PCA analiza utjecaja vremenskih prilika na agronomska svojstva pšenice

Lukačević, Ivan Ante

Master's thesis / Diplomski rad

2018

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:151:694259

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**

Sveučilište Josipa Jurja Strossmayera u Osijeku
Fakultet agrobiotehničkih znanosti Osijek

Repository / Repozitorij:

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

zir.nsk.hr

Image not found or type unknown

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA

FAKULTET AGROBIOTEHNIČKIH ZNANOSTI OSIJEK

Ivan-Ante Lukačević, apsolvent

Diplomski studij Bilinogojstvo

Smjer Oplemenjivanje bilja i sjemenarstvo

PCA ANALIZA UTJECAJA VREMENSKIH PRILIKA NA AGRONOMSKA SVOJSTVA PŠENICE

Diplomski rad

Osijek, 2018.

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA

FAKULTET AGROBIOTEHNIČKIH ZNANOSTI OSIJEK

Ivan-Ante Lukačević, apsolvent

Diplomski studij Bilinogojstvo

Smjer Oplemenjivanje bilja i sjemenarstvo

PCA ANALIZA UTJECAJA VREMENSKIH PRILIKA NA AGRONOMSKA SVOJSTVA PŠENICE

Diplomski rad

Povjerenstvo za ocjenu i obranu diplomskog rada:

1. izv. prof. dr. sc. Andrijana Rebekić, predsjednik

2. izv. prof. dr. sc. Sonja Petrović, mentor

3. prof. dr. sc. Sonja Vila, član

Osijek, 2018.

SADRŽAJ:

1. UVOD 1

1.1. Cilj istraživanja 2

2. PREGLED LITERATURE 3

2.1. Interakcija genotipa i okoline 4

2.2. Analiza glavnih komponenata (eng. Principal component analysis-PCA) 6

2.2.1. Primjena PCA 7

2.2.2. PCA u poljoprivrednim istraživanjima 8

3. MATERIJALI I METODE 10

3.1. Biljni materijal i poljski pokus 10

3.2. Klimatski uvjeti 14

3.3. Statistička obrada podataka 17

3.3.1. Opisna statistika 17

3.3.2. PCA agronomskih svojstava 17

4. REZULTATI 18

4.1. Rezultati opisne statistike agronomskih svojstava 18

4.1.1. Rezultati opisne statistike visine biljke 18

4.1.2. Rezultati opisne statistike broja dana do klasanja 19

4.1.3. Rezultati opisne statistike prinosa 21

4.2. Rezultati PCA 22

4.2.1. Rezultati PCA 2013./2014. 22

4.2.2. Rezultati PCA 2014./2015. 25

4.2.3. Rezultati PCA razlika agronomskih svojstava u dvije godine pokusa 28

5. RASPRAVA 30

6. ZAKLJUČAK 34

7. LITERATURA 35

8. SAŽETAK 40

9. SUMMARY 41

10. POPIS TABLICA 42

11. POPIS GRAFIKONA 44

TEMELJNA DOKUMENTACIJSKA KARTICA 45

BASIC DOCUMENTATION CARD 46

1. UVOD

Zrno pšenice (*Triticum spp*.) je vrlo važna namirnica u prehrambenoj industriji jer kruh, tijesto, ulje, pivo i druge prerađevine u ishrani svakodnevno koristi više od polovine svjetskog stanovništva. Osim u prehrambenoj industriji pšenica se koristi u farmaceutskoj te papirnoj industriji, kao i za ishranu stoke no u znatno manjoj mjeri. Razlikujemo ozime i jare vrste pšenice pogodne za uvjete uzgoja u gotovo svim dijelovima svijeta (Martinčić i Kozumplik, 1996.). Prema FAO podatcima iz 2016. godine pšenica se u cijelom svijetu uzgajala na ukupno 220.107.551 ha sa prinosom od 749.460.077 tona. U Europi je na 62.519.609 ha požnjeveno 250.126.499 tona. Trećina ukupne svjetske proizvodnje pšenice odvija se u Europi te je ona glavna ratarska kultura na tom području.

Osnovni preduvjet za stvaranje novih kultivara primjenom metoda selekcije je genetska varijabilnost roditeljskog biljnog materijala. Oplemenjivači se u svome radu za poboljšavanje svojstava novih kultivara koriste prirodnim izvorima varijabilnosti ili izvorima stvorenim hibridizacijom, induciranim mutacijama te drugim biotehnološkim metodama. Pod prirodne izvore varijabilnosti spadaju prirodne populacije i divlji srodnici kultiviranih vrsta pšenice. Introdukcija je također jedna od metoda kojom se oplemenjivači koriste za povećanje genetske varijabilnosti, a podrazumijeva prijenos bilja jednog uzgojnog područja u drugo. Oplemenjivačke tvrtke genetsku raznolikost mogu povećati razmjenom genetskog materijala s drugim tvrtkama i oplemenjivačima te u gen-bankama unutar svoje zemlje ili inozemstvu (Borojević S., 1981.; Borojević K., 1986.; Bede i Petrović, 2006.).

Ispitivanje genetske raznolikosti temelj je svakog oplemenjivačkog projekta. Može mu se pristupiti s razine biokemije ispitivanjem fizioloških i biokemijskih procesa ili s molekularne razine upotrebom molekularnih markera. Genotip svakog kultivara je pod izrazitim utjecajem okoline. Ispitivanje i mjerenje različitih agronomskih svojstava u umjetno stvorenim ili prirodnim uvjetima uzgoja predstavlja oblik utvrđivanja genetske raznolikosti prema fenotipu. Poljoprivredni su pokusi u različitim prirodnim uvjetima, tijekom više godina najbolji pokazatelj realne performanse pšenice i drugih vrsta kultiviranog bilja.

Statističke analize neophodan su korak pri ispitivanjima agronomskih svojstava. Primjenom statističkih metoda dobivamo uvid u zakonitosti veze ispitivanih svojstava, kultivara i čimbenika koji utječu na razvoj biljaka. Velik broj agronomskih svojstava i

njihova međusobna povezanost čine statističke analize izrazito kompleksnima osobito ako se istraživanje provodi na velikom uzorku. Metode multivarijatne analize kao što je analiza glavnih komponenata (eng. Principal component analysis – PCA) uvelike pomažu u sažimanju samih podataka te isticanju svojstava koja najviše utječu na varijabilnost uzorka (Horvat i sur., 2005; Pecina, 2006.).

1.1. Cilj istraživanja

Cilj ovog istraživanja bio je ispitati utjecaj vremenskih prilika na agronomska svojstva pšenice te grupiranje kultivara s obzirom na promjenu vrijednosti agronomskog svojstva između dvije godine pokusa.

2. PREGLED LITERATURE

Poljoprivredni se pokusi koriste za prikupljanje unaprijed određenih podataka o svojstvima pokusnih jedinica. Podatci se potom obrađuju i statistički analiziraju kako bi se omogućilo jasnije razlikovanje između tretmana i pokusnih članova te odabiranje najboljih vrijednosti iz skupa. Horvat i Ivezić (2005.) navode kako je kod ispitivanja agronomskih svojstava poljoprivrednih kultura moguće primijeniti laboratorijske ili plasteničke pokuse. Većina je uvjeta koji se ne ispituju kontrolirana, dok se uvjeti koji se odnose na cilj istraživanja mijenjaju u ponavljanjima (npr. količina vode, svijetla, gnojiva, itd.). Poljski su pokusi ipak najbolji pokazatelj adaptabilnosti i općenito performanse ispitivanih kultivara, jer su izloženi skupu prirodnih, nekontroliranih uvjeta područja na kojem je smještena pokusna parcela. Izvori varijacija u poljskim pokusima mogu potjecati iz samih tretmana, razlika u ponavljanjima, ali i iz pokusne pogreške. Pogreška pokusa se dobrim planiranjem i provedbom pokusa pokušava svesti na što manju razinu kako ne bi utjecala na rezultate. Pokusna parcela treba biti što ujednačenija za sve pokusne jedinice, pa je stoga nužna kvalitetna provedba agrotehnike, gnojidbe i zaštite za vrijeme pripreme i održavanja pokusa. Nekolicina autora (Jugo i Bogdan, 1957.; Kaya i sur., 2006.) u svojim radovima ističu kako su istraživački poljoprivredni pokusi izrazito lokalne prirode zbog promjenjivosti abiotskih i biotskih čimbenika na različitim lokacijama. Okolina utječe na izraženost nekog agronomskog svojstva, odnosno rezultati poljoprivrednih pokusa nekog područja mogu biti točni samo za tu regiju. Ispitivanje agronomskih svojstava poljoprivrednih kultura kroz poljske pokuse vrlo je složen proces, kako navodi Bondari (2003.), upravo zbog razlika između uzgojnih površina i klimatskih uvjeta u različitim godinama uzgoja. Genetski potencijal nekog kultivara predstavlja njegov prinos zrna u optimalnim uvjetima. Na polju se vrlo rijetko ostvaruju optimalni uvjeti te se stoga rezultati o realnom prinosu kultivara dobivaju primjenom pokusa kombiniranih u vremenu i prostoru promjenom okoline uzgoja.

Klimu nekog područja Šegota i Filipčić (1996.) definiraju kao prosječno stanje atmosfere kroz niz godina uzimajući u obzir prosječne i ekstremne vrijednosti odstupanja od prosjeka. Na klimu nekog područja uvelike utječe lokacija koja je određena geografskom širinom i dužinom, nadmorskom visinom, udaljenošću od mora i reljefom. Svaki je teren specifičan zbog različitog intenziteta klimatskih elemenata kao što su temperatura, oborine, tlak zraka, radijacija i sl. Klimatske promjene možemo podijeliti na periodične koje se redovno ponavljaju na godišnjoj ili dnevnoj bazi te na neperiodične, koje su uzrokovane

djelovanjem različitih zračnih masa, a očituju se kao količina oborina, vjetra i sl. Isti autori (Šegota i Filipčić, 2003.) u svom kasnijem radu, prema Köppenovoj klasifikaciji, Nizinsku Hrvatsku svrstavaju u umjereno toplu vlažnu klimu s toplim ljetima (Cfb). Cfb klimu karakterizira povoljan godišnji hod oborina, te povoljne temperature za uzgoj većeg broja poljoprivrednih kultura. Uspoređujući podatke iz razdoblja 1931.-1960. s onima iz razdoblja 1961.-1990., Filipčić (1998.) ukazuje na pomicanje granica određenih podtipova klime na području Republike Hrvatske. U kasnijem razdoblju istraživanja nisu zabilježena dva podtipa koja su karakterizirala svježa ljeta (Cfc, Csc).

2.1. Interakcija genotipa i okoline

Martinčić i Kozumplik (1996.) te Araus i sur. (2008.) definiraju prinos kultivara kao vrlo kompleksno kvantitativno svojstvo jer ga kontroliraju brojni minor geni koji su pod velikim utjecajem okolnih čimbenika. Broj klasova na jedinici površine, broj zrna po klasu i prosječna masa zrna su komponente kojima je određen prinos pšenice. Navedene komponente međusobno su u negativnom korelacijskom odnosu. U posljednje vrijeme sve su češće pojave suše koja je ograničavajući čimbenik u postizanju visokih prinosa. Oplemenjivači uz prinos moraju voditi računa o svojstvima koja razvijaju otpornosti na abiotske i biotske oblike stresa. Upravo u tome se očituje složenost oplemenjivanja na poboljšanje prinosa pšenice i drugih žitarica.

Adaptabilnost nekog kultivara je mogućnost postizanja stalnih i ekonomski prihvatljivih prinosa u različitim uvjetima sredine u kojoj se nalazi. U pšenice je često uvjetovana prisutnošću i međudjelovanjem *Rht (Reduced height genes)* gena za nisku stabljiku, *Vrn (Vernalisation genes)* gena za jarovizaciju i *Ppd (Photoperiod response genes)* gena za fotoperiodizam unutar genoma kultivara (Borojević, 1981.).

Poljske pokuse s ciljem dokazivanja utjecaja viših noćnih temperatura na prinos zrna i biomase pšenice i ječma u Buenos Airesu, proveli su Garcia i sur. (2015.). Pšenica i ječam sijani su u kasnim sjetvenim rokovima 2011., te u ranim rokovima 2013. godine. Svi su tretmani bili izloženi prirodnim noćnim i za 4^{o}C višim temperaturama u grijanim prostorima, u vremenu između IV. etape, kada se počinju formirati klasići u klasu, i X. etape organogeneze kada započinje formiranje zrna. Obje vrste su pokazale ubrzan metabolizam pri višim temperaturama. Utjecaj viših temperatura očitovao se odumiranjem bočnih vlati i smanjenjem biomase, kao i manjim brojem fertilnih klasića što je uzrokovalo mali broj zrna po klasu. Gubitke prinosa pri višim noćnim temperaturama u kritičnom

periodu razvoja klasa pšenice i ječma autori su pripisali smanjenoj asimilaciji ugljikovih atoma uslijed intenzivnije transpiracije biljaka noću.

Russel (2013.) ukazuje na negativnu korelaciju *Rht* gena kratke stabljike sa prinosom zrna. Kod patuljastih kultivara povećane su komponente prinosa kao broj zrna u klasu, te broj vlati na jedinici površine. Stabljika kultivara koje posjeduju *Rht* gene je kraća, a samim time kompaktnija, zbijenija i šireg promjera uspoređujući ju sa stabljikom kultivara normalne visine te je kao takva pogodne strukture za teži klas s više sjemenki. Kultivari pšenice niskog habitusa manje zasjenjuju jedna drugu u gustom sklopu čime je omogućen normalan razvoj većeg broja biljaka. Uz povećanje prinosa, otpornost na polijeganje je jedno od glavnih ciljeva oplemenjivača pšenice koji se postiže unošenjem *Rht* gena iz patuljastih kultivara.

