Adaptibilnost hibrida kukuruza u različitim megaokolinama

Radan, Zvonko

Doctoral thesis / Disertacija

2016

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:151:356201

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

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

Image not found or type unknown

Obrazac broj 10. Tehnički opis i struktura doktorske disertacije kao monografije

REPUBLIKA HRVATSKA
SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA
U OSIJEKU

POLJOPRIVREDNI FAKULTET U OSIJEKU

Zvonko Radan, dipl. ing.

ADAPTABILNOST HIBRIDA KUKURUZA U RAZLIČITIM MEGAOKOLINAMA

DOKTORSKA DISERTACIJA

Osijek, 2016.

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

Zvonko Radan, dipl. ing.

ADAPTABILNOST HIBRIDA KUKURUZA U RAZLIČITIM MEGAOKOLINAMA

DOKTORSKA DISERTACIJA

Osijek, 2016.

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

Zvonko Radan, dipl. ing.

ADAPTABILNOST HIBRIDA KUKURUZA U RAZLIČITIM MEGAOKOLINAMA

- Doktorska disertacija -

Mentor: **Prof. dr. sc. Vlado Guberac, Poljoprivredni fakultet u Osijeku**

Povjerenstvo za ocjenu:

1. **Prof. dr. sc. Sonja Marić, Poljoprivredni fakultet u Osijeku, predsjednica**
2. **Prof. dr. sc. Vlado Guberac, Poljoprivredni fakultet u Osijeku, član**
3. **Doc. dr. sc. Antun Jambrović, Poljoprivredni institut Osijek, član**
4. **Doc. dr. sc. Sonja Petrović, Poljoprivredni fakultet u Osijeku, član**
5. **Prof. dr. sc. Zvonimir Zdunić, Poljoprivredni institut Osijek, član**

Osijek, 2016.

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

Zvonko Radan, dipl. ing.

ADAPTABILNOST HIBRIDA KUKURUZA U RAZLIČITIM MEGAOKOLINAMA

- Doktorska disertacija -

Mentor: **Prof. dr. sc. Vlado Guberac, Poljoprivredni fakultet u Osijeku**

Povjerenstvo za ocjenu:

1. **Prof. dr. sc. Sonja Marić, Poljoprivredni fakultet u Osijeku, predsjednica**
2. **Prof. dr. sc. Vlado Guberac, Poljoprivredni fakultet u Osijeku, član**
3. **Doc. dr. sc. Antun Jambrović, Poljoprivredni institut Osijek, član**
4. **Doc. dr. sc. Sonja Petrović, Poljoprivredni fakultet u Osijeku, član**
5. **Prof. dr. sc. Zvonimir Zdunić, Poljoprivredni institut Osijek, član**

Osijek, 2016.

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište Josipa Jurja Strossmayera u Osijeku

Doktorska disertacija

Poljoprivredni fakultet u Osijeku
Poslijediplomski sveučilišni (doktorski) studij: Poljoprivredne znanosti
Smjer: Oplemenjivanje bilja i sjemenarstvo

UDK: 633.15.631.526.325|57.2
Znanstveno područje: Biotehničke znanosti
Znanstveno polje: Poljoprivreda
Grana: Bilinogojstvo

Adaptibilnost hibrida kukuruza u različitim megaokolinama

Zvonko Radan, dipl. ing.

Disertacija je izrađena na Poljoprivrednom fakultetu Sveučilišta Josipa Jurja Strossmayera u Osijeku
Mentor: Prof. dr. sc. Vlado Guberac

