosno 105.514,55 kn/0,33 ha, što bi činilo moguće povećanje od 319.741,06 kn/ha. Na lokaciji ŠEMBER na površni vinograda od 0,65 ha prosječno moguće povećanje ukupnih prihoda od proizvodnje vina nakon selektivne berbe iznosilo je gotovo 44%, odnosno 313.614,39 kn/0,65 ha, odnosno mogućih 482.483,68 kn/ha. Na lokaciji PUHELEK- PUREK moguće povećanje ukupnih prihoda od proizvodnje vina nakon selektivne berbe iznosilo je 21,93%, odnosno 200.193,81 kn/0,93 ha, što je u skladu s dosadašnjim istraživanjima (Bramley i sur., 2003), dok je na lokaciji KOS prosječno moguće povećanje ukupnih prihoda iznosilo gotovo 14%, odnosno 36.547,53 kn/0,47 ha, odnosno mogućih 77.760,70 kn/ha što je značajno manje od navedenih rezultata dosadašnjih istraživanja Bramley i sur. (2003). Na lokacijama PUHELEK-PUREK, TOMAC i ŠEMBER selektivna berba bi omogućila proizvodnju dva različita vina visoke kvalitete iz obje zone bujnosti (vrhunsko mirno vino i vrhunsko pjenušavo vino) koja dostižu i visoke cijene na tržištu te se može zaključiti kako je moguće povećanje ukupnih prihoda od proizvodnje vina nakon selektivne berbe jako ovisno o prodajnoj cijeni vina pojedine vinarije, što u svom istraživanju potvrđuju i Rousseau i sur. (2013). Nadalje, autori navode kako je moguće povećanje prihoda od proizvodnje „super premium“ vina kreće se od 800 do 5.000 EUR/ha i ovisi o prodajnoj cijeni vina. S obzirom na to da proizvođač KOS ima niže prodajne cijene vina, a nakon selektivne berbe bilo bi moguće proizvesti dva različita mirna vina, od kojeg je jedno više kakvoće i višeg cjenovnog ranga, povećanje ukupnih prihoda na lokaciji KOS najmanje je u ovom istraživanju, ali i dalje dvostruko više od navedenog povećanja u Rousseau i sur. (2013). Sve navedeno može se objasniti vrlo turbulentnim stanjem na tržištu vina na kojem je sortno vino 'Pinot crni' cjenjenije i postiže vrlo visoke jedinične cijene butelje, kao i pjenušava vina, dok su mirna vina autohtone sorte 'Kraljevina' u nižem cjenovnom rangu bez obzira na kvalitetu samog vina. Nadalje, ovo istraživanje je pokazalo kako je iz obje zone bujnosti moguća proizvodnja vrhunskih vina, a time i moguće povećanje maloprodajne cijene vina za 40-60 kn po butelji na lokacijama PUHELEK- PUREK, ŠEMBER i TOMAC, što je u skladu s dosadašnjim istraživanjima Bramley i sur. (2011b) gdje se navodi moguće povećanje cijene butelje vina za cca 5$ (35,50 kn) uz prijelaz na „super premium“ vina nakon selektivne berbe. Na lokaciji KOS povećanje cijene butelje vina iznosi 11,33 kn, no bez obzira na niže povećanje od ostalih proizvođača vina može se zaključiti kako cijena od 46,33 kn/butelji bila vrlo dobra tržišna cijena vina sorte 'Kraljevina'. Nastavno na sve

navedeno, može se zaključiti kako je proizvodnja različitih tipova vina iz istog vinograda na osnovu selektivne berbe sukladno kvalitativnim zonama, dobar pristup za upravljanje vinogradima i proizvodnjom vina u malim obiteljskim vinarijama, što potvrđuju i Bramley i sur. (2011b). Selektivna berba omogućava maksimiziranje učinaka varijabilnosti, proizvodnju različitih tipova vina te povećanje prihoda od proizvodnje vina nakon provedbe kvalitativnog zoniranja, posebice za male obiteljske vinarije koje imaju dobru poziciju na tržištu i više tržišne cijene vina.

Ekonomska korist i financijska procjena ulaganja u kvalitativno zoniranje i selektivnu berbu jedan je od najvažnijih preduvjeta za početak korištenja kvalitativnog zoniranja, odnosno općenito novih tehnologija u poljoprivredi (Adrian i sur., 2005; Maynard, 2015). S obzirom na to da se ulaganja u ovom istraživanju odnose samo na korištenje podatkovno intenzivnih tehnologija i da nije moguće direktno mjeriti profitabilnost, već prikupljeni podaci i kvalitativno zoniranje omogućuju kvalitetnije upravljanje proizvodnjom (Castle, 2016), za financijsku procjenu ulaganja korišteni su samo troškovi koji se odnose na nabavu opreme ili usluge za provedbu kvalitativnog zoniranja te moguće povećanje ukupnih prihoda koje bi nastalo proizvodnjom različitih tipova vina iz istog vinograda na osnovu kvalitativnih zona. Analiza investicije za ulaganje u kvalitativno zoniranje i selektivnu berbu napravljena je korištenjem financijskih kriterija (Griffin i sur., 2018) koji omogućuju procjenu isplativosti investicije u petogodišnjem razdoblju efektuiranja projekta. Dobiveni rezultati sugeriraju da je kvalitativno zoniranje i selektivna berba mogu biti isplativi na svim lokacijama istraživanja u kratkom roku, što je u skladu s istraživanjem Balafoutis i sur. (2017) koji su podatkovno intenzivne tehnologije i analizu prikupljenih podataka svrstali u nisku do srednju razinu investicije. No, razlike postoje u načinu provedbe kvalitativnog zoniranja i selektivne berbe. Na lokaciji KOS, u scenariju A u kojem je investicija procijenjena uz pretpostavku da proizvođač sam kupuje opremu i provodi kvalitativno zoniranje i selektivnu berbu, nije se pokazala isplativom jer je čista sadašnja vrijednost (NPV) bila negativna, diskontirano razdoblje povrata nije dogodilo u traženom petogodišnjem razdoblju efektuiranja projekta odnosno diskontirani čisti novčani tokovi nisu pokrili vrijednost ulaganja u traženom razdoblju, interna stopa profitabilnosti (IRR) bila je niža od diskontne stope odnosno cijene kapitala, a modificirana interna stopa profitabilnosti (mIRR) niža od stope reinvestiranja odnosno niža od granične stope povrata ulaganja. Ove financijske pokazatelje u svom istraživanju navode i Griffin i sur. (2018) te zaključuju kako NPV mora biti pozitivan da bi investicija bila isplativa, a IRR za određenu tehnologiju mora biti viša od cijene kapitala da bi to bila dobra investicija. No, pri desetogodišnjoj analizi, čak i uz nabavu nove opreme na kraju pete godine efektuiranja projekta (bespilotne letjelice, dodatne baterije i računala) investicija se pokazala isplativom. Na ostalim lokacijama istraživanja (PUHELEK- PUREK, TOMAC i ŠEMBER)

u scenariju A, svi financijski kriteriji su pokazali isplativost investicije s pozitivnom NPV, kratkim diskontiranim razdobljem povrata, IRR koja je viša od diskontne stope te modificiranom IRR koje je viša od stope reinvestiranja odnosno IRR je viša od potrebne stope povrata ulaganja, a mIRR je viša od potrebne granične stope povrata ulaganja. Na lokacijama PUHELEK- PUREK i ŠEMBER diskontirano razdoblje povrata investicije je već u prvoj godini efektuiranja projekta, što govori o visokoj razini isplativosti investicije, odnosno ulaganje u nabavu opreme za kvalitativno zoniranje i provedba selektivne berbe bilo bi otplaćeno već u prvoj godini provedbe i to isključivo prihodima koji bi nastali kao moguće povećanje prihoda od proizvodnje dva različita tipa vina iz istog vinograda na osnovu selektivne berbe. Na lokaciji TOMAC isto ulaganje bili bi isplativo već u drugoj godini efektuiranja projekta.

S obzirom na to da je provedba kvalitativnog zoniranja zahtjevna iz tehnološkog aspekta (provedba letova bespilotnom letjelicom), a zahtijeva i dodatne edukacije i angažman vinogradara (obrada i analiza podataka), napravljena je i financijska analiza u scenariju B u kojem vinogradari koriste usluge specijalizirane tvrtke za snimanje bespilotnom letjelicom i obradu i analizu prikupljenih podataka, a selektivnu berbu provode sami. U scenariju B izračuni su pokazali da je investicija isplativa na svim lokacijama istraživanja, s diskontiranim razdobljem povrata ulaganja na lokacijama PUHELEK- PUREK, TOMAC i ŠEMBER već u prvoj godini efektuiranja projekta, a na lokaciji KOS u trećoj godini efektuiranja projekta. Pri desetogodišnjoj procjeni isplativosti investicije na lokaciji KOS, diskontirano razdoblje povrata dogodilo se u petoj godini efektuiranja projekta, no NPV je gotovo 40% veća kada se promatra desetogodišnji period isplativosti investicije. Na svim lokacijama svi financijski kriteriji su pokazali isplativost investicije s pozitivnom NPV, kratkim diskontiranim razdobljem povrata, IRR koja je viša od diskontne stope te modificiranom IRR koje je viša od stope reinvestiranja odnosno IRR je viša od potrebne stope povrata ulaganja, a mIRR je viša od potrebne granične stope povrata ulaganja. Dodatno, na svim lokacijama IRR i mIRR su više u scenariju B od istih pokazatelja profitabilnosti u scenariju A, što pokazuje kako je korištenje usluge specijalizirane tvrtke za snimanje bespilotnom letjelicom i obradu i analizu prikupljenih podataka pokazuje se isplativijim rješenjem nego ulaganje u opremu i samostalno provođenje kvalitativnog zoniranja od strane vinogradara. Takve rezultate podupire i istraživanje Griffin i sur. (2018) koji navodi kako je za usporedbu različitih investicija u pametnoj poljoprivredi bolja ona investicija koja ima višu IRR. Nadalje, korištenje usluge specijalizirane tvrtke proizvođaču omogućava i izbjegavanje neočekivanih troškova koji su povezani s kupnjom i vlasništvom opreme, što u ovom istraživanju nije uzeto u obzir, no i da jest, ulaganje u scenariju B bilo bi još isplativije na svim lokacijama istraživanja. To potvrđuju i Swinton i Ahmad (2015) koji navode kako sav rizik korištenja opreme i njenog održavanja prelazi na

davatelja usluge, a za korisnika su svi troškovi isključivo novčani te kada financijske koristi premašuju troškove korištenja usluge, usluga je isplativa.