Svoje istraživanje o utjecaju *Rht* gena na prinos kultivara pšenice Uddin i Marshall (1989.) proveli su na tri skupine biljaka grupiranih prema visini na patuljaste, polupatuljaste i visoke sorte. Pokusi su provedeni u tretmanima s prirodnim uvjetima opskrbljenosti vodom i uz navodnjavanje. Dobiveni rezultati ukazali su na manji broj dana do početka cvatnje visokih sorti u odnosu na polupatuljaste i patuljaste u oba režima. Patuljaste sorte pokazale su smanjenje broja fertilnih klasića te mase 1000 zrna za 15,4% u tretmanima bez navodnjavanja. To upućuje na osjetljivost patuljastih sorti na nedostatak vode za vrijeme vlatanja i klasanja kada se razvijaju cvjetni zametci i sam klas. Naprotiv, u uvjetima s povoljnim količinama vode, sorte najnižeg habitusa imale su najbolji prinos.

Tican (2004.) je proveo istraživanje o utjecaju patuljastih gena pšenice na komponente prinosa u semi-humidnim uvjetima Rumunjske. Istraživanje je uključivalo 104 rekombinante inbred linije (RIL -Recombinant Inbred Lines) dobivene križanjem kultivara Sincron koju karakterizira polupatuljasti rast, jako busanje, te duga koleoptila s visokoprinosnim polupatuljastim kultivarom F1054W. Cilj istraživanja bio je utvrditi kako *Rht*B1 i *Rht*8 geni utječu na prinos u optimalnim i kasnijim rokovima sjetve. Poljski pokusi provedeni su kroz tri vegetacijske godine, a uz prinos mjereni su i broj isklijalih biljaka po m^2, ukupan broj klasova po m^2, broj zrna u klasu, te visina biljke. Rezultati su pokazali da su RIL koje sadrže oba patuljasta gena, kao i one koje su nosile samo *Rht*8 gen imale najkraću stabljiku u sve tri godine u oba roka sjetve. Biljke koje su sadržavale samo *Rht*B1 gene su bile više od patuljastih, ali znatno niže od visokih sorti. U normalnim rokovima sjetve RIL s *Rht*8 genima imale su najmanji prinos, dok se u kasnijim sjetvenim rokovima

prinosi nisu statistički značajno razlikovali. Bitno je istaknuti kako su polupatuljasti kultivari s *Rht*B1b genima ostvarili najbolji prinos neovisno o roku sjetve unutar sve tri godine istraživanja.

Broj dana do klasanja kod pšenice uvjetovan je jarovizacijom gdje su biljke u svojim ranijim fazama razvoja izložene periodu niskih temperatura, kao i osjetljivošću biljke na dužinu dana, poznatu kao fotoperiodizam. Kumar i sur. (2012.) istražili su genetsku konstituciju odgovornu za početak cvatnje pšenice. Ispitali su interakcije dominantnog *Vrn*-1 gena koji omogućuje proljetni rast bez jarovizacije s mutiranim *Ppd*-D1a genom neosjetljivosti na fotoperiodizam. U istraživanje je uključeno 12 Indijskih kultivara jare pšenice, te prirodna populacija Chinese Spring. Kultivari su sijani svaki mjesec u trajanju od 5 godina kako bi dobili različite dužine dana u tretmanima i na temelju njih došli do zaključka koji kultivari cvatu najranije neovisno o dužini dana. Upotrebom funkcionalnih molekularnih markera za utvrđivanje prisutnosti *Vrn*-A1, *Vrn*-D1, *Vrn*-B1 i *Ppd*-D1 gena određene su genetske konstitucije kultivara. Rezultati petogodišnjeg poljskog pokusa i PCR analize genotipova ukazali su na epistatičan učinak *Vrn*-D1 prema *Vrn*-A1 genu u kultivarima koji nemaju *Vrn*-B1 gen. Kultivari genotipa *Vrn*-1 *Ppd*-D1a imali su najkraće vrijeme cvatnje u svim tretmanima te je na taj način potvrđen aditivan učinak između *Vrn*-1 i *Ppd*-D1a gena. U danima kraćim od 12 sati niske temperature odložile su početak cvatnje i usporili zriobe genotipova *Vrn*-1 *Ppd*-D1a. Za vrijeme dugih dana visoke su temperature ubrzale zriobu zrna što takve kultivare u kasnijim rokovima sjetve čini izuzetno ranozrelim. Do sličnih su zaključaka o interakciji ranije spominjanih gena došli Gomez i sur. (2014.) na temelju statistički obrađenih rezultata poljskih pokusa i genetske analize Argentinskih kultivara pšenice.

2.2. Analiza glavnih komponenata (eng. Principal component analysis-PCA)

Kod praćenja većeg broja svojstava zbog različitih interakcija i međuzavisnosti između njih nužna je primjena metoda multivarijatne analize (eng. Multivariate analysis-MVA). MVA podrazumijeva analizu velikog broja mjerenja i varijabli istovremeno. Primjenom matematičkih i statističkih metoda MVA dobivamo jasnu sliku o višestruko nezavisnim i zavisnim varijablama, te je omogućeno opisivanje njihovih međusobnih utjecaja i odnosa (Halmi, 2003.; Pecina, 2006.)

Jedna od metoda MVA je i analiza glavnih komponenata (eng. Principal component analysis-PCA) čiju primjenu osim u poljoprivrednim istraživanjima pronalazimo u brojnim

granama suvremene znanosti. Lever i sur. (2017.) definiraju PCA kao metodu koja smanjuje kompleksnost ispitivanja većeg broja svojstava stvaranjem manjeg broja novih linearnih kombinacija početnih varijabli, odnosno glavnih komponenti (eng. Principal component-PC). PCA se najčešće koristi u svrhu sažimanja podataka te bolje i jasnije interpretacije rezultata.

Nekolicina autora (Pecina, 2006.; Jolliffe, 2002.; Johnson i Wichern, 2007.; Halmi, 1999.) napominje kako temelj za provedbu PCA, kao i ostalih metoda MVA čini primjena računa unutar matrice korelacija ili kovarijanci izvornih varijabli. Na taj se način mogu objasniti i razumjeti odnosi međuzavisnosti i utjecaja između velikog broja svojstava. Za PCA analizu neophodna je normalna raspodjela uzorka. Svojstveni vektori (eng. eigenvectors) dobivaju se iz matrice korelacija svojstava, a služe za izvođenje glavnih komponenata koje predstavljaju koordinatne osi u grafičkom prikazu transformiranih podataka. Možemo reći kako su svojstveni vektori sinusi i kosinusi kutova osi novo formiranog koordinatnog sustava. Ukupna varijanca ispitivanih varijabli jednaka je u izvornim podatcima i kod transformiranja u glavne komponente. Dio ukupne varijance koja je obuhvaćena pojedinom glavnom komponentom naziva se latentni korijen (eng. eigenvalue), a prvu glavnu komponentu predstavlja ona čiji latentni korijen opisuje najveći udio ukupne varijance.

Jolliffe (2002.) ističe kako je za dobru PCA potrebna jaka pozitivna ili negativna korelacija izvornih varijabli. Transformirane u glavne komponente, varijable nisu u međusobnim korelacijskim odnosima zbog čega se prikazuju ortogonalno jedna na drugu. Ukupna varijanca izvornih varijabli sadržana je u glavnim komponentama, a u većini slučajeva prvih nekoliko glavnih komponenti sadrži većinski udio ukupne varijance izvornih varijabli. Iz tog je razloga dovoljno odabrati 2 ili 3 komponente, a zanemariti ostale kako bi multidimenzionalni prikaz saželi u jednostavniji oblik bez velikog gubitka podataka. Prva glavna komponenta obuhvaća najveći dio ukupne varijance, dok svaka iduća komponenta predstavlja najveći preostali udio.

2.2.1. Primjena PCA

Analiza glavnih komponenata jedna je od pouzdanih multivarijatnih analitičkih metoda koja se koristi u istraživanjima gdje određene varijable promatrane pojedinačno ne pružaju dovoljno informacija za kvalitetan znanstveni zaključak. PCA se najčešće koristi za razne klasifikacije ili karakterizacije promatranih pojava, te sažimanje većeg broja varijabli u

nekolicinu. Njezinu primjenu možemo pronaći u raznim granama znanosti kao što su medicina, farmacija, geografija, oceanografija, meteorologija, poljoprivreda, sociologija, psihologija i mnoge druge.

Zbog velikog broja pacijenata i različitih simptoma istih bolesti Barber i sur. (1975.) primjenjuju PCA kako bi lakše sistematizirali podatke o bolesnicima. Na taj su način poboljšali učinak dijagnostike raka, povećali razumijevanje o metabolizmu kalcija u organizmu te funkcionalnosti želuca nakon operativnih zahvata. Kumar (2015.) koristi PCA u medicinskom istraživanju podataka o svojstvima povezanih s dijabetesom tipa 2 radi svrstavanja i lakšeg pretraživanja profila pacijenata prema simptomima. Široku primjenu PCA u procesuiranju i klasifikaciji rendgenskih i ultrazvučnih fotografija opisuju Ashour i sur. (2015.) u svom radu. Oni navode kako ovakva vrsta analize može biti temelj za fuziju, registraciju, segmentaciju, te kompresiju rendgenskih i ultrazvučnih slika nalaza. Vidhyavathi (2017.) je primijenila PCA na rendgenskim snimkama pacijenata radi lakšeg uočavanja uzoraka i za otklanjanje „šumova“ (eng. noise) iz slika.

Integracijom metoda Geografskog Informacijskog Sustava (eng. Geographical Information System-GIS) i PCA Pertisor i sur. (2012.) su analizirali tri veće regije Rumunjske kako bi došli do rezultata o najkritičnijim mjestima u tim regijama s gledišta razvijenosti. Analiza je uključivala 30 različitih čimbenika razvijenosti, pa je PCA izvrsno poslužila za redukciju podataka te isticanje najbitnijih čimbenika.

Preisendorfer (1988.) u svojoj knjizi detaljno razrađuje računski dio PCA koji se koristi u meteorologiji i oceanografiji za predviđanje i razumijevanje različitih pojava.

U svrhu klasifikacije i karakterizacije osam vrsta meda sa područja Republike Hrvatske, Šarić i sur. (2008.) obavili su PCA analizu na temelju njihovih fiziokemijskih profila. Na temelju rezultata zaključili su kako je primjena ove metode pogodna za klasifikaciju meda prema biološkom porijeklu zbog jasno predočenih razlika u samom sastavu i fiziokemijskim svojstvima.

2.2.2. PCA u poljoprivrednim istraživanjima

Skupina je autora Mirosavljević i sur. (2015.) primijenila PCA kako bi došli do zaključaka o povezanosti prinosa zrna s nekoliko agronomskih svojstava ozimog ječma (*Hordeum vulgare* L.). Pokusi su provedeni na Institutu za ratarstvo i povrtlarstvo u Novom Sadu kroz tri vegetacijske godine (2009./2010., 2010./2011., 2011./2012.). Svojstva čiji se

utjecaj na prinos zrna pratio bila su: visina biljke, postotak polijeganja, masa tisuću zrna, hektolitarska masa i sadržaj proteina u zrnu. Na temelju rezultata potvrdili su kako je prinos pozitivno koreliran s masom tisuću zrna i hektolitarskom masom, a negativno sa postotkom polijeganja i sadržajem proteina u zrnu. U ovom istraživanju prinos i visina biljke nisu pokazali korelaciju. Zarei i sur. (2013.) proveli su istraživanje na kultivarima durum pšenice (*Triticum turgidum* L.) kultivirane u poljskim uvjetima s periodima suše. Cilj istraživanja bio je istaknuti agronomska i morfološka svojstva povezana s prinosom u takvoj okolini. PCA analiza ukazala je na visoku povezanost prinosa zrna s količinom biomase, te brojem vlati i klasova po biljci. Ovakav tip analize daje oplemenjivaču uvid u svojstva koja može odabirati uz prinos kako bi stvorio kultivare otporne na takav tip stresa. Korelaciju prinosa s agronomskim svojstvima na temelju PCA analizirao je i Fahim (2014.). Poljski pokus iz 2013. godine uključivao je 57 kultivara krušne pšenice (*Triticum aestivum* L.). Uz prinos zrna zabilježeni su podatci o visinama biljaka, broju dana do klasanja i broju dana do fiziološke zriobe sjemena. Analizom je potvrđena pozitivna korelacija između prinosa i broja dana do klasanja. Upravo su ta dva svojstva pridonijela najvećem dijelu varijance koja je obuhvaćena prvom glavnom komponentom, a njezin latentni korijen opisuje oko 40% ukupne varijabilnosti. Kod formiranja druge glavne komponente najveći utjecaj imala je visina biljke te je ona obuhvaćala 24% ukupne varijance.

Skupina autora (Panishkan i sur., 2012.) na temelju PCA karakterizira vrste tla čiji su uzorci uzeti s različitih poljoprivrednih regija zapadnog Tajlanda. Za analizu su korištena svojstva tla kao količina organske tvari, ukupni udio dušika, kationski izmjenjivi kapacitet, gustoća mase, postotak mulja i postotak gline. Prve dvije glavne komponente obuhvatile su 72,24% ukupne varijabilnosti uzoraka. PCA se pokazala kao pouzdana metoda za pronalaženje povezanosti različitih regija i za isticanje odnosa između samih svojstava tla. Koch i sur. (2008.) također na temelju PCA analize šumskog tla zaključuju kako su upravo svojstva koja su koristili Panishkan i sur. (2012.) imala najviše utjecaja pri klasifikaciji njihovih uzoraka.

3. MATERIJALI I METODE

3.1. Biljni materijal i poljski pokus

U analizu je uključeno 40 kultivara ozime pšenice (*Triticum aestivum* L.) i njihove ostvarene vrijednosti prinosa, visine biljke i broja dana do klasanja kroz dvije pokusne godine (2013./2014. i 2014./2015.). Podaci su preuzeti iz baze podataka projekta na Katedri za genetiku, oplemenjivanje bilja i sjemenarstvo Fakulteta Agrobiotehničkih Znanosti u Osijeku. Odabir kultivara je obavljen je prema porijeklu, četiri zemlje porijekla i to iz Hrvatske (CRO), Austrije (AUT), Mađarske (HUN) i Francuske (FRA), pri čemu je iz svake zemlje odabrano po deset kultivara. Popis kultivara kao i ostvarene vrijednosti navedenih svojstava u obje sezone prikazane u Tablicama 1a i 1b.