Sažetak

Tijekom 2010. i 2011. godine testirana su 22 hibrida kukuruza na 2 lokacije u Hrvatskoj i na 4 lokacije (sa 2 roka sjetve) u Turskoj. Pokusi su bili posijani u 2 ponavljanja, po slučajnom bloknom rasporedu. Analizom varijance ustanovljeni su izvori variranja. Dvofaktorijelnom i trofaktorijelnom ANOV-om kao statistički značajan izvor variranja potvrđeni su i okoline i hibridi. Interakcija hibrida i okoline (GxE), bila je statistički vrlo značajna, osim u jednom slučaju. Statistički vrlo značajna interakcija bila je i između okolina i godina (ExY). Kod interakcija hibrida i okolina (GxL), kao i kod interakcije hibrid x godina (GxY) nije ostvarena statistička značajnost, dok je interakcija hibrida, okolina i godina (GxLxY) bila statistički značajna uz $P<0,05$. Procjenjena su 2 parametra stabilnosti – koeficijent regresije i varijanca odstupanja od regresije, za hibride i okoline. Isto tako, Pattern analizom napravljeno je grupiranje hibrida i okolina. Pet hibrida (pod brojevima 2, 3, 17, 21 i 22) primjenom obje metode svrstani su u skupinu visoko prinosnih hibrida, sa međusobno vrlo sličnim reakcijama po pitanju prinosa, kroz godine i okoline. Stoga možemo reći da su korištenjem parametara stabilnosti i Pattern analizom, kod grupiranja hibrida, dobiveni praktično vrlo slični rezultati. Prema parametrima stabilnosti jedina stabilna okolina koju možemo izdvojiti je Adana, u 2. sjetvi, u obje godine. Najveći broj okolina ne možemo jednostavno svrstati u neku od skupina, zbog neujednačenih vrijednosti ova dva parametra. Grupiranje okolina pokazuje nam postojanje 2 megaokoline. To su Hrvatska i Turska – generalno, bez obzira na rok sjetve. Kada bi interpretirali rezultate godinu po godinu, za pojedine podregije (posebno za Hrvatsku zbog dvije klimatski potpuno različite godine u istraživanju), ovo svrstavanje u megaokoline ne bi bilo tako jasno. To nam govori da kod proučavanja i identificiranja megaokolina trebamo podatke iz što većeg broja godina. Zbog podudarnosti i ponovljivosti dobijenih rezultata sa pojedinih lokacija u Turskoj (iz 1. i 2. sjetve), moguće je na pojedinim lokacijama ne sijati ponovo hibride u 2. sjetvi već u testiranje uvesti i dodatne lokacije, bez povećanja financijskih troškova. Ovi rezultati sa stanovišta praktičnog oplemenjivanje značajni su nam jer nam otkrivaju kako adaptabilnost hibrida kukuruza za zemljopisno bliže regije, tako i za regije koje su međusobno vrlo udaljene i prostorno diskontinuirane, kao što su Hrvatska i Turska.

Broj stranica: 115
Broj slika: 19
Broj tablica: 48
Broj literaturnih navoda: 101
Jezik izvornika: hrvatski

Ključne riječi: kukuruz, hibridi, megaokoline.

Datum obrane: 08. ožujka 2016.

Povjerenstvo za obranu:

1. **Prof. dr. sc. Sonja Marić, Poljoprivredni fakultet u Osijeku, predsjednica**
2. **Prof. dr. sc. Vlado Guberac, Poljoprivredni fakultet u Osijeku, član**
3. **Doc. dr. sc. Antun Jambrović, Poljoprivredni institut Osijek, član**
4. **Doc. dr. sc. Sonja Petrović, Poljoprivredni fakultet u Osijeku, član**
5. **Prof. dr. sc. Zvonimir Zdunić, Poljoprivredni institut Osijek, član**

Disertacija je pohranjena u:
Sveučilište Josipa Jurja Strossmayera u Osijeku.

BASIC DOCUMENTATION CARD

University of Josip Juraj Strossmayer in Osijek

PhD thesis

Faculty of Agriculture in Osijek
Postgraduate university study: Agricultural sciences
Course: Plant breeding and seed science

UDK: 633.15.631.526.325|57.2
Scientific Area: Biotechnical Sciences
Scientific Field: Agriculture
Branch: Plant production

Adaptibility Corn Hybrids in Different Mega-environments

Zvonko Radan, dipl. ing.