Može se zaključiti kako ovo ulaganje, uz pretpostavljene količine proizvodnje i cijene, a na temelju istraživanih primjera, može biti i financijski i ekonomski opravdano, kako to navode Shockley i sur. (2017) u svom istraživanju. Ulaganje je ekonomski opravdano ako generira dovoljan prihod kako bi se zadovoljili novčani zahtjevi u životnom vijeku investicije, a financijski je opravdano ako je korisnik sposoban osigurati novčani tok investicije s obzirom na financijsku strukturu investicije. Ovi rezultati ukazuju da bi ulaganje u korištenje kvalitativnog zoniranja i provedba selektivne berbe, uz pretpostavljene količine proizvodnje i cijene, a na temelju primjera s istraživanih vinarskih gospodarstava, moglo povećati financijsku korist za proizvođače vina koji imaju male površine vinograda i proizvode dva tipa „super premium“ vina od iste sorte i iz istog vinograda. Ovi rezultati su ujedno i način na koji je moguće pokrenuti investicije u nove tehnologije i nove načine upravljanja vinogradarskom proizvodnjom, što potvrđuju u svom istraživanju Adrian i sur. (2005) navodeći kako je ekonomska korist odlučujući faktor za korištenje alata precizne poljoprivrede. S obzirom na to da je ovo istraživanje koncipirano da se utvrdi može li ulaganje u provedbu kvalitativnog zoniranja i selektivne berbe biti pokriveno isključivo razlikom prihoda koji bi bili ostvareni nakon provedenog ulaganja, rezultati prikazuju kako je ulaganje u kvalitativno zoniranje i selektivnu berbu uz pretpostavljene količine proizvodnje i cijene, ekonomski opravdano u odnosu na proizvodnju grožđa i vina bez provedbe ulaganja, što otvara put usvajanju novih tehnologija u vinogradarskoj proizvodnji, ali i predstavljaju važno polazište za daljnja istraživanja stvarne financijske isplativosti ulaganja u tehnologije preciznog vinogradarstva. To u svom istraživanju potvrđuje i Maynard (2015) navodeći da je za usvajanje inovacije u proizvodnom procesu ključna ekonomska opravdanost kojom će proizvođač maksimizirati svoj profit uz minimalne prilagodbe načina proizvodnje, a analiza „s i bez usvajanja“ će biti ključna u donošenju odluke.

6. ZAKLJUČCI

Dvogodišnje istraživanje mogućnosti primjene tri različita vegetacijska indeksa- NDVI, NDRE i OSAVI za kvalitativno zoniranje vinograda pokazalo je kako su vegetacijski indeksi učinkovit alat za procjenu bujnosti i varijabilnosti u vinogradu te kako uspješno opisuju i povezuju određene karakteristike vinove loze, kao što su sastavnice prinosa i kvalitativna svojstva grožđa, s rezultatima spektralnih mjerenja.

Pri utvrđivanju povezanosti vegetacijskih indeksa (NDVI, NDRE, OSAVI) i bujnosti utvrđeno je da podaci prikupljeni ručnim uzorkovanjem koji mogu biti prediktori bujnosti u vinogradu (broj mladica, broj nodija, masa orezane rozgve (kg)) nisu dostatni za utvrđivanje razlika u povezanosti vegetacijskih indeksa i bujnosti u različitim fenofazama razvoja vinove loze za dvije istraživane sorte. Naime, vegetacijske indekse potrebno je promatrati kao pokazatelje fotosintetski aktivne vegetacije prisutne u određenoj fenofazi razvoja vinove loze, a da bi se uspješno povezala s bujnosti potrebno je mjerenje više sastavnica vinove loze koje utječu na vegetativni rast i razvoj i to u istim terminima kada se vrše spektralna mjerenja. No, utvrđeno je su kako vegetacijski indeksi relevantni pokazatelji vegetativnog stanja vinove loze i dobri prediktori bujnosti u određenoj fenofazi razvoja te kako je moguće uspješno generirati različite karte bujnosti u svim fenofazama razvoja koje su pogodne za kvalitativno zoniranje vinograda kod obje istraživane sorte vinove loze.

Pri utvrđivanju povezanosti zona različite bujnosti sa sastavnicama prinosa i kvalitativnim svojstvima grožđa utvrđene su određene razlike u učinkovitosti procjene povezanosti bujnosti ovisno o korištenom vegetacijskom indeksu, ali i o terminu prikupljanja podataka multispektralnim kamerama.

OSAVI kao najmanje korišten vegetacijski indeks u dosadašnjim istraživanjima i u ovom se istraživanju pokazao najmanje prediktivan za određivanje zona bujnosti i kvalitativno zoniranje vinograda. Niti u jednom terminu prikupljanja podataka multispektralnim kamerama kao niti na jednoj lokaciji provedbe istraživanja, OSAVI nije bio najprediktivniji vegetacijski. OSAVI svoju primjenu može naći za određivanje sadržaja dušika ili količine klorofila u vinovoj lozi, zatim kao odgovarajući indeks za npr. ciljanu gnojidbu dušikom u vinogradarstvu te kao vegetacijski indeks koji minimizira utjecaj visoke varijabilnosti tla na analizu vegetacije i to u slučaju kada se koriste snimke na kojima nije provedeno segmentiranje (izdvajanje) redova u vinogradu.

NDVI kao najviše korišten vegetacijski indeks u dosadašnjim istraživanjima i u ovom se istraživanju pokazao najprediktivnijim vegetacijskim indeksom za određivanje zona bujnosti i kvalitativno zoniranje vinograda. NDVI je u četiri analizirana slučaja prediktivnosti (od ukupno sedam), na četiri lokacije provedbe istraživanja, bio najprediktivniji vegetacijski indeks (postotak preklapanja klasifikacijskih kvalitativnih struktura iznosio je od 81% - 93%). S obzirom na uočene razlike u prediktivnosti vezane uz termine prikupljanja podataka, može se reći da je potrebno daljnje istraživanje idealnog termina prikupljanja podataka multispektralnim kamerama za određivanje zona bujnosti i kvalitativno zoniranje ovisno o klimatskim uvjetima u vegetacijskim sezonama. Dodatno se može zaključiti kako je za sortu 'Kraljevina' u 2020. godini NDVI bio najprediktivniji u terminu snimanja u kolovozu (fenofaza 36- srednje vrijednosti šećera) što možebitno govori i o praktično korisnom terminu mapiranja za određivanje kvalitativnih zona za sortu 'Kraljevina'.

NDRE, iako vrlo skromno korišten u dosadašnjim istraživanjima za određivanje zona bujnosti i kvalitativno zoniranje vinograda, u ovom istraživanju pokazao se dovoljno prediktivnim. NDRE je u tri analizirana slučaja prediktivnosti (od ukupno sedam), na tri lokacije provedbe istraživanja (KOS, ŠEMBER, TOMAC), bio najprediktivniji vegetacijski indeks za određivanje zona bujnosti i kvalitativno zoniranje vinograda. Na lokacijama ŠEMBER i TOMAC (sorta 'Pinot crni'), NDRE se pokazao kao najprediktivniji u kasnijim terminima snimanja (u fazi dozrijevanja grožđa) te se može reći kako je korištenje NDRE za određivanje kvalitativnih zona za sortu 'Pinot crni' dovoljno prediktivno za praktične svrhe provedbe selektivne berbe u vegetacijskoj sezoni u kojoj se prikupljaju podaci.

Ulaganje u kvalitativno zoniranje i selektivnu berbu s ciljem proizvodnje dva različita tipa vina od iste sorte grožđa i iz istog vinograda, a na osnovu kvalitativnih zona određenih uz pomoć najprediktivnijeg vegetacijskog indeksa, može povećati financijsku korist za proizvođače vina uz pretpostavljene količine proizvodnje i cijene na svim istraživanim vinarskim gospodarstvima, no uočene su određene razlike ovisno o sorti koja se uzgaja, prodajnoj cijeni vina, tipu vina koji se proizvodi i odabiru načina provedbe kvalitativnog zoniranja.
Analiza mogućih povećanja prihoda od proizvodnje različitih tipova vina na osnovu kvalitativnog zoniranja i selektivne berbe pokazala je prosječno moguće povećanje ukupnih prihoda od 14% (KOS) do gotovo 45% (TOMAC, ŠEMBER). Na lokacijama PUHELEK- PUREK, TOMAC i ŠEMBER selektivna berba bi omogućila proizvodnju dva različita „super premium“ vina iz obje zone bujnosti (vrhunsko mirno vino i vrhunsko pjenušavo vino) koja dostižu visoke cijene na tržištu te se može zaključiti kako je moguće

povećanje ukupnih prihoda od proizvodnje vina nakon selektivne berbe jako ovisno o prodajnoj cijeni vina pojedine vinarije. Nadalje, ovo istraživanje je pokazalo kako je iz obje zone bujnosti moguća proizvodnja vrhunskih vina, a time i moguće povećanje maloprodajne cijene vina za 40–60 kn po butelji na lokacijama PUHELEK- PUREK, ŠEMBER i TOMAC.

Rezultati analiza investicije za ulaganje u kvalitativno zoniranje i selektivnu berbu korištenjem financijskih kriterija, sugeriraju da investicija može biti isplativa na svim lokacijama istraživanja u kratkom roku uz pretpostavljene količine proizvodnje i cijene. No, razlike postoje u načinu provedbe kvalitativnog zoniranja i selektivne berbe. U scenariju A, u kojem je investicija procijenjena uz pretpostavku da proizvođač sam kupuje opremu i provodi kvalitativno zoniranje i selektivnu berbu, na lokaciji KOS investicija se nije pokazala isplativom u petogodišnjem razdoblju efektuiranja projekta, dok su na ostalim lokacijama (PUHELEK- PUREK, TOMAC i ŠEMBER) te u desetogodišnjem razdoblju efektuiranja projekta na lokaciji KOS, svi financijski kriteriji pokazali moguću isplativost investicije.