Tablica 1a. Popis i vrijednosti agronomskih svojstava hrvatskih i austrijskih kultivara ostvarenih u obje godine pokusa

R. br	Kultivar	Zemlja porijekla	Visina biljke (cm)		Broj dana do klasanja		Prinos (t/ha)	
			'13./'14.	'14./'15.	'13./'14.	'14./'15.	'13./'14.	'14./'15.
1.	U1	CRO	136,28	127,28	129	133	3,03	4,33
2.	SIRBAN PROLIFIK	CRO	145,16	126,04	129	133	3,09	5,29
3.	DIVANA	CRO	115,08	103,44	113	129	3,38	6,65
4.	OSJEČKA 20	CRO	86,76	77,08	115	126	5,69	7,35
5.	BC PATRIA	CRO	100,2	86,64	114	127	5,34	7,46
6.	ILIRIJA	CRO	104,16	103,36	122	131	5,59	9,04
7.	FELIX	CRO	85,12	78,88	112	122	5,96	9,12
8.	PANONIJA	CRO	90,84	78,08	117	127	5,35	9,17
9.	SRPANJKA	CRO	73,4	62	110	121	6,13	9,43
10.	ANĐELKA	CRO	78,08	70,2	115	125	6,32	9,48
11.	ACHAT	AUT	111	108,48	138	137	4,36	6,61
12.	BELMONDO	AUT	113,16	109,88	128	132	5,44	3,88
13.	CAPO	AUT	117,04	116,12	130	134	4,04	7,84
14.	CORNELIUS	AUT	109,44	110,88	127	132	6,16	9,33
15.	EUROJET	AUT	118,36	112,2	138	142	4,91	7,89
16.	EXCELICIOR	AUT	97,12	87,12	117	128	8,65	9,83
17.	INDIGO	AUT	102,72	104,92	129	133	4,11	5,34
18.	JUSTUS	AUT	112,68	110,08	127	133	5,19	8,97
19.	SOISSANA	AUT	104,88	96,32	131	129	5,35	9,54
20.	SW KRONJET	AUT	118,88	106,88	126	131	3,99	10,20

Tablica 1b. Popis i vrijednosti agronomskih svojstava mađarskih i francuskih kultivara ostvarenih u obje godine pokusa

R. br	Kultivar	Zemlja porijekla	Visina biljke (cm)		Broj dana do klasanja		Prinos (t/ha)	
			'13./'14.	'14./'15.	'13./'14.	'13./'14.	'14./'15.	'13./'14.
21.	MV EMESE	HUN	103,6	83,8	116	128	4,84	7,77
22.	MV SUBA	HUN	105,2	91,2	129	133	5,48	7,85
23.	MV MAMBÓ	HUN	100,56	88,44	116	128	4,07	7,97
24.	MV ZELMA	HUN	98,68	93,2	131	135	6,37	7,99
25.	MV PANNA	HUN	109,76	98,72	116	128	5,80	8,31
26.	MV KEMENCE	HUN	97,56	90,64	118	130	7,07	9,28
27.	MV OPTIMA	HUN	102,6	99,52	125	132	3,65	9,31
28.	MV AMANDA	HUN	101,12	80,56	117	129	4,73	9,40
29.	MV MAGDALÉNA	HUN	101,36	107,56	126	133	4,29	9,51
30.	MV MAZURKA	HUN	100,92	92,44	130	135	4,50	13,44
31.	CAPELLE DESPREZ	FRA	113,92	115,28	138	133	3,49	5,23
32.	GOELENT	FRA	95,8	100,12	117	130	5,58	7,72
33.	AUBUSSON	FRA	92,2	82,48	132	130	7,79	8,31
34.	ENESCO	FRA	89,72	73,28	116	128	5,87	8,35
35.	RENAN	FRA	100,32	96,64	127	133	5,17	8,62
36.	SOISSONS	FRA	91,6	82,52	118	130	7,45	9,63
37.	EXOTIC	FRA	91,56	79,2	117	128	7,82	9,70
38.	ISNEGRAIN	FRA	91,48	86,84	119	132	6,75	9,81
39.	PREMIO	FRA	88,44	77,24	122	133	8,53	9,97
40.	BASTIDE	FRA	93,6	79,26	118	140	8,40	10,12

Poljski su pokusi sijani kroz dvije vegetacijske godine, 2013./2014. u Nemetinu i 2014./2015. u Sarvašu na pokusnim parcelama Hrvatskog centra za poljoprivredu, hranu i selo, Zavoda za sjemenarstvo i rasadničarstvo. Pokusi su bili dio Uspostavnog istraživačkoga projekta PHENOWHEAT (no.2000) koji je financirala Hrvatska zaklada za znanost. U pokuse je uključeno ukupno 365 kultivara pšenice porijeklom s pet kontinenata koji su odabrani prema zastupljenosti u proizvodnji i godini priznavanja. Parcelice površine 6,25 m^2 su međusobno odvojene razmakom od 20 cm i raspoređene u pokusni plan bez ponavljanja. Za potrebe ovog istraživanja preuzeti su podatci mjerenja tri agronomska svojstva tijekom vegetacije. Visina biljke (cm) mjerena je nakon klasanja na 25 nasumično odabranih biljaka po parceli. Broj dana do klasanja predstavlja broj dana od

1. siječnja do početka klasanja biljaka na parceli. Prinos zrna po parceli (kg) izvagan je odmah nakon žetve te je preračunat u t/ha i na vlažnost zrna od 13% .

Razlike u postignutim vrijednostima agronomskih svojstava u različitim okolinama daju jasan uvid u sposobnost prilagodbe kultivara, kao i u otpornost na razne tipove stresnih uvjeta. Tablice 2a i 2b prikazuju razlike između ispitivanih agronomskih svojstava u dvije godine pokusa.

Tablica 2a. Razlike agronomskih svojstava hrvatskih i austrijskih kultivara u pokusnim godinama 2013./2014. i 2014./2015.

R.br.	Kultivar	Zemlja porijekla	Razlike u visini biljke (cm)	Razlike u prinosu (t/ha)	Razlike u broju dana do klasanja
1.	U1	CRO	9,00	1,30	4
2.	SIRBAN PROLIFIK	CRO	19,12	2,19	4
3.	DIVANA	CRO	11,64	3,27	16
4.	OSJEČKA 20	CRO	9,68	1,65	11
5.	BC PATRIA	CRO	13,56	2,12	13
6.	ILIRIJA	CRO	0,80	3,45	9
7.	FELIX	CRO	6,24	3,16	10
8.	PANONIJA	CRO	12,76	3,82	10
9.	SRPANJKA	CRO	11,40	3,29	11
10.	ANĐELKA	CRO	7,88	3,15	10
11.	ACHAT	AUT	2,52	2,25	1
12.	BELMONDO	AUT	3,28	1,56	4
13.	CAPO	AUT	0,92	3,79	4
14.	CORNELIUS	AUT	1,44	3,17	5
15.	EUROJET	AUT	6,16	2,98	4
16.	EXCELICIOR	AUT	10,00	1,18	11
17.	INDIGO	AUT	2,20	1,22	4
18.	JUSTUS	AUT	2,60	3,78	6
19.	SOISSANA	AUT	8,56	4,19	2
20.	SW KRONJET	AUT	12,00	6,20	5

Tablica 2b. Razlike agronomskih svojstava mađarskih i francuskih kultivara u pokusnim godinama 2013./2014. i 2014./2015.

R.br.	Kultivar	Zemlja porijekla	Razlike u visini biljke (cm)	Razlike u prinosu (t/ha)	Razlike u broju dana do klasanja
21.	MV EMESE	HUN	19,80	2,93	12
22.	MV SUBA	HUN	14,00	2,36	4
23.	MV MAMBÓ	HUN	12,12	3,89	12
24.	MV ZELMA	HUN	5,48	1,61	4
25.	MV PANNA	HUN	11,04	2,51	12
26.	MV KEMENCE	HUN	6,92	2,21	12
27.	MV OPTIMA	HUN	3,08	5,66	7
28.	MV AMANDA	HUN	20,56	4,66	12
29.	MV MAGDALÉNA	HUN	6,20	5,21	7
30.	MV MAZURKA	HUN	8,48	8,93	5
31.	CAPELLE DESPREZ	FRA	1,36	1,73	5
32.	GOELENT	FRA	4,32	2,14	13
33.	AUBUSSON	FRA	9,72	0,52	2
34.	ENESCO	FRA	16,44	2,47	12
35.	RENAN	FRA	3,68	3,45	6
36.	SOISSONS	FRA	9,08	2,17	12
37.	EXOTIC	FRA	12,36	1,88	11
38.	ISNEGRAIN	FRA	4,64	3,05	13
39.	PREMIO	FRA	11,20	1,43	11
40.	BASTIDE	FRA	14,33	1,71	22

3.2. Klimatski uvjeti

Podaci o mjesečnoj količini oborina i prosječnim temperaturama zraka u razdoblju od rujna 2013. do srpnja 2015. preuzeti su od Državnog hidrometeorološkog zavoda. Prikazani su u Tablici 3 za 2013./2014. te u Tablici 4 za 2014./2015. pokusnu godinu gdje se radi usporedbe nalaze i vrijednosti višegodišnjih prosjeka (1961.-1990.) temperatura i količine padalina.

Tablica 3. Srednje mjesečne temperature zraka (°C) i mjesečna količina oborina (mm) za prvu godinu pokusa (2013./2014.) i višegodišnji prosjek (1961.-1990.)

	Srednja mjesečna temperatura zraka u °C		Količina oborina po mjesecima u mm	
	Prosjek	1961.-1990.	Prosjek	1961.-1990.
Rujan 2013.	15,9	16,6	123,7	51,8
Listopad 2013.	13,7	11,2	52,3	48,3
Studeni 2013.	7,8	5,4	63,8	60,7
Prosinac 2013.	1,6	0,9	0,0	54,4
Siječanj 2014.	3,7	-1,2	36,0	45,2
Veljača 2014.	5,6	1,6	48,0	37,8
Ožujak 2014.	9,5	6,1	39,4	42,2
Travanj 2014.	13,2	11,3	81,3	54,1
Svibanj 2014.	16,1	16,5	161,4	58,9
Lipanj 2014.	20,5	19,4	91	83,5
Srpanj 2014.	21,9	21,1	66,4	66,6

U prvoj godini pokusa prosječne mjesečne temperature u 2013. godini bile su više za 2,5°C u listopadu i studenom, dok su temperature u prosincu bile slične višegodišnjem prosjeku. Siječanj 2014. obilježile su temperature za 5°C više od prosječnih, a naredni vremenski period od veljače do travnja iste godine prate temperature više za 4 do 2°C. Zadnja tri mjeseca u vegetaciji pšenice nisu se znatno razlikovale od višegodišnjeg prosjeka u prvoj godini pokusa.

Količina oborina u rujnu 2013. za vrijeme sjetve pšenice bila je dvostruko veća u usporedbi sa višegodišnjim prosjekom što je u polju stvorilo nepovoljne uvjete i odgodilo

rokove sjetve. Naredna dva mjeseca pala je normalna količina oborina za to područje. U prosincu pak uopće nije bilo padalina, što je mladu pšenicu u fazi nicanja i ukorjenjivanja uz prosječnu temperaturu od 1,6°C ostavilo bez izolacijskog sloja snježnog pokrivača te loše utjecalo na njezin početni razvoj. Prva tri mjeseca 2014. godine po pitanju padalina bile su slične prosječnim, dok je u travnju palo 27,2 mm, a u svibnju čak 102,5 mm više uspoređujući s višegodišnjim prosjekom. Lipanj i srpanj se po pitanju oborina nisu znatno razlikovali od višegodišnjeg prosjeka.

Povećana vlaga u travnju i svibnju 2014. godine uz temperature od 20°C i više su, kako navode Radan i sur. (2014.), idealni uvjeti za razvoj smeđe lisne (*Puccinia recondita*) i žute hrđe (*Puccinia striiformis*). Zaraza navedenim bolestima se te godine mogla vidjeti na poljima širom Slavonije, a tako i na pokusnim parcelama. Znatno topliji zimski mjeseci 2014. godine pogodovali su razvoju smeđe pjegavosti lista (*Septoria tritici*) na osjetljivim kultivarima. Simptomi navedenih bolesti su nekrotične površine na listu uzrokovane širenjem micelija kroz tkivo što zbog značajnog smanjenja asimilacijske površine negativno utječe na komponente prinosa.

Tablica 4. Srednje mjesečne temperature zraka (°C) i mjesečna količina oborina (mm) za drugu godinu pokusa (2014./2015.) i višegodišnji prosjek (1961.-1990.)