Thesis performed at Faculty of Agriculture in Osijek, University of Josip Juraj Strossmayer in Osijek
Supervisor: Prof. dr. sc. Vlado Guberac

Abstract
Total of 22 maize hybrids were tested in 2010 and 2011 at two locations in Croatia and four locations (with two different planting times) in Turkey. Trials were set in two replications with randomized complete block design. Sources of variation were determined with analysis of variance. Combined (two-way and three way factorial) ANOVA showed environments and genotypes as statistically significant sources of variation. Genotype and environment interaction (G×E) was statistically very significant, except at one occasion. Combination of locations and years (L×Y) showed statistically very significant interaction, interactions between genotypes and locations (G×L) and between genotypes and years (G×Y) were not statistically significant, while interaction between genotypes, locations and years (G×L×Y) showed statistical significance at $P<0.05$ probability level. Two stability parameters (regression coefficient and regression deviation variance) were estimated for hybrids and locations. Also, Pattern analysis was used for grouping hybrids and environments. Using both stability and Pattern analysis five hybrids (denominated as 2, 3, 17, 21, 22) were grouped in high yielding hybrids, with very similar yield performance across years and locations. Therefore, in order to group hybrids very similar results were obtained by using stability parameters and Pattern analysis. Stability parameters point out only one stable location – Adana, second planting, in both years. Largest number of locations cannot be simply put into groups due to uneven values of stability parameters. Grouping of environments showed two mega-environments (Croatia and Turkey in general, regardless of the planting time). Grouping in mega-environments would not be so transparent (especially for Croatia with two completely different research years in terms of weather conditions), if the results were interpreted year by year for certain sub-regions. That information emphasizes the need for multiple year data in research and identification of mega-environments. Due to compatible and repeatable data from certain locations in Turkey (from first and second planting), it is possible to avoid second planting of the same hybrids at some locations and instead test more locations without cost increase. From practical breeding perspective results from this thesis are important for adaptability assessment of maize hybrids, especially for geographically distant regions, such as Croatia and Turkey.

Number of pages: **115**
Number of figures: **19**
Number of tables: **48**
Number of references: **101**
Original in: croatian

Key words: corn, hybrids, mega-environments.

Date of the thesis defense: March 8th, 2016.

Reviewers:

1. **Prof. dr. sc. Sonja Marić, Faculty of Agriculture in Osijek, president**
2. **Prof. dr. sc. Vlado Guberac, Faculty of Agriculture in Osijek, member**
3. **Doc. dr. sc. Antun Jambrović, Institut of Agriculture Osijek, member**
4. **Doc. dr. sc. Sonja Petrović, Faculty of Agriculture in Osijek, member**
5. **Prof. dr. sc. Zvonimir Zdunić, Institut of Agriculture Osijek, member**

Thesis deposited in:
University of Josip Juraj Strossmayer in Osijek.

KAZALO

1.	UVOD	1
1.1.	Pregled literature	3
1.1.1.	Homogene adaptacijske regije – megaokoline	3
1.1.2.	Interakcija genotip x okolina	9
1.1.3.	Parametri stabilnosti genotipova i lokacija	13
1.1.4.	Cluster i Pattern analiza dobivenih podataka	18
1.2.	Ciljevi istraživanja	23
2.	MATERIJAL I METODE RADA	24
2.1.	Poljski pokusi	24
2.1.1	Zemljopisna pozicija lokacija za pokuse, u Hrvatskoj i Turskoj	34
2.2.	Agroekološki uvjeti proizvodnje u 2010. i 2011. godini, u Hrvatskoj i Turskoj	35
2.3.	Metode biometričke analize	41
2.3.1.	Dvofaktorijelni i trofaktorijelni model ANOVA-e za okoline i genotipove	42
2.3.2.	Koeficijent regresije (b_i)	43
2.3.3.	Varijanca odstupanja od regresije (s^2_{di})	43
2.3.4.	Cluster i Pattern analiza	44
3.	REZULTATI ISTRAŽIVANJA	46
4.	RASPRAVA	91
4.	ZAKLJUČCI	102
5.	LITERATURA	104
6.	SAŽETAK	113
7.	SUMMARY	114
8.	ŽIVOTOPIS	116