U scenariju B u kojem vinogradari koriste usluge specijalizirane tvrtke za snimanje bespilotnom letjelicom i obradu i analizu prikupljenih podataka, a selektivnu berbu provode sami, izračuni su pokazali da je investicija može biti isplativa na svim lokacijama istraživanja. Dodatno, na svim lokacijama IRR i mIRR su više u scenariju B, a korištenje usluge specijalizirane tvrtke pokazuje se financijski isplativijim rješenjem od ulaganja u opremu i samostalnog provođenja kvalitativnog zoniranja.

Dobiveni rezultati ekonomske analize na temelju pretpostavljene proizvodnje i prihoda, predstavljaju važno polazište za daljnja istraživanja stvarne financijske isplativosti ulaganja u korištenje alata i tehnologija precizne poljoprivrede u vinogradarstvu.

Navedeni zaključci ujedno su i odgovor na postavljene hipoteze istraživanja.

Prva hipoteza glasi:

1. Postoji razlika u povezanosti vegetacijskih indeksa (NDVI, NDRE, OSAVI) i bujnosti kod dviju istraživanih sorata u različitim fenofazama razvoja vinove loze

Postojanje razlika u povezanosti vegetacijskih indeksa i bujnosti u različitim fenofazama razvoja vinove loze nije moglo biti potvrđeno jer je vegetacijske indekse potrebno promatrati kao pokazatelje fotosintetski aktivne vegetacije prisutne u određenoj fenofazi razvoja vinove loze koji mogu detektirati varijabilnost mnogih svojstava vinove loze unutar vinograda te su potrebna dodatna istraživanja, analize i mjerenja više sastavnica vinove loze koje utječu na vegetativni rast i razvoj, a time i na povezanost s rezultatima spektralnih mjerenja. No, utvrđeno je su kako vegetacijski indeksi relevantni pokazatelji vegetativnog stanja vinove loze u određenoj fenofazi razvoja i dobri prediktori bujnosti te

kako je moguće uspješno generirati različite karte bujnosti koje su pogodne za kvalitativno zoniranje vinograda u svim fenofazama razvoja kod obje istraživane sorte vinove loze.

Druga hipoteza glasi:

2. Postoji povezanost zona različite bujnosti sa sastavnicama prinosa i kvalitativnim svojstvima grožđa

Utvrđena je povezanost različitih zona bujnosti sa sastavnicama prinosa i kvalitativnim svojstvima grožđa, odnosno utvrđena je mogućnost primjene dva različita vegetacijska indeksa za kvalitativno zoniranje vinograda na osnovu zona bujnosti. Zone bujnosti određene temeljem vegetacijskih indeksa NDVI i NDRE uspješno opisuju i povezuju sastavnice prinosa i kvalitativna svojstva grožđa s rezultatima spektralnih mjerenja, čime je ova hipoteza potvrđena istraživanjem. Ovim istraživanjem utvrđeno je i da vegetacijski indeks OSAVI nije pogodan za kvalitativno zoniranje vinograda jer definirane zone bujnosti nisu značajno povezane sa sastavnicama prinosa i kvalitativnim svojstvima grožđa.

Treća hipoteza glasi:

3. Ekonomski je opravdana primjena vegetacijskih indeksa za kvalitativno zoniranje vinograda i selektivnu berbu grožđa na vinogradarskim površinama do 1 ha

Na temelju primjera s istraživanih vinarskih gospodarstva, uz pretpostavljene količine proizvodnje i cijene, primjena vegetacijskih indeksa za kvalitativno zoniranje vinograda i provedba selektivne berbe grožđa, s ciljem proizvodnje dva različita tipa „super premium“ vina od iste sorte grožđa i iz istog vinograda na vinogradarskim površinama do 1 ha, može dovesti do povećanja financijske koristi i ekonomske opravdanosti investicije za proizvođače grožđa i vina.

7. POPIS LITERATURE

1. Adrian A.M., Norwood, S.H., Mask, P.L. (2005). Producers' perceptions and attitudes toward precision agriculture technologies. Comput Electron Agric 48 (3): 256-271. doi: 10.1016/j.compag.2005.04.004.
2. Allahyari, M.H., Mohammadzadeh, M., Nastis, S.A. (2016). Agricultural experts' attitude towards precision agriculture: Evidence from Guilan Agricultural Organization, Northern Iran. Information Processing in Agriculture 3 (3): 183-189. doi: 10.1016/j.inpa.2016.07.001.
3. Anastasiou, E., Balafoutis, A., Darra, N., Psiroukis, V., Biniari, A., Xanthopoulos, G., Fountas, S. (2018). Satellite and Proximal Sensing to Estimate the Yield and Quality of Table Grapes. Agriculture 8 (7): 94. doi: 10.3390/agriculture8070094.
4. Andújar, D., Moreno, H., Bengochea-Guevara, J., De Castro, A., Ribeiro, A. (2019). Aerial imagery or on-ground detection? An economic analysis for vineyard crops. Comput Electron Agric 157: 351-358. doi: 10.1016/j.compag.2019.01.007.
5. Agencija za plaćanja u poljoprivredi, ribarstvu i ruralnom razvoju (2021). Podaci iz Vinogradarskog registra za 2021. godinu. Dostupno na: https://www.apprrr.hr/registri/ [Pristupljeno 15.6.2022.]
6. Agencija za plaćanja u poljoprivredi, ribarstvu i ruralnom razvoju (2021). Vinogradarski registar. Zagreb, Republika Hrvatska. Dostupno na: https://www.apprrr.hr/registri/ [Pristupljeno 10.6.2022.]
7. Arnó, J., Martínez-Casasnovas, J.A., Ribes-Dasi, M., Rosell, J.R. (2009). Review. Precision viticulture. Research topics, challenges and opportunities in site-specific vineyard managment. Span J Agric Res 7 (4): 779-790. doi: 10.5424/sjar/2009074-1092.
8. Arnó, J., Martínez-Casasnovas, J. A. (2017). Assessing opportunities for selective winery vintage with a market-driven composite index. Cogent Food Agric 3 (1): 1-15. doi: 10.1080/23311932.2017.1386438.
9. Aubert, B.A., Schroeder, A., Grimaudo, J. (2012). IT as enabler of sustainable farming: An empirical analysis of farmers' adoption. Decision Support Systems, 54 (1): 510-520. doi: 10.1016/j.dss.2012.07.002.
10. Balafoutis, A. T., Beck, B., Fountas, S., Tsiropoulos,Z., Vangeyte, J., van der Wal, T., Soto-Embodas, I., Gómez-Barbero, M., Pedersen, S.M. (2017). Smart Farming Technologies – Description,Taxonomy and Economic Impact. In: Precision Agriculture: Technology and Economic Perspectives (Pedersen S.M., Martin K., eds), Springer International Publishing AG 2017, Cham, Switzerland, pp. 21-77. doi: 10.1007/978-3-319-68715-5_2.

11. Barnard, Y. (2018). The use of technology to improve current precision viticulture practises: predicting vineyard performance. MA. Stellenbosch University, South Africa. Dostupno na: https://scholar.sun.ac.za/handle/10019.1/104893 [Pristupljeno 24.7.2019.]
12. Barnes, A.P., Soto, I., Eory, V., Beck, B., Balafoutis, A., Sanchez, B., Vangeyte, J., Fountas, S., Van der Wal, T., Gomez-Barbero, M. (2019). Exploring the adoption of precision agricultural technologies: A cross regional study of EU farmers. Land Use Policy 80: 163-174. doi: 10.1016/j.landusepol.2018.10.004.
13. Boiarskii, B., Hasegawa, H. (2019). Comparison of NDVI and NDRE Indices to Detect Differences in Vegetation and Chlorophyll Content. J. Mech. Cont.& Math. Sci., Special Issue 4: 20-29. doi: 10.26782/jmcms.spl.4/2019.11.00003.
14. Bonilla, I., Martínez de Toda, F., Martínez-Casasnovas, J.A. (2014). Vineyard zonal management for grape quality assessment by combining airborne remote sensed imagery and soil sensors. In: Proceedings of SPIE 9239, Remote Sensing for Agriculture, Ecosystems, and Hydrology XVI (Neale C. M. U., Maltese A., eds), The International Society for Optical Engineering, Cardiff, Wales, pp. 92390S1-92390S9. doi: 10.1117/12.2177766.
15. Bonilla, I., Martinez de Toda, F., Martínez-Casasnovas, J.A. (2015). Vine vigour, yield and grape quality assessment by airborne remote sensing over three years: Analysis of unexpected relationships in cv. Tempranillo. Span J Agric Res 13 (2): 0903. doi: 10.5424/sjar/2015132-7809.
16. Bramley, R.G.V. (2001). Progress in the development of precision viticulture - variation in yield, quality and soil properties in contrasting Australian vineyards. In: Precision tools for improving land management (Currie L.D., Loganathan P., eds), Fertilizer and Lime Research Centre, Massey University, Palmerston North, New Zealand, pp: 25-43. Dostupno na: https://www.fsantos.utad.pt/bibliografia/AP050711-02.pdf [Pristupljeno 30.7.2019.]
17. Bramley, R.G.V., Pearse, B., Chamberlain, P. (2003). Being profitable precisely- a case study of precision viticulture from Margaret River. The Australian & New Zealand Grapegrower & Winemaker [Annual Technical Issue] 473a: 84-87. Dostupno na: https://www.fsantos.utad.pt/bibliografia/PVProfitabiltyPaper.pdf [Pristupljeno 30.8.2019.]
18. Bramley, R.G.V., Hamilton, R.P. (2004). Understanding variability in winegrape production systems: 1. Within vineyard variation in yield over several vintages. Aust J Grape Wine Res 10 (1): 32- 45. doi: 10.1111/j.1755-0238.2004.tb00006.x.