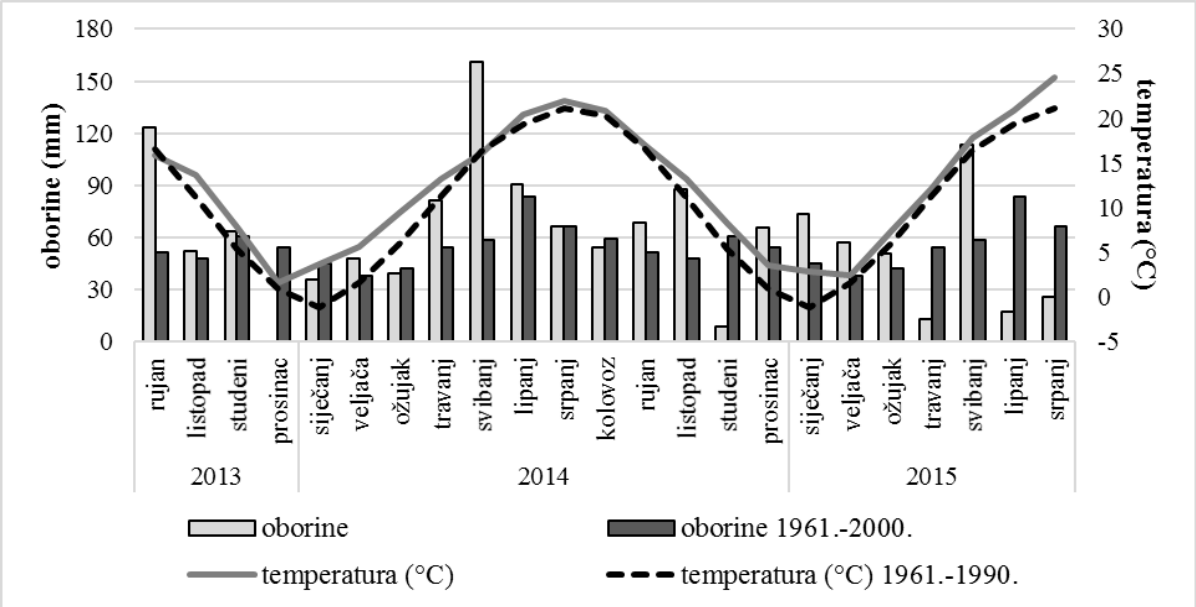
	Srednja mjesečna temperatura zraka u °C		Količina oborina po mjesecima u mm	
	Prosjek	1961.-1990.	Prosjek	1961.-1990.
Rujan 2014.	17,0	16,6	68,9	51,8
Listopad 2014.	13,3	11,2	87,9	48,3
Studeni 2014.	8,3	5,4	8,8	60,7
Prosinac 2014.	3,5	0,9	66,0	54,4
Siječanj 2015.	2,9	-1,2	73,7	45,2
Veljača 2015.	2,5	1,6	57,1	37,8
Ožujak 2015.	7,5	6,1	50,5	42,2
Travanj 2015.	12,1	11,3	12,9	54,1
Svibanj 2015.	17,8	16,5	113,4	58,9
Lipanj 2015.	20,8	19,4	17,1	83,5
Srpanj 2015.	24,6	21,1	25,6	66,6

Studeni i prosinac 2014. te siječanj 2015. godine u usporedbi s višegodišnjim prosjekom imali su više temperature za 3 do 4 °C. Vrijednosti u ostalim mjesecima druge pokusne godine bile veće za 1 °C od višegodišnjeg prosjeka, a značajno veće temperature zraka ostvarene su u srpnju 2015. godine.

U drugoj godini pokusa veća količina kiše u odnosu na višegodišnji prosjek zabilježena je u rujnu i listopadu 2014., nakon čega slijedi značajan nedostatak oborina u studenom. Početak 2015. godine imao je nešto veću količinu padalina od prosjeka, dok u travnju nastupa period sa manje od 15 mm kiše. U svibnju je palo 113,4 mm oborina što je dvostruko više od prosjeka. Znatno veća količina oborina u mjesecu svibnju za vrijeme vlatanja pšenice može biti uzrok odlaganja početka klasanja, kako navodi Petrović (2011.). Lipanj i srpanj obilježila je znatno manja količina oborina.

Količina oborina u travnju i svibnju za vrijeme vlatanja pšenice u prvoj je godini bila znatno veća u usporedbi s drugom godinom, te je manji broj sunčanih dana zasigurno bio jedan od uzroka izduživanja biljaka za vrijeme vlatanja u prvoj godini.

Na temelju podataka o prosječnim mjesečnim i višegodišnjim temperaturnim vrijednostima i količinama padalina napravljen je Walterov klima dijagram kojeg prikazuje Grafikon 1.



Grafikon 1. Walterov dijagram klime za razdoblje od rujna 2013. do srpnja 2015.

3.3. Statistička obrada podataka

Statistička obrada podataka napravljena je u praktikumu za informatiku Zavoda za bilinogojstvo na Fakultetu Agrobiotehničkih Znanosti u Osijeku. Za obradu podataka korišten je statistički informatički program SAS Enterprise Guide 5.1. Izrađena je opisna statistika kako bi dobili opću sliku o uzorku i raspodijeli podataka u njemu. Analiza glavnih komponenata korištena je za sagledavanje sveukupnog utjecaja svojstava kultivara na grupiranje samih kultivara.

3.3.1. Opisna statistika

Normalna raspodjela podataka osnovni je preduvjet za primjenu analiza parametrijske statistike. Radi utvrđivanja iste nužno je napraviti opisnu statistiku kako bi stekli dojam o varijabilnosti uzorka. Za svako svojstvo i godinu prikazane su najniže (Min.) i najviše (Max.) ostvarene vrijednosti kultivara grupiranih prema zemlji porijekla te su izračunate aritmetička sredina i medijan kao mjere centralne tendencije. Kao mjere varijacije korištene su standardna devijacija i koeficijent varijacije. Modus je prikazan jedino za broj dana do klasanja. Koeficijent varijacije kao i odnos aritmetičke sredine i medijana daju jasnu sliku o razlikama, odnosno homogenosti unutar grupa.

3.3.2. PCA agronomskih svojstava

PCA je temeljena na matrici korelacija izvornih varijabli visine biljke, broja dana do klasanja i prinosa. Analiza je napravljena za svaku godinu pojedinačno, kao i za razlike između ostvarenih vrijednosti kroz dvije godine pokusa. Vrijednosti latentnih korijena (eng. eigenvalues) predstavljeni kumulativnim postotcima od ukupne varijance poslužili su za odabir dvije glavne komponente. Biplot dijagrami poslužili su za prikaz vrijednosti kultivara i latentnih vektora (eng. eigenvectors) svakog svojstva. Matrice opterećenja glavnih komponenti varijablama ili doprinos varijabilnosti svakog svojstva pojedinim glavnim komponentama prikazane su radi lakšeg predočenja grupiranja kultivara i što je na njih utjecalo. Kultivari su označeni drugačije neovisno o zemlji porijekla, a grupirani su u hijerarhijske klastere prema sličnostima u svojstvima neovisno o PCA.

4. REZULTATI

4.1. Rezultati opisne statistike agronomskih svojstava

Grupe unutar uzorka formirane su prema četiri zemlje porijekla (Austrija, Hrvatska, Francuska i Mađarska) sa po 10 pripadajućih kultivara te su izračunane mjere centralne tendencije i varijacije. Cilj opisne statistike je istaknuti karakteristike svojstva kultivara iz različitih zemalja i njihov međusobni odnos. Mjere opisne statistike izračunate su za svaku godinu pojedinačno, kako bi mogli utvrditi utjecaj vremenskih prilika na agronomska svojstva.

4.1.1. Rezultati opisne statistike visine biljke

Rezultati opisne statistike za agronomsko svojstvo visine biljke (cm) prikazane su odvojeno za 2013./2014. u Tablici 5 i u Tablici 6 za 2014./2015. vegetacijsku godinu. U tablicama N označava broj ponavljanja, odnosno broj kultivara, a sve ostale vrijednosti za visine biljke izražene su u centimetrima (cm), osim koeficijenta varijacije koji je izražen u postotcima (%).

Tablica 5. Opisna statistika visine biljke u 2013./2014. godini

Zemlja porijekla	N	Aritmetička sredina	Standardna devijacija	Min.	Max.	Medijana	Koeficijent varijacije
AUT	10	110,53	7,14	97,12	118,88	111,84	6,46
CRO	10	101,51	24,14	73,40	145,16	95,52	23,79
FRA	10	94,86	7,48	88,44	113,92	91,90	7,88
HUN	10	102,14	3,47	97,56	109,76	101,24	3,40

U prvoj godini pokusa prosječno su najviši bili kultivari iz Austrije, dok su s razlikom od skoro 15 cm u prosječnim vrijednostima najniži bili kultivari iz Francuske. Najveća varijabilnost po pitanju visine stabljike u sezoni 2013./2014. može se uočiti u grupi hrvatskih kultivara gdje su standardna devijacija i koeficijent varijacije bili nekoliko puta veći nego kod ostalih zemalja. Najujednačenije visine biljke zabilježene su u sorata iz Mađarske čiji koeficijent varijacije iznosio samo 3,4%. Na homogenost mađarskih, odnosno varijabilnost hrvatskih kultivara u pogledu visine biljke ukazuju i razmaci varijacije.

Tablica 6. Opisna statistika visine biljke u 2014./2015. godini

Zemlja porijekla	N	Aritmetička sredina	Standardna devijacija	Min.	Max.	Medijana	Koeficijent varijacije
AUT	10	106,29	8,52	87,12	116,12	109,18	8,02
CRO	10	91,30	22,73	62,00	127,28	82,76	24,90
FRA	10	87,29	12,95	73,28	115,28	82,50	14,83
HUN	10	92,61	7,90	80,56	107,56	91,82	8,48

U drugoj godini pokusa također su prosječno najviši bili kultivari iz Austrije, a najniži oni iz Francuske. Najveću varijabilnost ponovno su pokazale hrvatski kultivari čiji koeficijent varijacije iznosi 24,90%, a razmak varijacije 65,28 cm. Veliku varijabilnost pokazale su i francuske sorte (KV=14,83%)

Prosječne visine biljaka, bez obzira na zemlju porijekla, bile su za 4 do 10 cm niže u drugoj godini. Najmanje razlike između aritmetičkih sredina i standardnih devijacija u dvije godine s obzirom na ovo agronomsko svojstvo imali su kultivari iz Austrije što nam govori o njihovoj stabilnosti, odnosno adaptabilnosti na različite klimatske uvjete. Hrvatski kultivari u obje godine imaju koeficijent varijacije preko 20% što je pokazatelj veće varijabilnosti između samih kultivara. Razlike u prosječnoj visini hrvatskih kultivara između godina od 10,21 cm ukazuju na velik utjecaj okoline na visinu biljke. Francuski su kultivari u drugoj godini imale skoro dvostruko veći koeficijent varijacije nego u prvoj godini. Iako su u drugoj godini biljke bile prosječno niže za 9,53 cm nego u prvoj. Mađarski kultivari u obje sezone imaju koeficijent varijacije manji od 10% te na temelju toga možemo zaključiti kako se cijela grupa mijenjala jednolično. Visina biljke pokazala se kao vrlo varijabilno agronomsko svojstvo u uzorku unutar i između grupa.

4.1.2. Rezultati opisne statistike broja dana do klasanja

Rezultati opisne statistike za agronomsko svojstvo broja dana do klasanja prikazane su odvojeno za 2013./2014. u Tablici 7 i u Tablici 8 za 2014./2015. pokusnu godinu. U tablicama N označava broj ponavljanja, odnosno broj kultivara, a sve ostale vrijednosti za broj dana do klasanja izražene su u broju dana, osim koeficijenta varijacije koji je izražen postotcima (%).

Tablica 7. Opisna statistika broja dana do klasanja u 2013./2014. godini

Zemlja porijekla	N	Aritmetička sredina	Standardna devijacija	Min.	Max.	Modus	Medijana	Koeficijent varijacije
AUT	10	129,10	6,05	117	138	127	128,50	4,68
CRO	10	117,60	6,80	110	129	115	115,00	5,78
FRA	10	122,40	7,50	116	138	117	118,50	6,13
HUN	10	122,40	6,38	116	131	116	121,50	5,21

Prosječno najmanji broj dana do klasanja u prvoj godini pokusa imali su kultivari iz Hrvatske (117,6 ± 6,8 dana), a najveći austrijski kultivari pšenice (129,1 ± 6,05 dana). Vrlo bliske vrijednosti aritmetičkih sredina, modusa i medijane u skupini hrvatskih i austrijskih sorti ukazuju na normalnu raspodjelu učestalosti u te dvije skupine. Koeficijenti varijacije svih zemalja bili su manji od 7% što upućuje na homogenost grupa po pitanju broja dana do klasanja u prvoj godini pokusa.

Tablica 8. Opisna statistika broja dana do klasanja u 2014./2015. godini

Zemlja porijekla	N	Aritmetička sredina	Standardna devijacija	Min.	Max.	Modus	Medijana	Koeficijent varijacije
AUT	10	133,10	4,01	128	142	132	132,50	3,01
CRO	10	127,40	4,17	121	133	127	127,00	3,27
FRA	10	131,70	3,50	128	140	130	131,00	2,70
HUN	10	131,10	2,90	128	135	128	131,00	2,17

Hrvatski kultivari imali su najmanji broj dana do klasanja i u drugoj godini pokusa, dok su austrijski ponovno trebali prosječno najduže vrijeme za početak klasanja. Vrlo bliske vrijednosti aritmetičkih sredina, modusa i medijana unutar svih zemalja na normalnu raspodjelu učestalosti ispitivanog svojstva, dok mali koeficijenti varijacije ispod 3,5% ukazuju na homogenost unutar grupa.

Unutar obje godine pokusa hrvatski su kultivari pokazali 2 do 5 dana kraći period do početka klasanja u odnosu na sve ostale zemlje porijekla, dok su Austrijski kultivari uvijek imali najdužu vegetaciju. Ovakva pojava može se objasniti geografskim položajima

zemalja porijekla jer su oplemenjivači stvarali kultivare za različita područja uzgoja i klimatske uvjete. Hrvatski, francuski i mađarski kultivari druge su godine produžili vrijeme do početka klasanja za 9 do 10 dana, dok su austrijski trebali 4 dana više nego prve godine. Na temelju dobivenih podataka možemo zaključiti kako je promjena okoline po pitanju broja dana do klasanja najmanje utjecala na austrijske kultivare.

4.1.3. Opisna statistika prinosa

Rezultati opisne statistike za agronomsko svojstvo prinosa prikazane su odvojeno za 2013./2014. u Tablici 9 i u Tablici 10 za 2014./2015. vegetacijsku godinu. U tablicama N označava broj ponavljanja, odnosno broj kultivara, a sve ostale vrijednosti vezane za prinos prikazane su u tonama po hektaru (t/ha), osim koeficijenta varijacije koji je izražen postotcima (%).

Tablica 9. Opisna statistika prinosa u 2013./2014. godini

Zemlja porijekla	N	Aritmetička sredina	Standardna devijacija	Min.	Max.	Medijana	Koeficijent varijacije
AUT	10	5,22	1,40	3,99	8,70	5,05	26,87
CRO	10	4,99	1,30	3,03	6,32	5,47	26,04
FRA	10	6,69	1,63	3,49	8,53	7,10	24,40
HUN	10	5,08	1,08	3,70	7,07	4,80	21,30

Najveći prosječni prinos po jedinici površine imali su francuski kultivari sa 6,69 t/ha, dok su najmanje prosječne prinose ostvarili kultivari iz Hrvatske. Mađarski i austrijski kultivari ostvarili su nešto više prinose od hrvatskih. Razmak varijacije ostvarenih prinosa kod hrvatskih kultivara iznosi 3,29 t/ha i najmanji je u usporedbi s ostalim grupama. Aritmetičke sredine i medijane svih grupa relativno su bliske. Svi koeficijenti varijacije iznose preko 20%, a najviši je zabilježen u austrijskih sorti.