1. UVOD

Kukuruz (*Zea mays L.*) spada u porodicu *Poaceae*, tribus *Maydae,* genus *Zea.* Vrlo je važna poljoprivredna kultura, širokog područja rasprostranjenosti i velike genotipske raznolikosti. U svjetskoj proizvodnji kukuruz zauzima treće mjesto, iza pšenice i riže. Sije se u svijetu na oko 130 milijuna hektara. Najviše u SAD-u – 28 milijuna hektara, Kini – 19 milijuna hektara i Brazilu - 12,5 milijuna hektara. Najviši prosječni prinosi otvareni su u SAD-u, Francuskoj i Mađarskoj. Kukuruz ima najveći potencijal rodnosti od svih žitarica. Tako su u Hrvatskoj u pojedinim slučajevima postignuti prinosi veći i od 18 t/ha suhog zrna, kao i prinosi veći od 50 t/ha suhe tvari, što nije moguće postići niti sa jednom drugom kulturom. Gotovo svi dijelovi biljke kukuruza (osim korijena) mogu se iskoristiti – kao hrana ili industrijski prerađeni. Od kukuruza se u svijetu proizvodi više od 500 različitih proizvoda. U Hrvatskoj je uobičajeno korištenje kukuruza prvenstveno kao stočne hrane (suho zrno ili silaža), ali postoji znatan trend proširenja načina korištenja kukuruza, za više namjena – škrob, bio-plin, bio–gorivo, pivarska industrija itd. U ljudskoj prehrani koristi se kao komponenta hrane za dojenčad, kod pravljenja kruha (skupa sa pšeničnim brašnom) itd.

Proizvodnja kukuruza u Hrvatskoj, u zadnjem desetljeću kretala se u rasponu od 300 000 do 350 000 hektara, a godišnja proizvodnja suhog zrna u rasponu od 1,8 – 2,2 milijuna tona.

Kukuruz spada u one kulture koje pokazuju najveću razliku u dužini vegetacije. Upravo ta osobina omogućuje široki areal rasprostranjenja (od 55° szš do 40° jzš) i podrazumjeva vrlo različite uvjete uzgoja kojima se kukuruz uspjeva prilagoditi. To svojstvo prilagodljivosti možemo nazvati adaptabilnošću. Sa adaptabilnošću je usko povezana stabilnost, odnosno postojanost visine ostvarenih prinosa, kroz različite okoline i tijekom različitih godina ispitivanja (Zdunić, 1998.).

U oplemenjivanju svake kulture potrebno je napraviti optimalnu raspodjelu raspoloživog broja genotipova, pokusnih parcelica, ponavljanja, lokacija i godina (Jambrović, 2001.). Sve je to važno ne samo zbog ekonomskih troškova već i zbog toga da bi informacije o ispitivanim genotipovima bile na visokoj razini, vrlo pouzdane.

Predmet ovog istraživanja biti će prinos hibrida duže vegetacije (FAO skupine 500 i 600) – uzgajani u proizvodnim uvjetima Hrvatske i Turske, u proizvodnim godinama 2010. i 2011.

Broj lokacija koje Poljoprivredni institut Osijek godišnje koristi u Hrvatskoj je 5 – 10 i mijenja se od godine do godine, ovisno o broju hibrida koji se žele testirati i o njihovoj pripadnosti određenoj FAO skupini. U ovom istraživanju biti će zastupljene 2 lokacije u Hrvatskoj i 4 lokacije u Turskoj. U Turskoj se kukuruz uzgaja u potpuno drugačijim proizvodnim uvjetima – isključivo uz navodnjavanje. Isto tako, uobičajeno je da se kukuruz sije u 2 vremenska roka, odnosno u dvije sjetve – početkom svibnja i početkom srpnja (Ilker i sur, 2009.). Pokusi u Turskoj u sklopu ovog istraživanja biti će postavljeni na ukupno 8 okolina – 4 u prvoj i 4 u drugoj sjetvi. Na osnovi ovako velikih razlika u proizvodnim uvjetima te na osnovi razlika u zemljopisnom položaju i klimi Hrvatske i Turske možemo govoriti o pokusima u dvije megaokoline (Zdunić i sur., 2010.).

Braun (1996.) definira megaokolinu kao široko, ne nužno i granično područje, koje se nalazi na području više od jedne zemlje i koje ima slične biotske i abiotske stresove, vodni režim i zahtjeve potrošača.