19. Bramley, R.G.V. (2005a). Understanding variability in winegrape production systems 2. Within 4 vineyard variation in quality over several vintages. Aust J Grape Wine Res 11 (1): 33-42. doi:10.1111/j.1755-0238.2005.tb00277.x.
20. Bramley, R.G.V., Proffitt, A.P.B., Hinze, C.J., Pearse, B., Hamilton, R.P. (2005b). Generating benefits from precision viticulture through selective harvesting. In: Proceedings of 5th European Conference on Precision Agriculture: Precision agriculture 2005 (Stafford J. V., ed), Uppsala, Sweden, pp.891-898. doi: 10.3920/978-90-8686-549-9.
21. Bramley, R.G.V. (2010). Precision viticulture: Managing vineyard variability for improved quality outcomes. In: Managing Wine Quality (Reynolds A.G., ed), Woodhead Publishing Ltd, Cambridge, United Kingdom, pp. 445-480. doi: 10.1533/9781845699284.3.445.
22. Bramley, R.G.V., Ouzman, J., Boss, P.K. (2011a). Variation in vine vigour, grape yield and vineyard soils and topography as indicators of variation in the chemical composition of grapes, wine and wine sensory attributes. Aust J Grape Wine Res 17: 217-229. doi: 10.1111/j.1755-0238.2011.00136.x.
23. Bramley, R.G.V., Ouzman, J., Thornton, C. (2011b). Selective harvesting is a feasible and profitabile strategy even when grape and wine production is geared towards large fermentation volumes. Aust J Grape Wine Res 17: 298-305. doi: 10.1111/j.1755-0238.2011.00151.x
24. Buschmann, C., Nagel, E. (1993). In Vivo Spectroscopy and Internal Optics of Leaves as Basis for Remote Sensing of Vegetation. Int J Remote Sens 14: 711-722. doi: 10.1080/01431169308904370
25. Campos, J., García-Ruíz, F., Gil, E. (2021). Assessment of Vineyard Canopy Characteristics from Vigour Maps Obtained Using UAV and Satellite Imagery. Sensors 21 (7), 2363. doi: 10.3390/s21072363
26. Candiago, S., Remondino, F., De Giglio, M., Dubbini, M., Gattelli, M. (2015). Evaluating Multispectral Images and Vegetation Indices for Precision Farming Applications from UAV Images. Remote Sensing 7 (4):4026-4047. doi: 10.3390/rs70404026
27. Carneiro, F.M., Furlani, C.E.A., Zerbato, C., C. de Menezes, P., A. da S. Girio, L. (2019a) Correlations among vegetation indices and peanut traits during different crop development stages. Engenharia Agrícola 39(spe):33-40. doi:10.1590/1809-4430-eng.agric.v39nep33-40/2019
28. Carneiro, F.M., Angeli Furlani, C. E., Zerbato, C., Candida de Menezes, P., da Silva Gírio, L. A., Freire de Oliveira, M. (2019b). Comparison between vegetation indices for

detecting spatial and temporal variabilities in soybean crop using canopy sensors. Precis Agric 21 (13):1-29. doi:10.1007/s11119-019-09704-3.

29. Castle, M.H. (2016). Has the Usage of Precision Agriculture Technologies Actually Led to Increased Profits for Nebraska Producers?. MS. University of Nebraska-Lincoln, USA. Dostupno na: http://digitalcommons.unl.edu/agecondiss/35 [Pristupljeno 30.8.2019.]
30. Coombe, B.G. (1995) Adoption of a system for identifying grapevine growth stages. Aust J Grape Wine Res 1 (2):104-110. doi: 10.1111/j.1755-0238.1995.tb00086.x.
31. Comba, L., Gay, P., Primicerio, J., Ricauda Aimonino, D. (2015). Vineyard detection from unmanned aerial systems images. Comput Electron Agric 114: 78-87 doi:10.1016/j.compag.2015.03.011
32. Costa, B., Oldoni, H., Junior, R., Bassoi, L. (2019). Delimitation of homogeneous zones in vineyards using geostatistics and multivariate analysis of different vegetation indices. Engenharia Agrícola 39: 13-22. doi: 10.1590/1809-4430-eng.agric.v39nep13-22/2019.
33. De Castro, A.I.,Jiménez-Brenes, F.M., Torres-Sánchez, J., Peña, J.M., Borra-Serrano, I., López-Granados, F. (2018). 3-D Characterization of Vineyards Using a Novel UAV Imagery-Based OBIA Procedure for Precision Viticulture Applications. Remote Sens.10 (4): 584. doi: 10.3390/rs10040584.
34. Delenne, C., Durrieu, S., Rabatel, G., Deshayes, M. (2010). From pixel to vine parcel: A complete methodology for vineyard delineation and characterization using remote-sensing data. Comput Electron Agric 70 (1): 78-83. doi:10.1016/j.compag.2009.09.012.
35. Dhoubhadel, S. P. (2020). Precision Agriculture Technologies and Farm Profitability. Journal of Agricultural and Resource Economics 46 (2): 256-268. doi: 10.22004/ag.econ.303598.
36. Di Gennaro, S.F., Dainelli, R., Palliotti, A., Toscano, P., Matese, A. (2019). Sentinel-2 Validation for Spatial Variability Assessment in Overhead Trellis System Viticulture Versus UAV and Agronomic Data. Remote Sens. 11 (21): 2573. doi: 10.3390/rs11212573.
37. D`Urso, M.G., Rotondi, A., Gagliardini, M. (2018). UAV low-cost system for evaluating and monitoring the growth parameters of crops. In: ISPRS Ann. Photogramm. Remote Sens. Spatial Inf. Sci. IV-5 (Kumar A.S., Saran S., Padalia H., eds), Dehradun, India, pp. 405-413. doi: 10.5194/isprs-annals-IV-5-405-2018.
38. ESRI 2012. ArcGIS [GIS software]. Version 10.1. Environmental Systems Research Institute (ESRI), Inc., 2012. ArcGIS Release 10.1. Redlands, CA.

39. EUROSTAT- European Statistical Office. EUROSTAT Database. © European Union, 1995-2022. Luxembourg, Luksemburg. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/APRI_AP_CRPOUTA__custom_2459107/default/table?lang=en [Pristupljeno 19.3.2021.]
40. EUSPA- European Union Agency for the Space Programme (2020). GNSS User Technology Report. Issue 3. Prag, Republika Češka. Dostupno na: https://www.euspa.europa.eu/sites/default/files/uploads/technology_report_2020.pdf [Pristupljeno 6.3.2021.]
41. Fern, R., Foxley, E., Bruno, A., Morrison, M. (2018). Suitability of NDVI and OSAVI as estimators of green biomass and coverage in a semi-arid rangeland. Ecol Indic 94: 16-21. doi: 10.1016/j.ecolind.2018.06.029.
42. Ferrer, M., Echeverria, G., Pereyra, G., Gonzales-Neves, G., Pan, D., Miras-Avalos, J.M. (2020). Mapping vineyard vigour using airborne remote sensing: relations with yield, berry composition and sanitary status under humid conditions. Precis Agric 21 (2): 178-197. doi: 10.1007/s11119-019-09663-9.
43. Filippetti, I., Allegro, G., Valentini, G., Pastore, C., Colucci, E., Intrieri, C. (2013). Influence of vigour on vine performance and berry composition of cv. Sangiovese (*Vitis vinifera* L.). Journal International des Sciences de la Vigne et du Vin 47: 21-33. doi: 10.20870/oeno-one.2013.47.1.1534.
44. Fiorillo, E., Crisci, A., De Filippis, T., Di Gennaro, S.F., Di Blasi, S., Matese, A., Primicerio, J., Vaccari, F.P., Genesio, L. (2012). Airborne high-resolution images for grape classification: changes in correlation between technological and late maturity in Sangiovece vineyard in Central Italy. Aust J Grape Wine Res 18: 80-90. doi: 10.1111/j.1755-0238.2011.00174.x.
45. Fraigneau, C. (2009). Precise Viticulture- Tools to measure and manage variability. Final report, Geography & Environment, School of Geosciences, University of Aberdeen, Scotland, UK. Dostupno na: https://www.abdn.ac.uk/geosciences/documents/Precision_Viticulture_tools_Fraigneau.pdf [Pristupljeno 24.7.2019.]
46. Fulton, J., Port, K. (2018). Precision Agriculture Data Management. In: Precision Agriculture Basics (Shannon D.K., Clay D.E., Kitchen N.R., eds), American Society of Agronomy; Crop Science Society of America; Soil Science Society of America, Madison, Wisconsin, USA, pp. 169-187. doi: 10.2134/precisionagbasics.2016.0095.
47. Gatti, M., Garavani, A., Vercesi, A., Poni, S. (2017). Ground-truthing of remotely sensed within-field variability in a cv. Barbera plot for improving vineyard management. Aust J Grape Wine Res 23 (3): 399-408. doi: https://doi.org/10.1111/ajgw.12286.

48. Gitelson, A.A., Kaufman, Y.J., Merzlyak, M.N. (1996). Use of a green channel in remote sensing of global vegetation from EOS-MODIS. Remote Sens Environ 58 (3): 289-298. doi:10.1016/S0034-4257(96)00072-7.
49. Godwin, R.; Richards, T.E., Wood, G.A, Welsh, J.P, Knight, S.M. (2003). An Economic Analysis of the Potential for Precision Farming in UK Cereal Production. Biosyst Eng. 84: 533-545. doi: 10.1016/S1537-5110(02)00282-9.
50. Griffin, T.W., Lowenberg-DeBoer, J., Lambert, D.M., Peone, J., Payne, B., Daberkow, S.G. (2004). Adoption, profitability, and making betteer use of precision farming data. Staff Paper #04-06, June 2004. Dostupno na: https://ageconsearch.umn.edu/record/28615 [Pristupljeno 24.7.2019.]
51. Griffin, T.W., Shockley, J.M., Mark, T.B. (2018). Economics of Precision Farming. In: Precision Agriculture Basics (Shannon D.K., Clay D.E., Kitchen N.R., eds), American Society of Agronomy; Crop Science Society of America; Soil Science Society of America, Madison, Wisconsin, US, pp. 169-187. doi: 10.2134/precisionagbasics.2016.0095.
52. Grgić, Z., Očić, V., Šakić Bobić, B. (2011). Troškovi i kalkulacije u agrobiznisu. Interna skripta za studente. Agronomski fakultet, Zagreb.
53. Hall, A., Lamb, D.W. Holzapfel, B., Louis, J. (2002). Optical remote sensing applications in viticulture - a review. Aust J Grape Wine Res 8 (1): 36-47. doi: 10.1111/j.1755-0238.2002.tb00209.x.
54. Hatfield, J.L. (2000). Precision Agriculture and Environmental Quality: Challenges for Research and Education. Summary for The National Arbor Day Foundation. Dostupno na: http://elibrary.cenn.org/Miscellaneous/Precision%20Agriculture%20and%20Environmental%20Quality%20Challenges%20for%20Research%20and%20Education.pdf [Pristupljeno 30.7.2019.]
55. Huete, A.R. (1988). A soil adjusted vegetation index (SAVI). Remote Sens. Environ. 25: 295–309. doi: 10.1016/0034-4257(88)90106-X.
56. Idso, S.B., Jackson, R.D., Pinter, Jr. P.J., Reginato, R.J., Hatfield, J.L. (1981). Normalizing the stress-degree-day parameter for environmental variability. Agricultural Meteorology 24 (1):45-55. doi: 10.1016/0002-1571(81)90032-7.
57. Ihuoma, S., Madramootoo, C. (2017). Recent advances in crop water stress detection. Comput Electron Agric 141: 267-275. doi: 10.1016/j.compag.2017.07.026.
58. Johnson, L.F., Bosch, D.F., Williams, D.C., Lobitz, B.M. (2001). Remote sensing of vineyard management zones: Implications for wine quality. Appl Eng Agric 17 (4):557-560. doi: 10.13031/2013.6454.