Tablica 10. Opisna statistika prinosa u 2014./2015. godini

Zemlja porijekla	N	Aritmetička sredina	Standardna devijacija	Min.	Max.	Medijana	Koeficijent varijacije
AUT	10	7,94	2,09	3,88	10,20	8,43	26,30
CRO	10	7,73	1,84	4,33	9,48	8,25	23,84
FRA	10	8,80	1,49	5,23	10,12	9,13	17,04
HUN	10	9,09	1,69	7,77	13,44	8,80	18,56

U drugoj godini pokusa najveće prosječne prinose ostvarili su mađarski kultivari s 9,09 t/ha, iza čega slijede francuske s 8,80 t/ha. Hrvatski i austrijski kultivari imali su nešto niže prosječne prinose, ali i veće koeficijente varijacije u usporedbi sa francuskim i mađarskim kultivarima. Najveći razmak i koeficijent varijacije očituje se u skupini austrijskih kultivara.

Prinosi su zbog povoljnijih vremenskih uvjeta i manjeg napada bolesti u drugoj godini pokusa bili znatno veći u usporedbi s prvom godinom. Francuski su kultivari u obje godine imali najveći prinos, a njihova je razlika u godinama najmanja što je dobar pokazatelj stabilnosti i visokog potencijala prinosa. Adaptabilnost kultivara iz Francuske može se objasniti različitosti podneblja te zemlje i stvaranjem kultivara pogodnim za uzgoj u različitim dijelovima zemlje. Mađarski su kultivari pokazali razlike od 3,99 t/ha u dvije godine što je najveća razlika od svih skupina. Podaci opisne statistike jasno potvrđuju kako je prinos izrazito kompleksno svojstvo na koje značajno utječu vremenske prilike, genetska konstitucija, napadi bolesti i mnogi drugi čimbenici.

4.2. Rezultati PCA

Rezultati analize glavnih komponenata prikazani su pojedinačno za godine 2013./2014., 2014./2015. te za razlike između vrijednosti agronomskih svojstava u te dvije godine.

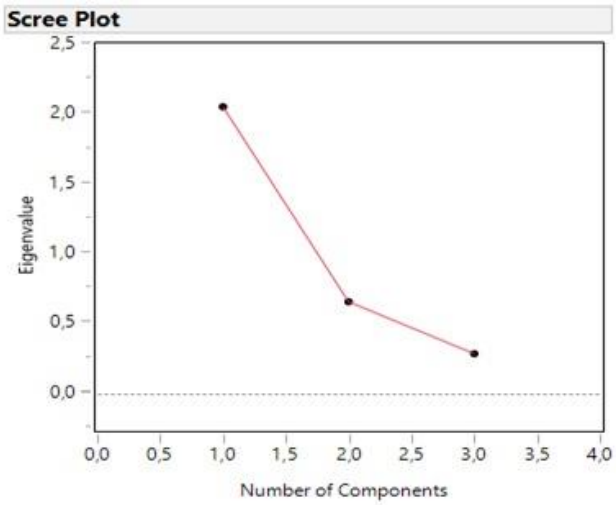
4.2.1. Rezultati PCA 2013./2014.

Latentni su korijeni izračunati na temelju visine biljke, broja dana do klasanja i prinosa 40 kultivara za 2013./2014. godinu čije vrijednosti, postotci ukupne varijance i kumulativni postotci glavnih komponenti prikazani u Tablici 11. Međusobne odnose latentnih korijena i krivulju koju tvore uočavamo na scree plot dijagramu kojeg prikazuje Grafikon 2.

Tablica 11. Latentni korijeni, postotci opisani pojedinim glavnim komponentama i kumulativni postotci od ukupne varijance objašnjeni glavnim komponentama u godini 2013./2014.

Broj	Latentni korijen (eng. eigenvalue)	Postotak	Kumulativni postotak
1	2,0558	68,53	68,53
2	0,6583	21,94	90,47
3	0,2858	9,53	100,00

Kao što je navedeno ranije u tekstu, maksimalan broj glavnih komponenti jednak je broju ispitivanih svojstava, no s obzirom da prva glavna komponenta obuhvaća 68,53%, a druga 20,94% što je zajedno 90,47% ukupne varijabilnosti uzorka, upravo su te dvije komponente izabrane za interpretaciju rezultata.



Grafikon 2. Scree plot dijagram latentnih korijena glavnih komponenti u 2013./2014. godini

Scree plot dijagrami također su jedno od sredstava pomoći odabira broja glavnih komponenti koje će biti poslužiti za prikaz svih 40 sorti s najmanjim gubitcima ukupne varijance. Obično se odabiru glavne komponente čije se vrijednosti latentnih korijena nalaze u strmini krivulje jer upravo su one te koje obuhvaćaju najveći dio varijabilnosti.

Tablica 12 prikazuje djelomične doprinose (%) ispitivanih varijabli (eng. partial contribution of variables) glavnim komponentama PC1 i PC2. Zbog različitog utjecaja varijabli na glavne komponente i nepovezanosti glavnih komponenti lakše je prema

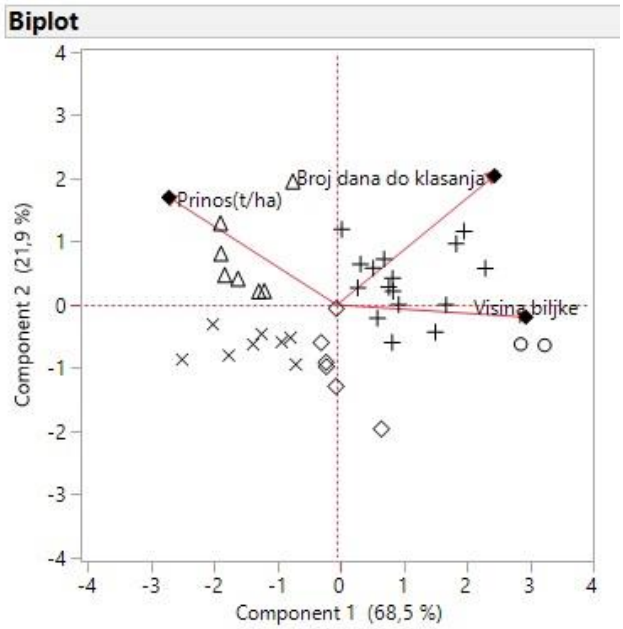
položaju kultivara na biplot dijagramu odrediti uzrok njihovog grupiranja ili odudaranja od uzorka.

Tablica 12: Djelomični doprinos varijabli glavnim komponentama izražen u postotcima za 2013./2014. godinu

	PC1	PC2
Visina biljke	40,24	0,52
Prinos	31,78	40,73
Broj dana do klasanja	27,98	58,75

Prema postotcima djelomičnih doprinosa agronomskih svojstava glavnim komponentama danim u Tablici 12 uočavamo kako su na prvu glavnu komponentu utjecale varijabilnosti sva tri svojstava različitim intenzitetom, a ponajviše visina biljke. Drugu glavnu komponentu velikim dijelom sačinjava varijanca prinosa i broja dana do klasanja, dok visina biljke nije znatno utjecala na nju.

Grafikon 3 prikazuje biplot dijagram PCA analize agronomskih svojstava u vegetacijskoj 2013./2014. čiju x os u koordinatnom sustavu predstavlja prva, a y druga glavna komponenta. Na dijagramu su prikazane vrijednosti kultivara projiciranih pomoću te dvije komponente i eigenvektori ispitivanih agronomskih svojstava.



Grafikon 3. Biplot dijagram PCA za 2013./2014. godinu

Kultivari označeni kružićima su hrvatski U1 i Sirban Prolifik, a prema vrijednostima iz Tablice 1a ti su kultivari bili najviši te su imali najniži ostvareni prinos što se može zaključiti iz njihovog položaja u koordinatnom sustavu glavnih komponenti. Grupa označena križićima obuhvaća sorte čiji je broj dana do klasanja 125 ili veći, a 9 od 16 kultivara je porijeklom iz Austrije. Rombovima označeni kultivari imali su raspon visine biljke od 100,56 cm (MV Mambo) do 115,08 cm (Divana), a njihov raspored duž PC2 ukazuje na varijabilnost u prinosu i broju dana do klasanja. Najniže pozicioniran, rombom označeni kultivar, koji je odvojeno projiciran od grupe je Divana koji je ostvario nizak prinos od 3,38 t/ha i imao mali broj dana do klasanja. Kultivare označene s X karakterizira mali broj dana do klasanja u rasponu od 110 do 117 dana i visina stabljike ispod 100,2 cm s prinosima nešto višim od prosječnih prinosa cijelog uzorka za tu godinu. Kultivari označeni trokutima su najniži u uzorku i ostvarili su najviše prinose u odnosu na druge grupe. Prinosi u rasponu od 6,75 do 8,65 t/ha objašnjavaju njihov viši položaj na PC2 osi kojoj doprinosi varijabilnost na temelju prinosa. Kultivar koji odudara od grupe označene trokutima je mađarski MV Kemence čija je visina biljke od 97,56 cm bila najviša u toj skupini. Francuski kultivar Aubusson trebao je 132 dana do početka klasanja što je za 10 do 15 dana više u usporedbi s drugim kultivarima iz iste skupine te iz tog razloga njegove vrijednosti fizički nisu stale u koordinatni sustav. Kultivar čija se projekcija nalazi na presjeku eigenvektora za agronomsko svojstvo prinosa jest austrijski Excelisior koji je ostvarila prinose od 8,65 t/ha što je ujedno i najveća ostvarena vrijednost u cijelom uzorku za to svojstvo.

Kako je spomenuto ranije, na slaganje PC1 najviše utjecaja imala je varijabilnost u visini biljke sa oko 40%, dok su druga dva svojstva doprinijela sa oko 30%. Prema raspodijeli kultivara u koordinatnom sustavu glavnih komponenti, te njihovom grupiranju duž osi PC1 možemo zaključiti kako je upravo visina biljke bila ključno agronomsko svojstvo za stvaranje skupina u uzorku.

4.2.2. Rezultati PCA 2014./2015.

Latentni korijeni izvedeni su na temelju visine biljke, broja dana do klasanja i prinosa 40 kultivara za 2014./2015. godinu čije su vrijednosti, postotci ukupne varijance i kumulativni postotci glavnih komponenti prikazane u Tablici 13.

Tablica 13. Latentni korijeni, postotci opisani pojedinim glavnim komponentama i kumulativni postotci od ukupne varijance objašnjeni glavnim komponentama u godini 2014./2015.

Broj	Latentni korijen (eng. eigenvalue)	Postotak	Kumulativni postotak
1	1,8275	60,92	60,92
2	0,8957	29,86	90,78
3	0,2768	9,23	100,00

Prva i druga glavna komponenta obuhvaćaju preko 90% ukupne varijance te su iz tog razloga odabrane za prikaz rezultata, dok je PC3 odbačena.

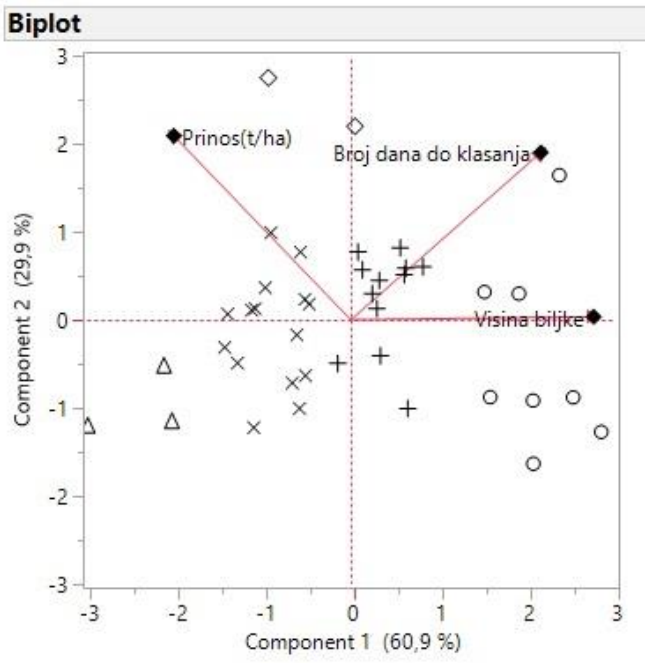
Tablica 14 prikazuje matricu opterećenja (eng. Loading Matrix) koja ukazuje na korelaciju između izvornih varijabli, odnosno agronomskih svojstava s glavnim komponentama.

Tablica 14: Matrica opterećenja glavnih komponenata u godini 2014./2015.

	PC1	PC2
Visina biljke	0,92	0,01
Prinos	-0,67	0,70
Broj dana do klasanja	0,72	0,64

Uočavamo kako najveću korelaciju s PC1 bez obzira na smjer ponovno pokazuje visina biljke kao i u prethodnoj godini pokusa. Preostale dvije varijable imaju manju korelaciju od visine biljke, uz napomenu da je prinos negativno povezan s prvom komponentom. PC2 je pozitivno korelirana s prinosom u nešto većoj mjeri od broja dana do klasanja, dok je korelacija visine biljke s tom komponentom zanemariva.

Grafikon 4 prikazuje biplot dijagram PCA analize agronomskih svojstava u vegetacijskoj 2014./2015. godini čiju x os u koordinatnom sustavu predstavlja prva, a y druga glavna komponenta. Na dijagramu su prikazane vrijednosti kultivara projiciranih pomoću te dvije komponente i eigenvektori ispitivanih agronomskih svojstava.