Prinos zrna hibrida kukuruza je kvantitativno, kompleksno svojstvo, pod jakim utjecajem interakcije genotip x okolina. Veličina i struktura ove interakcije za svojstva od interesa imaju veliki utjecaj na oplemenjivačke programe kod kukuruza. Proučavanje strukture ove interakcije omogućiti će nam da identificiramo različite homogene adaptacijske regije (megaokoline) – Hrvatsku i Tursku, za proučavane hibride i da unutar tih megaokolina izdvojimo reprezentativne lokacije za svaku homogenu podregiju, što je od velikog značaja, kako za oplemenjivače, tako i za proizvođače jer će se moći orjentirati na proizvodnju hibrida adaptiranih uvjetima u pojedinim podregijama i tako ostvariti bolje proizvodne rezultate.

U sklopu statističke obrade napraviti će se i procjena stabilnosti proučavanih hibrida. Svi podaci bit će prvo obrađeni univarijatnom analizom varijance (ANOVA) uz t-test za ocjenu značajnosti razlika srednjih vrijednosti hibrida i okolina. Rastavljenjem dvofaktorijelne interakcije hibrid x okolina izačunat će se dva parametra stabilnosti svih hibrida: regresijski koeficijent i devijacija od regresije. Od multivarijatnih tehnika uporabit će se “pattern“ analiza, kao varijanta cluster analize kako bi se pojednostavio set podataka grupiranjem hibrida sa sličnom reakcijom na prinos kroz sve okoline sa sličnom strukturom odnosno razinom prinosa, kao i grupiranjem okolina kroz sve genotipove sa sličnom razinom prinosa (Byth i sur., 1976.).

1.1. Pregled literature

1.1.1. Homogene adaptacijske regije - megaokoline

Gauch i sur. (1997.) navode da kod pokusa na teritoriju većeg broja regija, zbog heterogenosti okolina i brojnosti različitih genotipova, različiti su genotipovi dominantni u različitim okolinama ili godinama. Zbog optimiziranja ostvarenih prinosa, budući da zbog različite interakcije genotipova i okoline, nema genotipa koji bi bio najbolji uvijek i svugdje, uzgojne regije moraju biti podijeljene u relativno homogene megaokoline i odgovarajući genotipovi moraju biti ciljani za svaku megaokolinu. Racionalna procjena megaokoline moguća je samo poslije specificiranja ključnih kriterija za njenu procjenu. To su 4 osnovna kriterija:

1. Krajnji selektivni cilj je procjena prinosa kao osnovnog kriterija za otkrivanje megaokoline,
2. Značajnost agronomskih i oplemenjivačkih pitanja tipa „što pobjeđuje gdje“,
3. Analiza interakcije genotipova i okoline,
4. Elastičnost pri obradi i tumačenju različitih struktura podataka.

Više je izraza koji korespondiraju sa nazivom „megaokolina“. To je prije svega interakcija genotip x okolina, zbog koje i imamo potrebu definirati i pronaći odgovarajuće megaokoline. Zatim, u tom smislu možemo govoriti i kada pokuse radimo da bi definirali određene zone adaptacije, kao npr: skupine zrenja kod kukuruza i soje. Stabilnost genotipova, uska i široka adaptabilnost i nasljednost ovih svojstava, su također svojstva koja moramo poznavati da bi mogli govoriti o megaokolinama. Naravno, podjela na nekoliko megaokolina može se izbjeći ako postoje genotipovi koji ostvaruju superioran prinos u nekoj široj regiji, što znači da nisu najbolji samo u nekoj okolini koju preferiraju, već i na onim okolinama koje su različite ili čak vrlo različite od onih najprinosnijih. Ipak, kako je već rečeno, kod većine kultivara kulturnog bilja to nije slučaj. Identifikacija megaokolina je značajna i iz nekoliko drugih razloga. Npr: zbog toga jer se na taj način teži pronalaženju genetskog materijala koji bi bio adaptabilan na tzv: marginalne okoline u kojima žive milijuni ljudi i gdje vrlo često nedostatak velikih količina hrane biva nadomješten uvozom iz visoko produktivnih regija. Ove okoline nazivamo marginalnim jer kod njih postoji stresni moment tijekom vegetacije koji uzrokuje veliku interakciju

genotip x okolina pa genotipovi favorizirani za visoko prinosne okoline u ovim okolinama daju vrlo niske prinose.