59. Joint Research Centre (JRC) of the European Commission (2014). Precision Agriculture: An Opportunity for EU Farmers - Potential Support with the CAP 2014-2020. Dostupno na: https://www.europarl.europa.eu/RegData/etudes/note/join/2014/529049/IPOL-AGRI_NT%282014%29529049_EN.pdf [Pristupljeno 28.7.2019.]
60. Jones, H.G., Grant, O.M. (2016). Remote sensing and other imaging technologies to monitor grapevine performance. In: Grapevine in a Changing Environment: A Molecular and Ecophysiological Perspective (Gerós H., Chaves M.M., Medrano Gil H., Delrot S., eds), John Wiley & Sons Ltd, New Jersey, USA, pp: 179-201. doi: 10.1002/9781118735985.ch8
61. Jorge, J., Vallbé, M., Soler, J. A. (2019). Detection of irrigation inhomogeneities in an olive grove using the NDRE vegetation index obtained from UAV images. Eur J Remote Sens 52 (1): 169-177. doi: 10.1080/22797254.2019.1572459.
62. Kanič, M. (2018). Dronovi. Završni rad. Veleučilište u Rijeci, Rijeka
63. Kandylakis, Z., Karantzalos, K. (2016). Precision viticulture from multitemporal, multispectral very high resolution satellite data. In: Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci. XLI-B8 (Halounova L., Šafář V., Raju P. L. N., Plánka L., Ždímal V., Srinivasa Kumar T., Faruque F. S, Kerr Y., Ramasamy S. M., Comiso J., Hussin Y. A. (Yousif), Thenkabail P. S., Lavender S., Skidmore A., Yue P., Patias P., Altan O., Weng Q., eds), Prague, Czech Republic, pp. 919-925. doi: 10.5194/isprs-archives-XLI-B8-919-2016.
64. Kazmierski, M., Glémas, P., Rousseau, J., Tisseyre, B. (2011). Temporal stability of within-field patterns of NDVI in non irrigated Mediterranean vineyards. OENO One 45 (2): 61–73. doi: 10.20870/oeno-one.2011.45.2.1488.
65. Khaliq, A., Comba, L., Biglia, A., Ricauda Aimonino, D., Chiaberge, M., Gay, P. (2019). Comparison of Satellite and UAV-Based Multispectral Imagery for Vineyard Variability Assessment. Remote Sens 11 (4), 436. doi: 10.3390/rs11040436.
66. Kernecker, M., Knierim, A., Wurbs, A., Kraus, T., Borges, F. (2018). Project Smart-AKIS, Smart Farming Thematic Network. Dostupno na: https://www.smart-akis.com/wp-content/uploads/2019/01/Peer-reviewed-paper.pdf [Pristupljeno 28.7.2019.]
67. Kidman, C., Pagay, V., Jenkins, A. (2017). Optimizing water use efficiency for improved wine quality in Coonawarra vineyards using remote sensing technologies-Season 2. FINAL REPORT. Dostupno na: https://coonawarra.org/wp-content/uploads/2017/06/CWGI-Final-report-310517.pdf [Pristupljeno 1.9.2019.]

68. Knight, S., Miller, P., Orson, J. (2009). An up-to-date cost/benefit analysis of precision farming techniques to guide growers of cereals and oilseeds. HGCA Research Review. Dostupno na: https://projectblue.blob.core.windows.net/media/Default/Research%20Papers/Cereals%20and%20Oilseed/rr71-final-project-report.pdf [Pristupljeno 28.10.2019.]
69. Korunić, K. (2017) CBA- analiza troškova i koristi. Moneo savjetovanje d.o.o., Zagreb, Hrvatska
70. Krstić, G. (2012) Savremeni trendovi primene informacionih tehnologija u oblasti poljoprivrede. In: Zbornik radova Konferencija YUINFO 2012 (Ivković M., ed), Kopaonik, Republika Srbija, pp. 306-310.
71. Lamb, D.W., Weedon, M.M., Bramley, R.G.V. (2004). Using remote sensing to map grape phenolics and colour in a Cabernet sauvignon vineyard - the impact of image resolution and vine phenology. Aust J Grape Wine Res 10 (1):46-54. doi: 10.1111/j.1755-0238.2004.tb00007.x.
72. Lambert, D., Lowenberg-DeBoer, J. (2000). Precision Agriculture Profitability Review. Site-specific Management Center, School of Agriculture, Purdue University, West Lafayette, USA. Dostupno na: https://www.agriculture.purdue.edu/ssmc/Frames/newsoilsX.pdf [Pristupljeno 28.7.2019.]
73. Lambert, D. M., Lowenberg-DeBoer, J., Griffin, T. W., Peone, J., Payne, T., Daberkow S.G. (2004). Adoption, profitability, and making better use of precision farming data. Staff Papers 28615, Purdue University, West Lafayette, USA. Dostupno na: https://ageconsearch.umn.edu/record/28615 [Pristupljeno 28.7.2019.]
74. Ledderhof, D., Brown, R., Reynolds, A., Jollineau, M. (2016). Using remote sensing to understand Pinot noir vineyard variability in Ontario. Can J Plant Sci 96 (1): 89-108. doi: 10.1139/cjps-2015-0120.
75. Lowenberg-DeBoer, J., Boehlje, M. (1996). Revolution, Evolution or Dead-End: Economic Perspectives on Precision Agriculture. In: Proceedings of the Third International Conference on Precision Agriculture (Robert P.C, Rust R.H., Larson W.E., eds), Minneapolis, Minnesota, USA, pp. 921-944. doi: 10.2134/1996.precisionagproc3.c116.
76. Maletić, E., Karoglan Kontić, J., Pejić, I. (2008) Vinova loza ampelografija, ekologija, oplemenjivanje. Školska knjiga, Zagreb, Hrvatska.
77. Maletić, E., Karoglan Kontić, J., Pejić, I., Preiner, D., Zdunić, G., Bubola, M., Stupić, D., Andabaka, Ž., Marković, Z., Šimon, S., Žulj Mihaljević, M., Ilijaš, I., Marković, D. (2015). Zelena knjiga: Hrvatske izvorne sorte vinove loze. Hrvatska agencija za okoliš i prirodu, Zagreb, Hrvatska, pp. 308-309. e-knjiga- Dostupno na:

https://www.agr.unizg.hr/multimedia/03d1ddc97051e60b1563fce2493453fbee61b34e2ff04f5b3b63481e9ae7e3d6afcfea551562585902.pdf [Pristupljeno 13.3.2020.]

78. Martínez-Casasnovas,, J.A., Agelet-Fernandez, J., Arnó, J., Ramos, C. (2012). Analysis of vineyard differential management zones and relation to vine development, grape maturity and quality. Spanish Journal of Agriculture Research 10 (2): 326-337. doi: 10.5424/sjar/2012102-370-11.
79. Matese, A., Crisci, A., Di Gennaro, F. S., Fiorillo, E., Primicerio, J., Toscano, P., Primo Vaccari, F., Di Blasi, S., Genesio, L. (2012). Influence of Canopy Management Practices on Vineyard Microclimate: Definition of New Microclimatic Indices. Am J Enol Vitic 63 (3): 424–430. doi: 10.5344/ajev.2012.11117.
80. Matese, A., Crisci, A., Di Gennaro, S. F., Primicerio, J., Tomasi, D., Marcuzzo, P., Guidoni, S. (2014). Spatial variability of meteorological conditions at different scales in viticulture. Agric For Meteorol s189-190: 159-167. doi: 10.1016/j.agrformet.2014.01.020.
81. Matese A., Di Genaro S.F. (2015). Technology in precision viticulture: a state of the art review. International Journal of Wine Research 7 (1): 69-81. doi: 10.2147/IJWR.S69405.
82. Matese, A., Di Gennaro, S., Miranda, C., Berton, A., Santesteban, L. (2017). Evaluation of spectral-based and canopy-based vegetation indices from UAV and Sentinel 2 images to assess spatial variability and ground vine parameters. Advances in Animal Biosciences, 8 (2): 817-822. doi:10.1017/S2040470017000929.
83. Matese, A.; Di Gennaro, S.F. (2018). Practical Applications of a Multisensor UAV Platform Based on Multispectral, Thermal and RGB High Resolution Images in Precision Viticulture. Agriculture 8, 116. https://doi.org/10.3390/agriculture8070116.
84. Maynard, H. D. (2015) An Economic Analysis of Precision Viticulture, Fruit, and Pre-Release Wine Pricing across Three Western Australian Cabernet Sauvignon Vineyards. PhD. Curtin University, Perth, Australia. Dostupno na: https://espace.curtin.edu.au/bitstream/handle/20.500.11937/1919/241006_Maynard%20Hayley%202016.pdf?sequence=2 [Pristupljeno 15.3.2019.]
85. Microsoft Corporation (2010). Microsoft Excel. Dostupno na: https://office.microsoft.com/excel
86. Mirošević, N., Turković, Z. (2003). Ampelografski atlas. Golden marketing- Tehnička knjiga, Zagreb, Hrvatska
87. Mirošević, N., Alpeza, I., Bolić, J., Brkan, B., Hruškar, M., Husnjak, S., Jelaska, V., Karoglan Kontić, J., Maletić, E., Mihaljević, B., Ričković, M., Šestan I., Zoričić, M. (2009). Atlas hrvatskog vinogradarstva i vinarstva. Golden marketing- Tehnička knjiga, Zagreb, Hrvatska