Grafikon 4. Biplot dijagram PCA za 2014./2015. godinu

Skupina kultivara označenih sa kružićima je skupina sa visinom biljke u rasponu od 104,92 do 110,88 cm što ju čini najvišom skupinom u uzorku. Velik broj dana do klasanja te niski prinosi u usporedbi s drugim skupinama također karakteriziraju tu grupu. Raspored duž y osi ukazuje na velike razlike u ostvarenim prinosima i broju dana do klasanja unutar skupine. Tako je u koordinatnom sustavu najniže pozicioniran kultivar Belmondo ostvario 3,88 t/ha i trebao 132 dana do početka klasanja, dok je Eurojet koji je najviše postavljen kultivar iz te grupe imao prinos od 7,89 t/ha i 142 dana do klasanja. Križićima označeni kultivari nešto su niži od prethodne skupine, a prinosi se kreću u rasponu od 6,65 do 10,20 t/ha. Kultivar koji se ističe iz skupine u donjem dijelu koordinatnog sustava je hrvatski kultivar Divana koji je ostvario najmanji prinos u grupi, a ima i mali broj dana do klasanja. Dva kultivara označena rombovima, Bastide i MV Mazurka ostvarili su vrlo visoke prinose s više od 10t/ha. Imale su i veći broj dana do klasanja u usporedbi s cjelokupnim uzorkom, a njihov međusobni razmak s obzirom na PC1 os ukazuje nam i na razlike u visini biljke ta dva kultivara. Felix, Srpanjka i Anđelka su tri hrvatska kultivara na grafikonu označena trokutima, a njihovu skupinu karakteriziraju stabljike niže od 78,88 cm, ostvareni visoki prinosi te manje od 125 dana do početka klasanja.

4.2.3. Rezultati PCA razlika agronomskih svojstava u dvije godine pokusa

Podatci o razlikama agronomskih svojstava u dvije godine iz Tablice 2a i 2b korišteni su kao izvorne varijable za provedbu PCA. Latentni su korijeni izračunati na temelju razlika visine biljke, broja dana do klasanja i prinosa 40 kultivara čije su vrijednosti, postotci ukupne varijance i kumulativni postotci glavnih komponenti prikazane u Tablici 15.

Tablica 15. Latentni korijeni, postotci opisani pojedinim glavnim komponentama i kumulativni postotci od ukupne varijance razlika svojstava objašnjenih glavnim komponentama

Broj	Latentni korijen (eng. eigenvalue)	Postotak	Kumulativni postotak
1	1,3746	45,82	45,82
2	1,0000	33,33	79,15
3	0,6254	20,85	100,00

Latentni korijen PC1 obuhvaća 45,82%, a PC2 33,33% ukupne varijance te odbacivanjem PC3 gubi se samo mali dio varijabilnosti opisane glavnim komponentama.

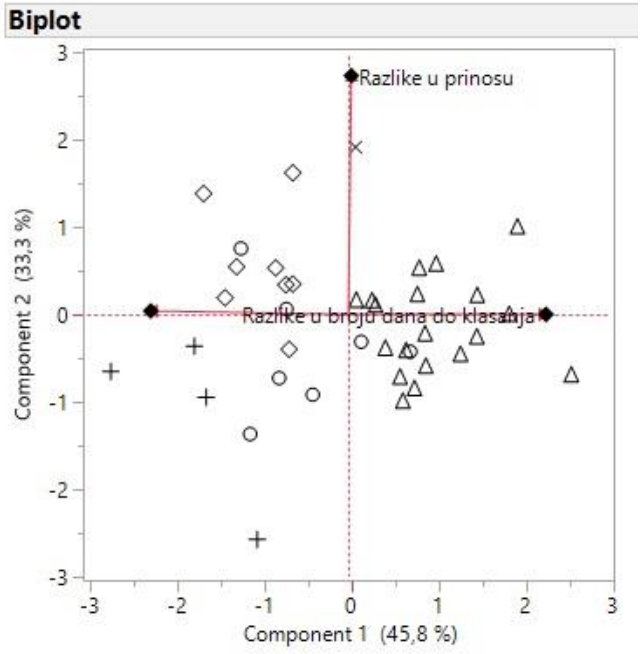
Tablica 16 prikazuje djelomične doprinose (%) ispitivanih varijabli (eng. partial contribution of variables) glavnim komponentama označenim Prin1, 2 i 3.

Tablica 16. Djelomični doprinos varijabli razlika agronomskih svojstava glavnim komponentama

	PC1	PC2
Razlike u visini biljke	49,99	0,02
Razlike u prinosu	0,01	99,98
Razlike u broju dana do klasanja	50,00	0,00

Na sastavljanje prve glavne komponente utjecale su razlike u visini biljke i broju dana do klasanja skoro podjednakim udjelom, dok su razlike u prinosu neznatno utjecale na tu komponentu. Druga komponenta opisuje isključivo varijanca razlika u prinosu, što će znatno utjecati na raspored kultivara u koordinatnom sustavu.

Grafikon 5 prikazuje biplot dijagram PCA analize razlika agronomskih svojstava čiju x os u koordinatnom sustavu predstavlja prva, a y drugu glavna komponenta. Na dijagramu su prikazane vrijednosti kultivara projiciranih pomoću te dvije komponente i eigenvektori ispitivanih agronomskih svojstava.



Grafikon 5. Biplot dijagram PCA za razlike agronomskih svojstava u dvije godine pokusa

Neoznačeni ulijevo usmjeren eigenvektor pripada razlikama u visini biljke, ali je naziv zbog preglednosti izostavljen sa grafikona. Dva kultivara istaknuta od skupine označene trokutima su Divana koja ima 16 dana razlike u broju dana do klasanja i 11,64 cm razlike u visini biljke, te Bastide sa 22 dana razlike što ujedno predstavljaju i najveće razlike u broju dana do klasanja cijelog uzorka. Jedna od vrijednosti dva kultivara označena slovom X prelazi gornju granicu grafikona te iz tog razloga nije prikazana. Razlog njihovog visokog položaja duž osi PC2 jesu najveće razlike u prinosu od čitavog uzorka, a predstavljaju kultivare SW Kronjet sa 6,20 t/ha i MV Mazurka sa 8,94 t/ha razlike u prinosu. Dva kultivara označena rombovima koji odudaraju od svoje skupine na grafičkom prikazu predstavljaju MV Optima i MV Magdalena koji su u toj skupini imali najveće razlike u visini biljke i prinosu. Najniže lociran od kružićem označenih kultivara koji se razlikuje od skupine jest Francuski Aubusson koji je imao uvjerljivo najmanje razlike u prinosu i to samo 0,53 t/ha. Achtat, Belmondo, Indigo i Capelle Desprez kultivari su označeni križićem, a grupirani su skupa zbog najmanjih razlika u sva tri svojstva unutar cijelog uzorka.

5. RASPRAVA

Genetska varijabilnost kulturnog bilja temelj je i osnovni preduvjet svakog uspješnog oplemenjivanja. Izvori varijabilnosti obično podrazumijevaju mutacije i rekombinacije roditeljskih gena koje se koriste za dobivanje superiornih kombinacija genotipova te je nužno koristiti sve dostupne izvore genetske varijabilnosti i tehnologije (Bede i Petrović, 2006.). Mjerenje i analiziranje agronomskih svojstava u različitim okolinama jedan su od glavnih koraka u otkrivanju adaptabilnih genotipova i općenito genetske različitosti između ispitivanih kultivara. Na temelju statističkih analiza agronomskih svojstava mogu se odabrati genetski udaljene roditeljske linije ovisno o cilju oplemenjivanja. Prinos zrna glavni je cilj oplemenjivanja pšenice, no s obzirom na složenost oplemenjivanja na prinos oplemenjivači usmjeruju svoju pažnju i prema drugim svojstvima koja pokazuju veliku korelaciju, a najčešće je to visina biljke (Borojević S., 1981.; Martinčić i Kozumplik, 1996.). Posljednje stoljeće oplemenjivanja pšenice prati trend smanjenja visine biljke koje je u početku za osnovni cilj imalo povećanje otpornosti na polijeganje, a kasnijim analizama potvrđena je i negativna korelacija visine biljke i prinosa. Niska, čvrsta stabljika jedan je od osnovnih preduvjeta visokog potencijala rodnosti jer se gubi rizik od loma stabljike pod težinom klasa te je sam klas kod kultivara niske stabljike kompaktniji i sadrži veći broj zrna (Bede, 1993.; Martinčić i Kozumplik, 2000.). Trend smanjenja visine stabljike unutar skupine kultivara iz Hrvatske uočavamo usporedimo li na primjer podatke iz 2014./2015. za visinu biljke kultivara U1 (127,28 cm) koji je nastao 1936. godine sa znatno mlađim kultivarom Srpanjka (62 cm). Kultivari uključeni u analizu 2013./2014. vegetacijske godine imaju raspon varijacije u visini biljke od 71,76 cm, a u 2014./2015. nešto manjih 65,28 cm što ukazuje na različite godine nastanka, ciljeve oplemenjivača i genetske konstitucije samih kultivara. Veći broj dana do klasanja podrazumijeva duže vlatanje pšenice te je to jedan od razloga pozitivne korelacije tog svojstva s visinom biljke. Najbolji je primjer skupina Austrijskih kultivara koji su u obje godine bile prosječno najviše i imale najveći broj dana do početka klasanja. Austrijski su kultivari većinom bili viši od 100 cm i imali su najmanje razlike u obje godine pokusa za sva tri svojstva. Razlog tomu jest što su to kultivari namijenjeni ekstenzivnom uzgoju i odlikuju se dobrom adaptabilnom sposobnošću (Petrović, 2011.).

Prinos, visina biljke i broj dana do klasanja svojstva su koja kontroliraju nekolicina major i mnoštvo minor gena te su zbog toga izrazito kvantitativne prirode. Dvije godine pokusa značajno su se razlikovale u pogledu klimatskih uvjeta, a ponajviše po pitanju količine i

rasporeda oborina kroz vegetaciju pšenice koji je bio povoljniji u drugoj godini. Nedostatak vode za vrijeme busanja pšenice predstavlja jedan od kritičnih perioda u tom pogledu. Uzrok je slabijeg početnog porasta biljke i slabijeg busanja te odlaže kompletan vegetacijski ciklus zbog stagniranja razvoja za vrijeme nepovoljnih uvjeta (Assuero i Tognetti, 2010.). Na visinu biljke znatno utječu vremenske prilike u ranijim stadijima razvoja, a osobito temperatura koja pri višim vrijednostima ubrzava asimilaciju hranjiva u biljci (Kronenberg i sur., 2017.). Takvu situaciju uočavamo za vrijeme zimskih i proljetnih mjeseci u prvoj godini pokusa što za posljedicu ima prosječno više biljkama uspoređujući ih s visinama izmjerenih u drugoj godini. Dobiveni rezultati slažu se i s rezultatima Kiss i sur. (2013.) koji su koristili različite datume sjetve u svojim pokusima kako bi postigli drugačije vremenske uvjete u istim fenofazama. Oni su zaključili kako kultivari ozime pšenice izloženi višim temperaturama u fenofazi busanja i vlatanja pokazuju jaču inicijaciju izduživanja stabljike, ali i manji broj bočnih vlati što je u oba slučaja imalo negativan utjecaj na prinos. Broj dana do klasanja u negativnoj je korelaciji sa prinosom u obje godine pokusa. Rezultati korelacija agronomskih svojstava se slažu i sa istraživanjem koje su proveli Mohammadi i sur. (2012.) ispitavši agronomska svojstava pšenice u uvjetima sa periodima suše i uz navodnjavanje. Sezonska godina 2013./2014. u Republici Hrvatskoj, a osobito u Slavoniji zapamćena je među ratarima po epidemiji lisne hrđe koja je bila jedan od glavnih uzroka niskih prinosa te godine (Drezner, 2014.). Uz navedene klimatske uvjete koji su uzrokovali izduživanje stabljike slabije čvrstoće, veće temperature i više padalina u vrijeme vlatanja pšenice kada je sklop obrastao i gust idealno su pogodovale razvoju bolesti. Pozitivna korelacija visine biljke i broja dana do klasanja vidljiva je u uzorku unutar obje godine, kao i u PCA analizama godina pokusa te se slaže s navodima Villegas i sur. (2001.). Broj dana do klasanja u prvoj godini pokusa bio je prosječno manji nego u drugoj iako su biljke tada bile više, a to možemo pripisati prisilnoj zriobi kultivara zbog napada bolesti i nepovoljnih vremenskih uvjeta.

PCA je osim u pogledu redukcije podataka i pojednostavljenom prikazu grupa koje su se formirale s obzirom na sličnost agronomskih svojstava poslužila za predočavanje smjera i jačine povezanosti između samih svojstava. Omogućeno je i sagledavanje promjena svojstava u različitim uvjetima uzgoja. Upravo su zbog velikog broja svojstava koja su povezana s prinosom, metode multivarijatne statističke analize kao što je PCA pogodne za lakši rad i sagledavanje sveobuhvatne slike o ispitivanim kultivarima i njihovim svojstvima. Dobiveni rezultati o formiranju glavnih komponenti i utjecaju pojedinih

agronomskih svojstava na njih u obje godine pokusa razlikuju se od rezultata Desheva i sur. (2016.). U njihovom radu prvu glavnu komponentu sačinjavale su komponente prinosa osim broja klasića po klasu čija je varijabilnost skupa s varijabilnošću visine biljke najviše utjecala na drugu komponentu. Razlike u genetskoj konstituciji kultivara, veličini uzorka i većeg broja ispitivanih svojstava uzrok su drugačijeg formiranja glavnih komponenti. Istraživanje utjecaja vremenskih prilika na agronomska svojstva pšenice je zbog izrazite povezanosti velikog broja svojstava složen postupak i zahtijeva ispitivanja u različitim okolinama. Najbolji rezultati o utjecaju vremenskih prilika dobivaju se cjelokupnim promjenama okoline što podrazumijeva više godina pokusa sa različitim okolinama koje su sačinjene od vremenskih uvjeta, napada raznih bolesti i štetnika te samog lokaliteta pokusa. Mirosavljević i sur. (2016.) su PCA analizi utjecaja vremenskih prilika na agronomska svojstva ozimog ječma pristupili na isti način analiziravši podatke iz dvije godine pokusa. U pogledu povezanosti svojstava potvrdili su negativnu korelaciju prinosa s visinom biljke i brojem dana do klasanja koji su međusobno pozitivno korelirani. Njihovi se rezultati slažu s rezultatima dobivenim u 2013./2014. i 2014./2015. godinama analize agronomskih svojstava pšenice. Prinos zrna, visina biljke i broj dana do klasanja pokazala su veliku varijabilnost među ispitivanim kultivarima što se pripisuje utjecaju genotipova kultivara (G), okolina (E) i njihove interakcije (GxE). Nedostatak vode jedan je od glavnih problema tijekom vegetacije pšenice jer negativno utječe na prinos osobito u periodu formiranja cvjetnih zametaka i zriobe sjemena, a utjecaj različitog režima vode uz pomoć PCA analizirala je nekolicina autora (Gizaw i sur., 2016.; Zamani-Babgohari i sur., 2017.).