Annicchiarico (1992.) prema Gauch i sur. (1998.), je uspoređivao prinos lucerne (*Medicago sativa L.*) na tri megaokoline u Italiji, sa prosječnim prinosom u cijeloj toj regiji. Široka i statistički značajna razlika u ostvarenim prinosima bila je veća unutar pojedinih megaokolina nego u sveukupnom prosjeku, a i kultivar sa najvećim prinosom na svakoj megaokolini bio je različit od onoga koji je imao najveći prinos u prosjeku svih lokacija.

Rajaran i sur. (1988.) navode kako CIMMYT definira postojanje 12 megaokolina za uzgoj strnih žitarica (6 za jare, 3 za fakultativne i 3 za ozime). Glavni kriteriji za pripadnost pojedinoj megaokolini je količina oborina i temperatura. Najviše se strnih žitarica proizvede u ME 1 (uz navodnjavanje) – 36,1 % te u ME 11 (sa puno oborina i niskim temperaturama) – 15 % te u ME 4 (sa manje od 500 mm oborina i visokim temperaturama) – 14,6 % (tablica 1.).

CIMMYT (2009.) u svom DTMA projektu (The drought tolerant maize for Africa initiative) navodi i razliku između megaokolina i agroekoloških zona.

Megaokolina za kukuruz opisuje područje gdje različiti hibridi kukuruza pokazuju sličan poredak prema prinosu, zbog sličnih uzgojnih svojstava (padaline, temperature, tip tla). Megaokoline pokrivaju opsežnija područja uzgoja neke kulture nego agroekološke zone. Agroekološke zone za kukuruz pokrivaju specifične zemljopisne zone, često i u više zemalja, gdje se proučava interakcija genotipova i okoline, da bi se stvorio okvir za dalje aktivnosti u samoj poljoprivrednoj proizvodnji koji bi trebali biti primjereni takvim uvjetima i da bi takva prozvodnja dala što bolje rezultate.

Tablica 1. Megaokoline prema CIMMYT – ovom oplemenjivačkom programu.

Megaokolina (ME)	Vodni režim	Temperatura	Tip pšenice	Područje %	Proizvodnja (milijuni tona)
ME1 IR	Navodnjavanje	Umjereno	Jari	36,1	83
ME2 HR	Više od 500 mm	Umjereno	Jari	8,5	25
ME3 AS	Više od 500 mm – kiselo tlo	Umjereno	Jari	1,9	3
ME4 SA	Manje od 500 mm	Umjereno/toplo	Jari	14,6	20
ME5 TE	Navodnjavanje	Toplo	Jari	7,1	12
ME6 HL	Polu-sušno	Umjereno	Jari	6,2	13
ME7 IR	Navodnjavanje	Hladno	Fakultativno		
ME8 HR	Dovoljno oborina	Hladno	Fakultativno	10,0	23
ME9 SA	Polu-sušno	Hladno	Fakultativno		
ME10 IR	Navodnjavanje	Hladno	Ozimi		
ME11 HR	Dovoljno oborina	Hladno	Ozimi	15,0	30
ME12 SA	Polu-sušno	Hladno	Ozimi		

Setimela i sur. (2009.) pokušali su sumirati prve rezultate ovog DTMA projekta. Ovaj projekt pokrenut je 2007. i pokrivao je 13 zemalja sub-saharske Afrike. Među više ciljeva mogu se izdvojiti: definiranje potrebnog vremena za skupljanje elitnog genetskog materijala adaptiranog za uzgoj u tom području, testiranje takvih hibrida, prijava i ispitivanje hibrida u Nacionalnim komisijskim pokusima, u svakoj od zemalja, u skladu sa DUS-om i UPOV-om, registracija i proizvodnja sjemena hibrida i njihova distribucija malim farmerima koji imaju glavninu ove proizvodnje na svojim poljima, te strategija što i kako dalje raditi po svim ovim pitanjima. Pokazalo se da postoje brojni problemi: zakonska procedura o prometu sjemena vrlo je kompliciranа, stroga, često i nedosljedna, u pojedinim zemljama. Stoga sam postupak testiranja, otkrivanja dobrih hibrida, njihova

registracija i kasnija proizvodnja, traje predugo. Često prilikom registracije novih hibrida javni sektor u pojedinoj zemlji ima drugačije poglede oko kriterija priznavanja od privatnog sektora, što izaziva brojne prigovore i nesporazume, u puno slučajeva podaci o prinosima testiranih hibrida nisu bili pouzdani i slično.