88. Njavro, M. (2008). Kada i zašto se koristi gross margin analiza-kratki vodič (Preuzeto od Terms of References, «Contribution to the Farm Data Information Network» (FAO SEUR), u originalu: «D.W. Norman, Agricultural Economics Department, Kansas State University, SAD (izvješće za UN FAO, AGSP i AGS)). Dostupno na: http://agririsk.agr.hr/Uprava-pdf/gross_margin.pdf [Pristupljeno 13.9.2019.]
89. Nolan, A. P., Park, S., O'Connell, M., Fuentes, S., Ryu, D., Chung, H. (2015). Automated detection and segmentation of vine rows using high resolution UAS imagery in a commercial vineyard. In: Proceedings of 21st International Congress on Modelling and Simulation, MODSIM 2015 (Weber T., McPhee M., Anderssen R., eds.), Gold Coast, Australia, pp. 1406-141
90. Oldoni, H., Costa, B.R.S., Bognola, I.A., de Souza, C.R., Bassoi, L.H. (2021). Homogeneous zones of vegetation index for characterizing variability and site-specific management in vineyards. Sci. Agric. 78 (4), e20190243. doi: 10.1590/1678-992x-2019-0243.
91. Orsag, S. (2002). Budžetiranje kapitala: Procjena investicijskih projekata. Masmedia, Zagreb, Hrvatska
92. Ortega-Blu, R., Molina-Roco, M. (2016). Evaluation of vegetation indices and apparent soil electrical conductivity for site-specific vineyard management in Chile. Precis Agric 17(4): 434-450. doi:10.1007/s11119-016-9429-x.
93. Osrečak, M., Jeromel, A., Puhelek, I., Huzanić, N., Jagatić Korenika, A-M., Anić, M., Karoglan, M. (2020). Mikoriza u vinogradarskoj proizvodnji. Glasnik zašite bilja 43 (4): 26-30. doi: 10.31727/gzb.43.4.4.
94. Ozdemir, G., Sessiz, A., Pekitkan, F.G. (2017). Precision viticulture tools to production of high quality grapes. Horticulture LXI: 209-218. Dostupno na: http://horticulturejournal.usamv.ro/pdf/2017/Art30.pdf [Pristupljeno 25.7.2019.]
95. Pádua, L. ,Vanko, J., Hruška, J., Adão, T., Sousa, J., Peres, E., Morais, R. (2017). UAS, sensors, and data processing in agroforestry: a review towards practical applications. Int J Remote Sens 38 (8-10): 2349-2391. doi: 10.1080/01431161.2017.1297548.
96. Pádua, L., Marques, P., Adão, T., Guimarães, N., Sousa, A., Peres, E., Sousa, J. (2019). Vineyard Variability Analysis through UAV-Based Vigour Maps to Assess Climate Change Impacts. Agronomy 9 (10): 581. doi: 10.3390/agronomy9100581.
97. Pastonchi, L., Di Gennaro, S. F., Toscano, P., Matese, A. (2020). Comparison between satellite and ground data with UAV-based information to analyse vineyard spatio-temporal variability. OENO One 54 (4): 919–934. doi: 10.20870/oeno-one.2020.54.4.4028.

98. Patrun, L. (2019). Mjerenje sjanosti kolnika digitalnim fotoaparatom. Diplomski rad. Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija, Osijek
99. Pichon, L., Leroux, C., Macombe, C., Taylor, J., Tisseryre, B. (2019). What relevant information can be identified by experts on unmanned aerial vehicles' visible images for precision viticulture?. Precision Agric 20 (5): 278-294. doi: 10.1007/s11119-019-09634-0.
100. Pierpaoli, E., Carli, G., Pignatt, E., Canavari, M. (2013). Drivers of Precision Agriculture Technologies Adoption: A Literature Review. Procedia Technology 8: 61-69. doi: 10.1016/j.protcy.2013.11.010.
101. Poni, S., Gatti, M., Palliotti, A., Dai, Z., Duchêne, E., Truong, T.T., Ferrara, G., Matarrese, A., Gallotta, A., Bellincontro, A., Mencarelli, F., Tombesi, S. (2017). Grapevine quality: A multiple choice issue. Sci Hortic 234: 445-462. doi: 10.1016/j.scienta.2017.12.035.
102. Pourezza, A., Moghimi, A., Zuniga-Ramirez, G., Omidi, R. (2020). Project: Remote sensing for precision vineyard nutrient management- Prediction of Nitrogen Status in Table Grape Using Drone Imagery. UC Davis Digital Agricultural Laboratory, Davis, USA. Dostupno na: https://digitalag.ucdavis.edu/research/High-Resolution-Vineyard-Nutrient/2018 [Pristupljeno 25.7.2021.]
103. Primicerio, J., Gay, P., Ricauda Aimonino, D., Comba, L., Matese, A., Di Gennaro, S. (2015). NDVI-based vigour maps production using automatic detection of vine rows in ultra-high resolution aerial images. In Precision Agriculture '15 -Proceedings of 10th European Conference on Precision Agriculture (Stafford J.V., ed), Tel-Aviv, Israel, Wageningen Academic Publishers, Wageningen, Netherlands, pp. 465-470. doi:10.3920/978-90-8686-814-8_57.
104. Proffit, T., Malcom, A. (2005). Zonal vineyard management through airborne remote sensing. The Australian & New Zealand Grapegrower & Winemaker 502: 22-27. Dostupno na: http://winetitles.com.au/gwm/articles/november-502/zonal-vineyard-management-through-airborne-remote-sensing/ [Pristupljeno 13.9.2020.]
105. Proffitt, T.,Bramley R. G.V., Lamb, D., Winter, E. (2006). Precision Viticulture : A New Era in Vineyard Management and Wine Production. Winetitles Pty Ltd., Ashford, South Australia
106. Radočaj, D., Obhođaš, J., Jurišić, M.,Gašparović, M. (2020) Global Open Data Remote Sensing Satellite Missions for Land Monitoring and Conservation: A Review. Land 9 (11): 402. doi: 10.3390/land9110402

107. Rataj, V., Galambošová, J. (2011). Economical assessment of information in precision agriculture. Dostupno na: https://www.researchgate.net/publication/289397914_Economical_assessment_of_information_in_precision_agriculture [Pristupljeno 14.10.2020.]

108. Ravaz, L. (1903). Sur la brunissure de la vigne. Les Comptes Rendus de l'Académie des Sciences 136:1276-1278.

109. Rendulić Jelušić, I., Anić, M., Puhelek, I., Osrečak, M., Šakić Bobić, B., Grgić, Z., Karoglan, M. (2020). Pregled novih tehnologija za praćenje vinogradarske proizvodnje i primjenu preciznog vinogradarstva. In: Zbornik radova 55. hrvatski i 15. međunarodni simpozij agronoma (Mioč B., Širić I., eds), Sveučilište u Zagrebu, Agronomski fakultet, Zagreb, Hrvatska, pp. 510-514

110. Rendulić Jelušić, I., Kraljičković, J., Karoglan, M., Grgić, Z., Šakić Bobić, B. (2021) Stav vinogradara Zagrebačke županije prema novim tehnologijama za praćenje vinogradarske proizvodnje In: Zbornik radova 56. hrvatski i 16. međunarodni simpozij agronoma (Rozman V., Antunović Z., eds), Fakultet agrobiotehničkih znanosti Sveučilišta Josipa Jurja Strossmayera u Osijeku, Osijek, Hrvatska, pp. 279-283

111. Rey Caramés, C. (2015). Assessment of the spatial variability of vegetative status in vineyards using non-destructive sensors. Application of remote and proximal sensing technologies in precision viticulture. PhD. Universidad de La Rioja, La Rioja, Spain

112. Reynolds, A.G., Brown, R., Jollineau, M., Shemrock, A., Lee, H., Dorin, B., Shabanian, M., Meng, B. (2018). Viticultural Mapping by UAVs, Part 2 Applying unmanned aerial vehicles in viticulture. Wines & Vine. Dostupno na: https://www.vineyardteam.org/files/resources/Wines%20&%20Vine%20Aerial%20Imaging%20Pt.%202.pdf [Pristupljeno 18.9.2020.]

113. Rondeaux, G., Steven, M., Baret, F. (1996). Optimization of Soil-Adjusted Vegetation Indices. Remote Sens Environ 55 (2): 95-107. doi: 10.1016/0034-4257(95)00186-7.

114. Rouse, J.W.; Haas, R.H.; Schell, J.A.; Deering, D.W. (1973). Monitoring vegetation systems in the Great Plains with ERTS. In: Proceedings of the Third ERTS Symposium, (Freden S.C., Boecke J.H., eds), NASA, Washington, DC, USA, pp. 20 Dostupno na: https://ntrs.nasa.gov/api/citations/19740003048/downloads/19740003048.pdf [Pristupljeno 15.5.2019.]

115. Rousseau, J., Lefevre, V., Douche, H., Poilve, H. and Habimana, T. (2013). Oenoview®: Remote Sensing in Support of Vineyard Profitability and Wine Quality. Acta Hortic 978: 139-148, doi: 10.17660/ActaHortic.2013.978.15.

116. Santesteban, L.G., Guillaume, S., Royo, J.B., Tisseyre, B. (2013). Are precision agriculture tools and methods relevant at the whole-vineyard scale?. Precis Agric 14: 2–17. doi: 10.1007/s11119-012-9268-3.

117. Santesteban, L.G. (2019). Precision viticulture and advanced analytics. A short review. Food Chem 279: 58-62. doi: 10.1016/j.foodchem.2018.11.140.

118. Santos, A.O., WampleII R.L., Sachidhanantham, S., Kaye, O. (2012). Grape quality mapping for vineyard differential harvesting. Brazilian Archives of Biology and Technology 55 (2): 193-204. doi: 10.1590/S1516-89132012000200003.