Utvrđena je velika varijabilnost između sva tri ispitivana agronomska svojstva, a na temelju grupiranja kultivara prema ostvarenim vrijednostima moguće je izdvojiti one koje su adaptabilne od ispitivanih 40 kultivara. Kako je ranije prikazano i utvrđeno, prva godina pokusa bila je nepovoljna za uzgoj pšenice, a upravo se u takvim uvjetima ističu sorte stabilnih svojstvava i mogućnostima adaptabilnosti na nepovoljne uvjete. Prema vrijednostima na biplotu sa Grafikona 4 u prvoj godini pokusa kao najbolji kultivari u pogledu dobrih prinosa i ranozrelosti ističu se oni označeni s X gdje pripadaju hrvatski kultivari Osječka 20, BC Patria, Felix, Panonija, Srpanjka i Anđelka te francuski Goelent i Enesco. Valja istaknuti i sorte Excelicior, MV Kemence, Aubusson, Soissons, Exotic, Isnegrain, Premio i Bastide označene trokutima koje su ostvarile najviše prinose, ali su imale veći broj dana do klasanja od prethodno navedene grupe. Druga godina pokusa bila je puno pogodnija za uzgoj pšenice zbog boljeg rasporeda padalina tijekom vegetacije i

manje pojave bolesti te su ostvareni prinosi u toj godini puno veći nego u prijašnjoj. Puno kultivara koji su prve godine ostvarili najbolje vrijednosti u pogledu prinosa, ranozrelosti i visine biljke ponovno su uključeni u grupe s poželjnim svojstvima 2014./2015. godine. Sorte označene s X na Grafikonu 5 također predstavljaju grupu kultivara s najnižim stabljikama i najmanjim brojem dana do klasanja te visokim prinosima, a skupina uključuje kultivare Osječka 20, BC Patria, Panonija, Excelicior, Soissana, MV Emese, MV Mambo, MV Kemence, MV Amanda, Aubusson, Enesco, Soissons, Exotic, Isnegrain te Premio. Kultivari Bastide i MV Mazurka označeni rombovima imali su prinose iznad 10 t/ha, ali i veći broj dana do klasanja od prethodno navedene grupe. U drugoj godini posebno su se istaknuli hrvatski kultivari Felix, Srpanjka i Anđelka koji su imali najniže stabljike i najmanji broj dana do klasanja s vrlo visokim prinosima od 9 t/ha i više. Na temelju Grafikona 6 koji je rezultat PCA analize razlika agronomskih svojstava treba istaknuti sorte označene kružićima koje su imale najmanje razlike u prinosu i broju dana do klasanja unutar dvije godine pokusa, a skupina uključuje kultivare U1, Sirban Prolifik, Eurojet, Soissana, MV Suba, MV Zelma i Aubusson. Sorte označene križićima su Achat, Belmondo, Indigo te Capelle Desperez i predstavljaju grupu s najmanjim razlikama u sva tri svojstva. Zanimljivo je napomenuti kako su tri od četiri kultivara iz skupine s najmanjim razlikama za sva tri svojstva porijeklom iz Austrije. Očuvanje genetske varijabilnosti germplazme i unošenje različitih gena otpornosti na sušu, bolesti i druge oblike stresa introdukcijom stranih sorti neophodni su koraci u stvaranju otpornih sorti (Knežević i sur., 2016.). S obzirom na različitost svojstava istaknutih kultivara, zemlje njihovog porijekla i genetske konstitucije utvrđena je velika varijabilnost te je stvorena jasna slika o visokoprinosnim i adaptabilnim kultivarima u uzorku. Takvi kultivari mogu poslužiti za stvaranje novih sorti visokih prinosa s odgovarajućim svojstvima za uzgoj u klimatskim uvjetima Slavonije.

6. ZAKLJUČAK

Na temelju analize glavnih komponenata utjecaja kojom je ispitivan utjecaj vremenskih prilika na agronomska svojstva pšenice možemo zaključiti sljedeće:

1. PCA analiza je vrlo efikasno poslužila za redukciju podataka, ukazivanje veza između varijabli te isticanje i grupiranje kultivara od interesa.
2. Potvrđena je negativna korelacija između prinosa i visine biljke te broja dana do klasanja u obje pokusne godine
3. Rezultati PCA analize istakli su kultivare s malim brojem dana do klasanja i visinom biljke te visokim prinosima u obje godine uspoređujući ih s ostatkom uzorka (Osječka 20, BC Patria, Panonija, Srpanjka, Anđelka, Felix, Enesco, Soissons, Excelicior, MV Kemence, Bastide, Isnegrain, Exotic, Premio, Aubusson).
4. Rezultati PCA analize razlika agronomskih svojstava u dvije godine pokusa ukazali su na najadaptabilnije kultivare koji su imali najmanje razlike između ispitivanih svojstava (U1, Sirban Prolifik, Eurojet, Soissana, MV Suba, MV Zelma, Aubusson, Achat, Belmondo, Indigo, Capelle Desperez).
5. Zbog sve češćih perioda suše i drugih stresnih uvjeta tijekom vegetacije pšenice istraživanja utjecaja vremenskih prilika na agronomska svojstva vrlo su važna zbog razumijevanja njihovih međusobnih povezanosti, kao i za stvaranje temelja u odabiru roditeljskih linija ovisno o cilju oplemenjivanja.

7. LITERATURA

1. Araus J. L., Slafer G. A., Royo C., Serret M. D. (2008.): Breeding for Yield Potential and Stress Adaptation in Cereals, Critical Reviews in Plant Science, 27:377-412
2. Ashour A. S., Nandi D., Samanta S., Chakraborty S., Salem M. A. M., Dey N. (2015.): Principal component analysis in medical image processing: a study, Int. J. Image Mining 1(1): 65-86
3. Assuero S. G., Tognetti J. A. (2010.): Tillering Regulation by Endogenous and Environmental Factors and its Agricultural Management, The Americas Journal of Plant Science and Biotechnology, Global Science Books 4(Special Issue 1) 35-48
4. Barber D. C., Howlett P. J., Smart R. C. (1975.): Principal component analysis in medical research, Journal of Applied Statistics, 2(1): 39-43
5. Bede M. (1993.): Novi trendovi u oplemenjivanju pšenice, Sjemenarstvo 11(94):5-14
6. Bede M., Petrović S. (2006.): Genetska varijabilnost roditelja – uvjet uspješnom oplemenjivanju pšenice, Sjemenarstvo 23(1): 5-11
7. Bondari, K. (2003.): Statistical Analysis of Genotype X Environment Interaction in Agricultural Research, Experimental Statistics, Coastal Plain Station, University of Georgia, Tifton, GA 31793-0748
8. Borojević S. (1981.): Principi i metodi oplemenjivanja bilja, Ćirpanov, Novi Sad
9. Borojević K. (1986.): Geni i populacija, Forum, Novi Sad
10. Desheva G., Sabeva M., Zacharieva M. (2016.): Variation of agronomic traits among introduced winter bread wheat cultivars, Trakia Journal of Sciences, 2: 171-175
11. Drezner G. (2014): Ogromne štete na pšenici od žute hrđe, koje u ovom kraju nije bilo 50 godina. www. http://www.glas-slavonije.hr/239899/1/.
12. Fahim M. G. (2014.): Study on yield and some agronomic traits of promising genotypes and lines of bread wheat through principal component analysis, Journal of Biodiversity and Environmental Sciences (JBES), 4(2):443-446
13. Filipčić A. (1998.): Klimatska regionalizacija Hrvatske po W. Köppenu za standardno razdoblje 1961.-1990. u odnosu na razdoblje 1931.-1960., Acta Geographica Croatica, Vol. 33, 1-15, Zagreb

14. Garcia G. A., Dreccer M. F., Miralles D. J. Serrago R. A. (2015.): High night temperatures during grain number determination reduce wheat and barley grain yield: a field study, Global Change Biology 21:4153-4164
15. Gomez D., Vanzetti L., Helguera M., Lombardo L., Fraschina J., Miralles D.J. (2014.): Effect of *Vrn*-1, *Ppd*-1 genes and earliness *per se* on heading time in Argentinean bread wheat cultivars, Field Crops Research 158:73-81
16. Gizaw S. A., Garland-Campbell K., Carter A. H. (2016.): Evaluation of agronomic traits and spectral reflectance in Pacific Northwest winter wheat under rain-fed and irrigated conditions, Field Crops Research 196: 168-179
17. Halmi A. (1999.): Temelji kvantitativne analize u društvenim znanostima: Kvantitativni pristup u socijalnome radu, Alinea, Zagreb
18. Halmi A. (2003).: Multivarijatna analiza u društvenim znanostima, Alinea, Zagreb
19. Horvat D., Ivezić M. (2005.): Biometrika u poljoprivredi, Poljoprivredni fakultet u Osijeku, Osijek
20. Johnson R. A., Wichern D. W. (2007.): Applied Multivariate Statistical Analysis, Pearson Education, New Jeresey
21. Jolliffe I. T. (2002.): Principal component analysis, Springer-Verlag, New York
22. Jugo, Bogdan (1957.): Uloga proizvodnih pokusa u unapređenju poljoprivrede, Agronomski glasnik, Vol. 7, No. 1-2, Zagreb
23. Kaya Y., Akcura M., Taner S. (2006.): GGE-Biplot Analysis Multi-Environment Yield Trials in Bread Wheat, Turk J Agric For 30:325-337
24. Kiss T., Balla K., Banyai J., Veisz O., Karsai I. (2018.): Effect of Different Sowing Times on the Plant Developmental Parameters of Wheat (*Triticum aestivum* L.), Cereal Research Communications, 46(2): 211-220
25. Knežević D., Paunović A., Madić M., Kondić D., Menkovska M. (2016.): Oplemenjivanje pšenice i ječma i očuvanje genetičkih resursa u poljoprivredi, XXI savetovanje o biotehnologiji, Zbornik radova 21 (23): 11-18
26. Kooch Y., Jalilvand H., Bahmanyar M. A., Pormajidian M. R. (2008.): The Use of Principal Component Analysis in Studying Physical, Chemical and Biological Soil Properties in Southern Caspian Forests (North of Iran), 11(3):366-372
27. Kronenberg L., Yu Kang, Walter A., Hund A. (2017.): Monitoring the dynamics of wheat stem elongation: genotypes differ at critical stages, Euphytica 213: 157
28. Kumar S., Sharma V., Chaudhary S., Tyagi A., Mishra P., Priyadarshini A., Singh A. (2012.): Genetics of flowering time in bread wheat *Triticum aestivum*:

complementary interaction between vernalization-insensitive and photoperiod-insensitive mutations imparts very early flowering habit to spring wheat, Journal of Genetics, 91:33-47

29. Kumar S. S. (2015.): Big Data: A dimensionality Reduction and Attribute Selection using PCA for Diabetic Data bases, Research Journal of Pharmaceutical, Biological and Chemical Sciences, 6(2):1395-1401
30. Lever J., Krzywinski M., Altman N.(2017.): Points of significance: Principal component analysis, Nature Methods, 14:641-642
31. Martinčić J., Kozumplik V. (1996.): Oplemenjivanje bilja, Poljoprivredni fakultet Osijek, Agronomski fakultet Zagreb, Zagreb
32. Martinčić Z., Kozumplik V. (2000.): Oplemenjivanje ratarskog i povrtnog bilja u Hrvatskoj, Agriculture Conspectus Scientificus, 65(2):129-141
33. Mirosavljević M., Pržulj N., Čanak P., Momčilović V., Aćin V., Jocković B., Hristov N., Mladenov N. (2015.): Relationship between Grain Yield and Agronomic Traits in Winter Barley, Ratarstvo i povrtlarstvo, 52(2):74-79
34. Mirosavljević M., Momčilović V., Pržulj N., Hristov N., Aćin V., Čanak P., Denčić S. (2016.): The variation of agronomic traits associated with breeding progress in winter barley cultivars
35. Mohammadi M., Sharifi P., Karimizadeh R., Shefazadeh M. K. (2012.): Relationships between Grain Yield and Yield Components in Bread Wheat under Different Water Avialability (Dryland and Supplemental Irrigation Conditions), Not Bot Horti Agrobo, 40(1): 195-200
36. Panishkan K., Swagjang K., Sanmanee N., Sungthong D. (2012.): Principal Component Analysis for the Characterization in the Application of Some Soil Properties, International Journal of Environmental and Ecological Engineering, 6(5):279-281
37. Pecina M. (2006.): Metode multivarijatne analize - osnove, Sveučilište u Zagrebu, Agronomski fakultet
38. Petrisor A.-I., Ianos I., Iurea D., Vaidianu M.-N. (2012.): Applications of Principal Component Analysis integrated with GIS, Procedia Environmental Sciences, 14:247-256
39. Petrović S. (2011.): Genetska različitost germplazme ozime krušne pšenice (*Triticum aestivum* L. spp. *vulgare*), Sveučilište Josipa Jurja Strossmayera u

Osijeku, Sveučilišni poslijediplomski interdisciplinarni doktorski studij Molekularne bioznanosti, Doktorski rad