Pollak i Corbett (1992.) su za područje Meksika i Centalne Amerike, koristeći podatke GIS-a (geographic information system) i CIMMYT-ove kriterije za megaokoline, napravili podjelu tog područja za uzgoj kukuruza na 10 podregija – 3 nizinske, 3 brdske, 2 subtropske i 2 prijelazne od subtropske ka brdskoj.

Balestre i sur. (2009.) su koristili multivarijatne tehnike obrade podataka kod procjene stabilnosti i adaptabilnosti 45 hibrida kukuruza na 3 megaokoline - 15 lokacija u sjeveroistočnom, centralnom i jugoistočnom Brazilu. Cilj je bio na tako velikom području identificirati i preporučiti hibride adaptirane za uzgoj u pojedinim regijama.

Ilker i sur. (2009.) su u Turskoj proučavali 17 hibrida na 4 lokacije, tijekom 2005., i 2006. godine. Rezultati pokazuju da pri izboru najboljih lokacija u testiranom području zbog redundantnih podataka istraživanje bi moglo biti smanjeno za jednu lokaciju. U istraživanju je rađena i procjena stabilnosti genotipova, i upravo ovaj kriterij omogućio je izdvajanje jednog eksperimentalnog hibrida kao najboljeg i preporučenog za dalji postupak registracije.

Kaya i sur. (2006.) su u svom istraživanju potvrdili postojanje 2 megaokoline za pšenicu u Turskoj, na području Centralne Anadolije. Isti autor na osnovu rezultata uspio je izdvojiti samo jednu lokaciju unutar tih megaokolina (Cumra) kao najreprezentativniju u izboru genotipova pšenice.

Dolatabad i sur. (2010.) proučavali su 14 hibrida kukuruza na jednoj megaokolini (koja obuhvaća 9 lokacija) i na 2 manje regije u Iranu sa željom da se identificiraju megaokoline i izdvoje adaptirani hibridi na osnovi njihove stabilnosti uroda na različitim lokacijama. Jasno je izdvojen hibrid OSSK 602 kao najprinosniji i najstabilniji.

Tadesse i sur. (2010.) radili su pokuse sa pšenicom na megaokolini tipa ME 2 – to je megaokolina koja ima više od 500 mm oborina tijekom vegetacije pšenice i jedna je od 12 tipova megaokolina koje je na globalnoj razini uspostavio CIMMYT. Najveći raspon ostvarenih prinosa bio je u Africi (0,69 - 9,60 t/ha) i Aziji (0,38 - 6,93 t/ha), dok je Europa imala najviši ostvareni prosjek prinosa – 4,39 t/ha. Korelacijska analiza pokazala je da su najbolje lokacije za predviđanje najboljih kultivara sa najvećom vjerojatnošću Marcos

Juarez u Argentini, Pergamino u Argentini, Izmir u Turskoj, Betlehem u Južnoj Africi, Sakha u Egiptu i Tassaout u Maroku.

Zdunić i sur (2010.) proučavali su 7 Os hibrida na 6 lokacija u megaokolinama Hrvatske i Turske. Budući da su to dvije vrlo velike i vrlo različite adaptacijske regije, bilo je potrebno istražiti specifičnost interakcija pojedinog hibrida kukuruza s lokacijama koje se nalaze u tim okolinama. Pokazalo se da postoje 2 skupine hibrida sa različitim reakcijama u dvije megaokoline.