119. Sassu, A., Gambella, F., Ghiani, L., Mercenaro, L., Caria, M., Pazzona, A.L. (2021) Advances in Unmanned Aerial System Remote Sensing for Precision Viticulture. Sensors. 21 (3): 956. doi: 10.3390/s21030956.

120. Schimmelpfennig, D. (2016). Farm Profits and Adoption of Precision Agriculture, U.S. Department of Agriculture, Economic Research Service. Dostupno na: https://www.ers.usda.gov/webdocs/publications/80326/err-217.pdf?v=0 [Pristupljeno 15.11.2019.]

121. Shockley, J., Mark, T., Dillon, C. (2017). Educating producers on the profitability of precision agriculture technologies. Advances in Animal Biosciences 8 (2): 724-727. doi:10.1017/S2040470017000759.

122. Smart, R. (1985). Principles of grapevine canopy management microclimate manipulation with implications for yield andquality. Am J Enol Vitic 36(3): 230-239.

123. Soubry, I., Patias, P., Tsioukas, V. (2016). Monitoring vineyards with UAV and multi-sensors for the assessment of water stress and grape maturity. J Unmanned Veh Syst 5(2): 37-50. doi: 10.1139/juvs-2016-0024.

124. SPSS (2021) IBM Corp. Released 2021. IBM SPSS Statistics for Windows, Version 28.0. Armonk, NY: IBM Corp. Trial version. Dostupno na: https://www.ibm.com/analytics/spss-trials [Pristupljeno 4.6.2021.]

125. Steyn, J., Aleixandre-Tudo, J.L., Aleixandre, J.L. (2016). Grapevine Vigour and Within-Vineyard Variability: A Review. Int J Sci Eng Res 7 (2): 1056-1065. Dostupno na: https://riunet.upv.es/bitstream/handle/10251/97767/Research%20paper.%20Definitivo.pdf?sequence=1&isAllowed=y [Pristupljeno 18.9.2020.]

126. Šmejkal, M. (2018). Mogućnosti primjene dronova u Republici Hrvatskoj, Diplomski rad. Sveučilište u Zagrebu, Fakultet prometnih znanosti, Zagreb

127. Swinton, S.M., Ahmad, M. (1996). Returns to Farmer Investments in Precision Agriculture Equipment and Services. In: Proceedings of the Third International Conference on Precision Agriculture (Robert P.C, Rust R.H., Larson W.E., eds),

Minneapolis, Minnesota, USA, pp. 1009-1018. doi: 10.2134/1996.precisionagproc3.c124.

128. Tanda, G., Chiarabini, V. (2019). Use of multispectral and thermal imagery in precision viticulture. J. Phys: Conf. Ser. 1224. doi:10.1088/1742-6596/1224/1/012034

129. Tardáguila, J., Blasco, J., Diago, M.P. (2017) Vinerobot. European Commission, FP7-ICT - Specific Programme "Cooperation": Information and communication technologies, ICT-2013.2.2 - Robotics use cases; Accompanying measures, Call for proposal: FP7-ICT-2013-10 Dostupno na: https://cordis.europa.eu/project/rcn/111031/results/en [Pristupljeno 15.11.2019.]

130. Tey, Y.S., Bindal, M. (2012). Factors influencing the adoption of precision agricultural technologies: A review for policy implications. Precis Agric 13 (6): 713-730. doi: 10.1007/s11119-012-9273-6.

131. Thompson, J.L., Puntel, A. L. (2020). Transforming Unmanned Aerial Vehicle (UAV) and Multispectral Sensor into a Practical Decision Support System for Precision Nitrogen Management in Corn. Agronomy & Horticulture -- Faculty Publications. Dostupno na: https://digitalcommons.unl.edu/agronomyfacpub/1340 [Pristupljeno 18.9.2020.]

132. Tisseyre, B., Taylor, J.A. (2005). An overview of methodologies and technologies for implementing precision agriculture in viticulture. In: Proceedings of XII Congresso Brasileiro de Vitivinicultura e Enologia (Ritschel P., De Souza Sebben, S.) Bento Gonçalves, Brasil, pp. 45-54

133. Tisseyre, B., Mazzoni, C., Fonta, H. (2008). Whithin-field temporal stability of some 40 parameters in viticulture: potential toward a site specific management. J. Int. Sci. Vigne Vin 42 (1): 27-39. doi: 10.20870/oeno-one.2008.42.1.834.

134. Tsouros, D.C., Bibi, S., Sarigiannidis, P.G. (2019). A Review on UAV-Based Applications for Precision Agriculture. Information 10 (11): 349. doi: 10.3390/info10110349.

135. Urretavizcaya, I., Santesteban, L.G., Tisseyre, B., Guillaume, S. (2014). Oenological significance of vineyard management zones delineated using early grape sampling. Precis Agric 15: 111–129. doi: 10.1007/s11119-013-9328-3.

136. Üstüner, M., Sanli, F. B., Abdikan, S., Esetlili, M. T., Kurucu, Y. (2014) Crop Type Classification Using Vegetation Indices of RapidEye Imagery. In: Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci. XL-7 (Sunar F., Altan O., Taberner M., eds), Istanbul, Turkey, pp. 195 -198. doi: 10.5194/isprsarchives-XL-7-195-2014.

137. Vanegas, F., Bratanov, D., Powell, K., Weiss, J., Gonzalez, F. (2018). A Novel Methodology for Improving Plant Pest Surveillance in Vineyards and Crops Using

UAV-Based Hyperspectral and Spatial Data. Sensors 18 (1): 260. doi: 10.3390/s18010260.

138. Vidučić, Lj., Pepur, S., Šimić Šarić, M. (2015). Financijski menadžment- IX. dopunjeno i izmijenjeno izdanje. RRiF-plus d.o.o. za nakladništvo i poslovne usluge, Zagreb, Hrvatska

139. Vicente, L.E., Gomes, D., Zillmann, E., Gonzales, A., Vicente, A.K., Pedroni de Oliviera, B., Spinelli de Araujo, L. (2017). Assessment of vegetational incices applied to sugarcane monitoring using Rapideye images. In: Proceedings of XVIII Simposio Brasilero de Sensoriamento Remoto (Gherardi D.F.M., Eduardo L., Aragão C., eds), Santos, Brasil, pp. 3970-3977

140. Viña, A., Gitelson, A. A. (2005). New developments in the remote estimation of the fraction of absorbed photosynthetically active radiation in crops. Geophys Res Lett 32 (17): L17403. doi: 10.1029/2005GL023647.

141. Xue, J, Su, B. (2017). Significant Remote Sensing Vegetation Indices: A Review of Developments and Application. J Sens 2017(1):1-17. doi: 10.1155/2017/1353691.

142. Zhang, C., Kovacs, J.M. (2012). The application of small unmanned aerial systems for precision agriculture: a review. Precision Agric 13 (6): 693–712. doi: 10.1007/s11119-012-9274-5.

143. Zovko, M., Žibrat, U., Knapič, M., Bubalo Kovačić, M., Romić, D. (2019). Hyperspectral remote sensing of grapevine drought stress. Precision Agric 20 (1): 335–347. doi: 10.1007/s11119-019-09640-2.

ŽIVOTOPIS KANDIDATA

Ivana Rendulić Jelušić rođena je 09.03.1981. godine u Zagrebu, gdje i danas živi sa suprugom Augustinom i sinom Lovrom. Pohađala je Osnovnu školu Izidora Kršnjavoga u Zagrebu te Gornjogradsku (VI) gimnaziju u kojoj je maturirala 1999. godine s odličnim uspjehom. Iste godine upisuje Agronomski fakultet Sveučilišta u Zagrebu, smjer Bilinogojstvo, usmjerenje voćarstvo, vinogradarstvo i vinarstvo na kojem je, s prosjekom ocjena 4,61, diplomirala 11.7.2005. godine obranivši diplomski rad na temu *„Novi kultivar u uvjetima regije Kontinentalna Hrvatska cv. Manzoni bijeli (Vitis vinifera L.)“* pod mentorstvom prof.dr.sc. Bernarda Kozine. Tijekom studija bila je stipendistica Ministarstva znanosti i tehnologije Republike Hrvatske i stipendistica Grada Zagreba. Pohvala Dekana prigodom dana fakulteta za primjeran uspjeh u studiju dodijeljena joj je 2002. godine, a 2004. godine primila je i Dekanovu nagradu za marljivost i ostvarenje uzornih rezultata u studiranju. Iste godine dobitnica je i Rektorove nagrade Sveučilišta u Zagrebu za znanstveni rad „*Primjena mikrosatelitskih markera u utvrđivanju sinonima kod pojedinih sorata vinove loze Hrvatskog primorja*“ pod mentorstvom doc.dr.sc. Aleša Vokurke. Tijekom studija pokazivala je interes za znanstvena istraživanja te je aktivno sudjelovala u istraživanjima iz područja voćarstva i vinogradarstva.

Nakon studija, krajem 2006. godine zapošljava se u Zagrebačkoj županiji, u Upravnom odjelu za poljoprivredu, ruralni razvitak i šumarstvo kao vježbenik te dalje napreduje do višeg stručnog suradnika uz aktivan rad na mjerama i programima razvoja poljoprivrede, posebice vinogradarstva i vinarstva na području Zagrebačke županije, pod mentorstvom mr.sc. Josipa Kraljičkovića. 2014. godine, zbog reorganizacije unutar Zagrebačke županije, počinje raditi u Upravnom odjelu za EU fondove i međunarodnu suradnju na mjestu voditelja Odsjeka za međunarodnu suradnju gdje stječe bogato međunarodno iskustvo te znanja i vještine za pripremu i provedbu EU projekata. Uz brojne dodatne specifične edukacije i sudjelovanja na konferencijama, pokazuje interes i za nove digitalne tehnologije i njihovu primjenu u javnoj upravi i poljoprivredi. Voditeljica je brojnih razvojnih projekata na razini Zagrebačke županije, članica više projektnih timova te članica različitih vijeća i odbora na regionalnoj i međunarodnoj razini. Od lipnja 2020. godine voditeljica je Odsjeka za regionalni razvoj i međunarodnu suradnju u Upravnom odjelu za gospodarstvo i fondove EU Zagrebačke županije gdje, između ostalog, sudjeluje u planiranju, izradi i provedbi strateških dokumenata, planiranju i provedbi strateških projekata, organizaciji međunarodne suradnje, planiranju i provedbi mjera regionalnog razvoja i dr.