40. Preisendorfer R. W. (1988.): Principal Component Analysis in Meteorology and Oceanography, Elsevier Science Publisher, New York
41. Radan Z., Ćosić J., Vrandečić K. (2014.): Bolesti lista pšenice – simptomi i epidemiologija, Glasnik zaštite bilja 4/2014
42. Russel G. E. (2013..): Progress in Plant Breeding-1, Dwarfing genes in wheat, Butterworth, London
43. Šarić G., Matković D., Hruškar M., Vahčić N. (2008.): Characterisation and Classification of Croatian Honey by Physicocemical Parameters, Food Technol. Biotechnol., 46(4):355-367
44. Šegota T., Filipčić A. (1996.): Klimatologija za geografe, 3. prerađeno izdanje, Školska knjiga, Zagreb
45. Šegota T., Filipčić A. (2003.): Köppenova podjela klima i hrvatsko nazivlje, Geoadria, Vol. 8/1, 17-37, Zadar
46. Tican C. (2004.): Effects of two height reducing genes on yield and its components in a semi-humid environtment, Romanian Agricultural Research, 21:13-18
47. Uddin M. N., Marshall D. R. (1989.): Effects of dwarfing genes on yield components under irrigated and rainfed conditions in wheat (*Triticum aestivum* L.), Euphytica 42:127-134
48. Vidhyavathi R. M. (2017.): Principal component analysis (PCA) in medical image processing using digital imaging and communications in medicine (DICOM) medical images, Int J Pharm Bio Sci, 8(2):598-606
49. Villegas D., Aparicio N., Blanco R., Royo C. (2001.): Biomass Accumulation and Main Stem Elongation of Durum Wheat Grown under Mediterranean Conditions, Annals of Botany, 88(4): 617-627
50. Zamani-Babgohari S., Heidari B., Dadkhodaie A. (2017.): The Interrelationship of Agronomic and Physiological Traits as Affected by Irrigation Regimes in Wheat: Application of Multivariate Statistical Analyses, Plant Breed. Biotech., 5(3): 172-182
51. Zarei L., Cheghamirza K., Farshadfar E. (2013.): Evaluation of grain yield and some agronomic characters in durum wheat (*Triticum turgidum* L.) under rainfed conditions, Australian Journal of Crop Science, 7(5):609-617

Mrežni izvori:

http://www.obz.hr/vanjski/CD_AGBASE2/HTM/psenica.htm

http://www.fao.org/land-water/databases-and-software/crop-information/wheat/en/

http://www.fao.org/faostat/en/?#data/QC

https://www.agroklub.com/sortna-lista/zitarice/psenica-108/

http://www.glas-slavonije.hr/324545/7/Zitna-hrdja-prijeti-Sredozemlju-brzo-se-siri-i-desetkuje-prinose

http://www.gospodarski.hr/Publication/2015/6/uta-hra-ponovno-napada/8195#.W3wPwiQzbIU

8. SAŽETAK

Većina je agronomskih svojstava kvantitativne prirode i na njih okolina ima velik utjecaj, a kombinacije gena otpornosti i adaptabilnosti stvaraju genotipove koji posjeduju mehanizme za ostvarivanje stalnih prinosa pod stresnim uvjetima okoline. Broj agronomskih svojstava pšenice je velik, a njihov međusobni odnos često je složen te se multivarijatne metode statističke analize kao što je analiza glavnih komponenata (PCA) koriste za redukciju podataka i isticanje najznačajnijih varijabli koje su utjecale na varijabilnost uzorka. Cilj ovog istraživanja bio je ispitati utjecaj vremenskih prilika na agronomska svojstva pšenica i grupiranje ispitivanih sorata s obzirom na promjenu vrijednosti agronomskog svojstva između godina primjenom PCA analize. U analizu je uključeno ukupno 40 kultivara porijeklom iz Austrije, Francuske, Hrvatske i Mađarske koji su sijani na pokusnim parcelama Hrvatskog centra za poljoprivredu, hranu i selo, Zavoda za sjemenarstvo i rasadničarstvo u 2013./2014. i 2014./2015. pokusnoj godini. Ispitivana su agronomska svojstva visine biljke, broja dana do klasanja i prinosa. PCA analiza u obje godine pokusa pokazala je sličnosti u korelacijama između agronomskih svojstava i grupiranja kultivara na koje je ponajviše utjecala visina biljke. Kultivari koji su se izdvojili po visokim prinosima, niskim stabljikama i malim brojem dana do klasanja u obje godine su: Osječka 20, BC Patria, Panonija, Srpanjka, Anđelka, Felix, Enesco, Soissons, Excelicior, MV Kemence, Bastide, Isnegrain, Exotic, Premio i Aubusson. PCA analiza razlika agronomskih svojstava izdvojila je: U1, Sirban Prolifik, Eurojet, Soissana, MV Suba, MV Zelma, Aubusson, Achat, Belmondo, Indigo i Capelle Desperez kao kultivare koji su imali najmanje razlike za dva ili više ispitivanih agronomskih svojstava u cijelom uzorku.

9. SUMMARY

Most of agronomic traits are quantitative in their nature, so environment plays a big role in their expression. Combinations of different stress resistance genes and genes involved in adaptation mechanisms in plants are the main reason for developing genotypes that have ability to maintain constant yields under stress conditions on field. Because of the big number of agronomic traits in wheat and its complex correlations, multivariate statistycal analysis like principal component analysis (PCA) are used for data reduction and emphasis of variables that contributed the most in total variability of the sample. The main goal of this analysis is to explore the influence of the environmental factors on agronomic traits of wheat and grouping of the cultivars based on the change of agronomic traits in two years of experiment using PCA. Analysis included 40 cultivars from Austria, France, Croatia and Hungary. They were sown on experimental fields of the Croatian center for agriculture, food and rural affairs in seasons 2013./2014. and 2014./2015. Analised agronomic traits in this paper were plant height, days to heading and yield. PCA from both years of experiment showed similarity in correlations between agronomic traits and grouping of cultivars which was mostly influenced by plant height. Cultivars that stand out in aspect of relatively big yields, low plant height and small number of days to heading in both years are Osječka 20, BC Patria, Panonija, Srpanjka, Anđelka, Felix, Enesco, Soissons, Excelicior, MV Kemence, Bastide, Isnegrain, Exotic, Premio and Aubusson. PCA analysis of changes in agronomic traits pointed out U1, Sirban Prolifik, Eurojet, Soissana, MV Suba, MV Zelma, Aubusson, Achat, Belmondo, Indigo and Capelle Desperez as cultivars that had the smallest differences in two or more analised traits.

10. POPIS TABLICA

Broj	Naziv tablice	Stranica
Tablica 1a	Popis i vrijednosti agronomskih svojstava hrvatskih i austrijskih kultivara ostvarenih u obje godine pokusa	10
Tablica 1b	Popis i vrijednosti agronomskih svojstava mađarskih i francuskih kultivara ostvarenih u obje godine pokusa	11
Tablica 2a	Razlike agronomskih svojstava hrvatskih i austrijskih kultivara u pokusnim godinama 2013./2014. i 2014./2015.	12
Tablica 2b	Razlike agronomskih svojstava mađarskih i francuskih kultivara u pokusnim godinama 2013./2014. i 2014./2015.	13
Tablica 3	Srednje mjesečne temperature zraka (°C) i mjesečna količina oborina (mm) za prvu godinu pokusa (2013./2014.) i višegodišnji prosjek (1961.-1990.)	14
Tablica 4	Srednje mjesečne temperature zraka (°C) i mjesečna količina oborina (mm) za drugu godinu pokusa (2014./2015.) i višegodišnji prosjek (1961.-1990.)	15
Tablica 5	Opisna statistika visine biljke u 2013./2014. godini	18
Tablica 6	Opisna statistika visine biljke u 2014./2015. godini	19
Tablica 7	Opisna statistika broja dana do klasanja u 2013./2014. godini	20
Tablica 8	Opisna statistika broja dana do klasanja u 2014./2015. godini	20
Tablica 9	Opisna statistika prinosa u 2013./2014. godini	21
Tablica 10	Opisna statistika prinosa u 2014./2015. godini	22
Tablica 11	Latentni korijeni, postotci opisani pojedinim glavnim komponentama i kumulativni postotci od ukupne varijance objašnjeni glavnim komponentama u godini 2013./2014.	23
Tablica 12	Djelomični doprinos varijabli glavnim komponentama izražen u postotcima za 2013./2014. godinu	24
Tablica 13	Latentni korijeni, postotci opisani pojedinim glavnim komponentama i kumulativni postotci od ukupne varijance objašnjeni glavnim komponentama u godini 2014./2015.	26
Tablica 14	Matrica opterećenja glavnih komponenata u godini 2014./2015.	26
Tablica 15	Latentni korijeni, postotci opisani pojedinim glavnim komponentama i kumulativni postotci od ukupne varijance razlika	28

svojstava objašnjenih glavnim komponentama
Tablica 16 Djelomični doprinos varijabli razlika agronomskih svojstava glavnim komponentama 28

11. POPIS GRAFIKONA

Broj	Naziv grafikona	Stranica
Grafikon 1	Walterov dijagram klime za razdoblje od rujna 2013. do srpnja 2015.	16
Grafikon 2	Scree plot dijagram latentnih korijena glavnih komponenti u 2013./2014. godini	23
Grafikon 3	Biplot dijagram PCA za 2013./2014. godinu	24
Grafikon 4	Biplot dijagram PCA za 2014./2015. godinu	27
Grafikon 5	Biplot dijagram PCA za razlike agronomskih svojstava u dvije godine pokusa	29

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište Josipa Jurja Strossmayera u Osijeku **Diplomski rad**

Fakultet agrobiotehničkih znanosti u Osijeku

Sveučilišni diplomski studij, smjer Oplemenjivanje bilja i sjemenarstvo

PCA ANALIZA UTJECAJA VREMENSKIH PRILIKA NA AGRONOMSKA SVOJSTVA PŠENICE

Ivan-Ante Lukačević

Sažetak: Većina je agronomskih svojstava kvantitativne prirode i na njih okolina ima velik utjecaj, a kombinacije gena otpornosti i adaptabilnosti stvaraju genotipove koji posjeduju mehanizme za ostvarivanje stalnih prinosa pod stresnim uvjetima okoline. Broj agronomskih svojstava pšenice je velik, a njihov međusobni odnos često je složen te se multivarijatne metode statističke analize kao što je analiza glavnih komponenata (PCA) koriste za redukciju podataka i isticanje najznačajnijih varijabli koje su utjecale na varijabilnost uzorka. Cilj ovog istraživanja bio je ispitati utjecaj vremenskih prilika na agronomska svojstva pšenica i grupiranje ispitivanih sorata s obzirom na promjenu vrijednosti agronomskog svojstva između godina primjenom PCA analize. U analizu je uključeno ukupno 40 kultivara porijeklom iz Austrije, Francuske, Hrvatske i Mađarske koji su sijani na pokusnim parcelama u 2013./2014. i 2014./2015. pokusnoj godini. Ispitivana su agronomska svojstva visine biljke, broja dana do klasanja i prinosa. PCA analiza u obje godine pokusa pokazala je sličnosti u korelacijama između agronomskih svojstava i grupiranja kultivara na koje je ponajviše utjecala visina biljke. Istaknuti su kultivari s visokim prinosima, niskim stabljikama i malim brojem dana do klasanja u obje godine pokusa. PCA analiza razlika agronomskih svojstava istakla je kultivare koji su imali najmanje razlike za dva ili više ispitivanih agronomskih svojstava u cijelom uzorku.

Diplomski rad izrađen pri: Fakultet agrobiotehničkih znanosti Osijek

Mentor: izv. prof. dr. sc. Sonja Petrović

Broj stranica: 44

Broj grafikona: 5

Broj tablica: 16

Broj literaturnih navoda: 51

Broj priloga:

Jezik izvornika: hrvatski

Ključne riječi: PCA/agronomska svojstva/pšenica/vremenske prilike/poljoprivredni pokusi

Datum obrane:

Stručno povjerenstvo za obranu:

1. izv. prof. dr. sc. Andrijana Rebekić, predsjednik

2. izv. prof. dr. sc. Sonja Petrović, mentor

3. prof. dr. sc. Sonja Vila, član

Rad je pohranjen u: Knjižnica Fakulteta agrobiotehničkih znanosti u Osijeku, Sveučilištu u Osijeku, Kralja Petra Svačića 1d

BASIC DOCUMENTATION CARD

Josip Juraj Strossmayer University of Osijek **Graduate thesis**

Faculty of Agrobiotechnical sciences in Osijek

University Graduate Studies, Plant breeding and seed production

PCA ANALYSIS OF THE EFFECT OF WEATHER CONDITIONS ON AGRONOMIC TRAITS IN WHEAT

Ivan-Ante Lukačević

Abstract: Most of agronomic traits are quantitative in their nature, so environment plays a big role in their expression. Combinations of different stress resistance genes and genes involved in adaptation mechanisms in plants are the main reason for developing genotypes that have ability to maintain constant yields under stress conditions on field. Because of the big number of agronomic traits in wheat and its complex correlations, multivariate statistycal analysis like principal component analysis (PCA) are used for data reduction and emphasis of variables that contributed the most in total variability of the sample. The main goal of this analysis is to explore the influence of the environmental factors on agronomic traits of wheat and grouping of the cultivars based on the change of agronomic traits in two years of experiment using PCA. Analysis included 40 cultivars from Austria, France, Croatia and Hungary. They were sown on experimental fields in seasons 2013./2014. and 2014./2015. Analised agronomic traits in this paper were plant height, days to heading and yield. PCA from both years of experiment showed similarity in correlations between agronomic traits and grouping of cultivars which was mostly influenced by plant height. Analysis highlighted cultivars that stand out in aspect of relatively big yields, low plant height and small number of days to heading in both years. PCA analysis of changes in agronomic traits pointed cultivars that had the smallest differences in two or more analised traits.

Thesis performed at: Faculty of Agrobiotechnical sciences in Osijek

Mentor: izv. prof. dr. sc. Sonja Petrović

Number of pages: 44

Number of figures: 5

Number of tables: 16

Number of references: 51

Number of appendices:

Original in: Croatian

Key words: PCA/agronomic traits/wheat/weather conditions/field experiments

Thesis defended on date:

Reviewers:

1. prof. dr. sc. Andrijana Rebekić, chairman

2. prof. dr. sc. Sonja Petrović, mentor

3. prof. dr. sc. Sonja Vila, member

Thesis deposited at: Library, Faculty of agrobiotechnological sciences in Osijek, University in Osijek, Kralja Petra Svačića 1d