No, uz dinamičan i zanimljiv posao u regionalnoj samoupravi, želja za znanstvenim radom i daljnjim usavršavanjem rezultirala je upisom Poslijediplomskog doktorskog studija Poljoprivredne znanosti na Agronomskom fakultetu Sveučilišta u Zagrebu u akademskoj godini 2006/2007 u drugoj generaciji upisanih studenata. Tijekom studija, uz manje promjene istraživačke teme i mentora, odabire temu istraživanja na kojoj izrađuje svoju doktorsku disertaciju vezanu uz istraživanje i praktičnu primjenu novih tehnologija u vinogradarstvu. Kao jedna od prvih istraživača u Republici Hrvatskoj u području pametnog vinogradarstva, proučava upotrebu bespilotnih letjelica – dronova opremljenih multispektralnim kamerama i njihovu praktičnu primjenu na malim vinogradarskim površinama uz procjenu ekonomičnosti tih postupaka, uz mentorstvo prof.dr.sc. Marka Karoglana i izv.prof.dr.sc. Branke Šakić Bobić.

Aktivno se služi engleskim i talijanskim jezikom što potvrđuje i međunarodnim certifikatima B2 razine. Posjeduje vozačku dozvolu B kategorije. Aktivno se služi računalom uz korištenje specijaliziranih programskih paketa kao što su Pix4D, DJI Terra i sl.

Članica je Povjerenstva za organoleptičko ocjenjivanje vina i voćnih vina od 2008. godine, a sudjeluje i kao ocjenjivač vina na brojnim domaćim i međunarodnim ocjenjivanjima vina. Bila je Vinska kraljica Zagrebačke županije za 2006. godinu.

Popis radova

Radovi u časopisima

Znanstveni i pregledni radovi

1. Rendulić Jelušić, Ivana; Šakić Bobić, Branka; Grgić, Zoran; Žiković, Saša; Osrečak, Mirela; Puhelek, Ivana; Anić, Marina; Karoglan, Marko

Grape Quality Zoning and Selective Harvesting in Small Vineyards—To Adopt or Not to Adopt. // *Agriculture*, 12 (2022), 6; 852, 22 doi:10.3390/agriculture12060852 (međunarodna recenzija, članak, znanstveni)

2. Karoglan Kontić, Jasminka; Rendulić Jelušić, Ivana; Tomaz, Ivana; Preiner, Darko; Marković, Zvjezdana; Stupić, Domagoj; Andabaka, Željko; Maletić, Edi.

Polyphenolic Composition of the Berry Skin of Six Fungus-Resistant Red Grapevine Varieties. // *International Journal of Food Properties*, 19 (2016), 8; 1809-1824 doi:10.1080/10942912.2015.1107844 (međunarodna recenzija, članak, znanstveni)

3. Jeromel, Ana; Kovačević Ganić, Karin; Herjavec, Stanka; Mihaljević, Marin; Jagatić Korenika, Ana-Marija; Rendulić, Ivana; Čolić, Marijana.

Concentration of Biogenic Amines in 'Pinot Noir' Wines Produced in Croatia. // *ACS - Agriculturae conspectus scientificus*, 77 (2012), 1; 37-40. (https://www.bib.irb.hr/599106) (međunarodna recenzija, članak, znanstveni)

Radovi u zbornicima skupova

Znanstveni radovi u zbornicima skupova

4. Rendulić Jelušić, Ivana; Kraljičković, Josip; Karoglan, Marko; Grgić, Zoran; Šakić Bobić, Branka

Stav vinogradara Zagrebačke županije prema novim tehnologijama za praćenje vinogradarske proizvodnje. // 56th Croatian & 16th International Symposium on Agriculture eProceedings / Rozman, Vlatka ; Antunović, Zvonko (ur.). Osijek, Fakultet agrobiotehničkih znanosti, 2021. str. 279-283 (https://www.bib.irb.hr/1142601/download/1142601.PROCEEDINGS.pdf) (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

5. Rendulić Jelušić, Ivana; Anić, Marina; Puhelek, Ivana; Osrečak, Mirela; Šakić Bobić, Branka; Grgić, Zoran; Karoglan, Marko

Pregled novih tehnologija za praćenje vinogradarske proizvodnje i primjenu preciznog vinogradarstva. // 55th Croatian & 15th International Symposium on Agriculture eProceedings.Full text / Mioč, Boro ; Širić, Ivan (ur.). Zagreb: Agronomski fakultet, 2020. str. 510-514. (https://www.bib.irb.hr/1075627) (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

6. Brišar, Sanda; Rendulić, Ivana; Preiner, Darko; Maletić, Edi; Karoglan Kontić, Jasminka

Biološke i gospodarske karakteristike međuvrsnih križanaca vinove loze tolerantnih prema gljivičnim bolestima u uvjetima Zagrebačkog vinogorja. // Proceedings of 43rd Croatian and 3rd International Symposium on Agriculture / Pospišil, Milan (ur.). Zagreb: Sveučilište u Zagrebu, Agronomski Fakultet, 2008. str. 312-313 (poster, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

7. Puškar, Boris; Rendulić, Ivana; Vokurka, Aleš; Pejić, Ivan
Unutarsortna varijabilnost Oblačinske višnje. // Zbornik radova XL. znanstvenog skupa hrvatskih agronoma s međunarodnim sudjelovanjem / Kovačević, Vlado; Jovanovac, Sonja (ur.). Osijek: Poljoprivredni fakultet Sveučilišta J.J. Strossmayera u Osijeku, 2005. str. 727-728 (predavanje, cjeloviti rad (in extenso), znanstveni)

Sažeci sa skupova

Sažeci u zbornicima i časopisima

8. Stupić, Domagoj; Marković, Zvjezdana; Preiner, Darko; Andabaka, Željko; Karoglan Kontić, Jasminka; Maletić, Edi; Jeromel, Ana; Rendulić Jelušić, Ivana; Štambuk, Petra; Šikuten, Iva.
Otporne sorte vinove loze nove generacije. // Zbornik radova "Drugi središnji stručni skup vinogradara i vinara Hrvatske", Požega, Hrvatska, 2019. str. 40-41 (predavanje, domaća recenzija, sažetak, stručni)

9. Kozina, Bernard; Karoglan, Marko; Rendulić, Ivana; Osrečak, Mirela
Manzoni bijeli - novi vinski kultivar u Hrvatskoj. // Drugi hrvatski oplemenjivački i sjemenarski kongres - Program i sažeci / Ivan Kolak (ur.). Zagreb: GRAFO 900 - Zagreb, 2006. str. 64-65 (predavanje, domaća recenzija, sažetak, znanstveni)

Druga sudjelovanja na skupovima

10. Jeromel, Ana; Kovačević Ganić, Karin; Herjavec, Stanka; Mihaljević, Marin; Jagatić Korenika, Ana-Marija; Rendulić, Ivana; Čolić, Marijana.
Concentration of Biogenic Amines in 'Pinot Noir' Wines Produced in Croatia. // 46th Croatian & 6th International Symposium on Agriculture, Opatija, Hrvatska, 2011. str. 1-2 (poster, međunarodna recenzija, sažetak, znanstveni)

Ostale vrste radova

11. Rendulić, Ivana
Primjena mikrosatelitskih markera u utvrđivanju sinonima kod pojedinih sorata vinove loze Hrvatskog primorja, 2004. (podatak o recenziji nije dostupan, studentski rad nagrađen rektorovom nagradom).

8. PRILOG

ANKETA: TRŽIŠNE CIJENE GROŽĐA SORTE 'KRALJEVINA' I SORTE 'PINOT CRNI'

OŽUJAK 2021. godine

Cilj ove ankete je prikupiti podatke vinogradara s područja Zagrebačke županije o uzgoju sorata 'Kraljevina' i 'Pinot crni'.

Anketa će obuhvatiti 10-ak profesionalnih vinogradara (koji stavljaju vlastito vino u promet) koji su različitih dobnih skupina, različite razine obrazovanja, različite su površine vinograda koje obrađuju te su različite cjenovne kategorije vina koje proizvode (može se pretpostaviti i da su različite cjenovne kategorije grožđa koje proizvode zbog manjeg prinosa, eko proizvodnje, više manjih proizvodnih površina, korištenja novih ili naprednijih tehnologija proizvodnje grožđa i sl.)

U ovom istraživanju fokus je na proizvođačima grožđa i vina sorata 'Kraljevina' i 'Pinot crni'. Prikupljaju se informacije vezano uz gospodarstvo, vinogradara, sortu u uzgoju, kvalitativnim podacima te tržišnim cijenama grožđa.

UPITNIK:

1. Upitnik se provodi sa:
    - Nositelj gospodarstva
    - Direktor
    - Upravitelj
    - Drugo _____
2. Spol
    - M
    - Ž
3. Pravni status gospodarstva:
    - OPG
    - OBRT
    - TVRTKA
    - ZADRUGA
    - Drugo _____
4. Vinogorje:
    - Vinogorje Voloder – Ivanić Grad
    - Vinogorje Dugo Selo – Vrbovec
    - Vinogorje Zelina
    - Vinogorje Samobor
    - Vinogorje Zaprešić

- Vinogorje Plešivica – Okić
- Vinogorje Sveta Jana
- Vinogorje Krašić
- Vinogorje Vukomeričke gorice

5. Ukupna površina vinograda_____(ha)
6. Ukupna površina sorte 'Kraljevina'/'Pinot crni':
   _____/ površina _____(ha)
7. Odvajate li grožđe prema kvalitativnim parametrima šećera i kiselina?
   - Da
   - Ne
8. Ukupan prinos sorte 'Kraljevina'/'Pinot crni' u 2019. i 2020. godini (kg)?
   - 2019:
   - 2020:
9. Prosječan sadržaj šećera (°Oe) i kiselina (g/l) u 2019. i 2020. godini?

Godina	šećera (°Oe)	kiselina (g/l)
2019.		
2020.		

10. Otkupne cijene grožđa sorte 'Kraljevina'/'Pinot crni' u razdoblju od 2011. -2020. godine:

Godina	Prosječna otkupna cijena grožđa (kn/kg)
2011.	
2012.	
2013.	
2014.	
2015.	
2016.	
2017.	
2018.	
2019.	
2020.	