Yuksel i Akcura (2012.) proveli su MET (multi environment trials) pokuse kod 24 kultivara ječma uzgajanih na 26 različitih okolina u Turskoj, u vremenu od 2004. do 2008. godine. Uspješno su identificirane 2 megaokoline – visoko prinosne (Eskisehir i Konya) i nisko prinosne (Afyon i Usak). Rezultati pokazuju postojanje značajne interakcije GxE i postojanje 2 megaokoline – Afričke i Azijske. Unutar obje megaokoline postoje međusobno slične podskupine. Pokazalo se da je Azijski tip okolina uzak i zatvoren, dok je sasvim drugačije kod Afričkog tipa koji je vrlo divergentan. Unutar obje okoline postoje različiti tipovi adaptacije genotipova.

Algarswamy i Chandra (1998.) su kod 12 genotipova sirka na 25 okolina pokušali identificirati i grupirati genotipove i okoline. Ti genotipovi bili su širokog zemljopisnog porijekla, različite genetske strukture, s 3 tipa foto-periodske osjetljivosti. Ocjenjivana je cvatnja, visina biljaka i prinos. Rezultati pokazuju postojanje značajne interakcije GxE i postojanje 2 megaokoline – Azijske i Afričke.

DeLacy i sur. (1994.) su proučavali dobivene rezultate iz 26 godišnjeg perioda (1964. - 1990.) u kojem su ispitivani kultivari jare pšenice, koristeći kao osnovni pokazatelj prinos zrna. Okoline su imale status megaokolina jer su pokusi postavljani u područjima koja su se međusobno značajno razlikovala po klimatskim karakteristikama te po faktorima i nivoima stresnih situacija. Identificirane su dvije najvažnije megaokoline za jaru pšenicu: Europska i Azijska. Uočeno je da megaokolinska klasifikacija ne može objasniti niti dati jasnu povezanost između lokacija. Preporučuje se oplemenjivanje, odnosno stvaranje kultivara sa germplazmom koja je široko adaptabilna i u koju je ugrađena otpornost na specifične stresne situacije.

Windhausen i sur. (2012.) iznose rezultate grupiranja ciljanih okolina prema rezultatima CIMMYT-ovog programa testiranja hibrida kukuruza u Africi, od 2001. – 2009. godine. Osnovni cilj bio je pronaći stabilne i visoko prinosne hibride za svaku od različitih ciljanih homogenih podskupina regija. Istraživanje je provedeno u istočnoj i

južnoj Africi, sa 448 hibrida kukuruza, u 513 pokusa, u 17 država. Pokusi su bili grupirani prema 5 kriterija: klima, nadmorska visina, zemljopisni položaj, zemlja i razina prinosa. Između prva 4 kriterija i genotipova nije utvrđena značajna interakcija, dok je to bio slučaj kod razlike razine prinosa između visoko i nisko prinosnih lokacija. Korištenjem ove strategije dobiveni su rezultati najmanje 10 % bolji nego kad su korišteni samo podaci o prinosu na nisko i visoko prinosnim okolinama (subregijama) i omogućeno je lakše prepoznavanje hibrida adaptiranih za uzgoj u obje ove subregije.

Braun i sur. (2010.) u svom djelu knjige M. Reynoldsa, raspravljaju kako pokušati doskočiti globalnim promjenama klime u području otpornosti biljaka na takve uvjete. Sugeriraju da je već kroz dugogodišnji oplemenjivački rad internacionalnih oplemenjivačkih kompanija, međunarodnih znanstvenih istraživačkih centara i nacionalnih programa oplemenjivanja, dobivena germplazma široke adaptabilnosti, posebno kada govorimo o ciljanim podskupinama okolina ili o megaokolinama. Sugeriraju da se korištenjem podataka CIMMYT-a i Internacionalnog instituta za rižu (IRRI), uz slobodan pristup germplazmi, mogu pronaći kultivari riže i kukuruza sposobni izdržati rastuću varijabilnost uzgojnih uvjeta, do koje dolazi zbog sve većih klimatskih promjena. Oplemenjivanje na što širu adaptabilnost postaje osnovni izazov i pokušaj odgovora na globalnu promjenu klime.

Barrero Farfan i sur. (2013.) analizirali su trend kretanja prinosa, kroz 11 godina, da bi identificirali koji značajni faktor može dovesti do napretka u oplemenjivanju i testiranju novih hibrida kukuruza. U istraživanju je bilo ukupno 107 hibrida, kroz 11 godina, na 16 lokacija. Napravljena je trosmjerna analiza interakcija, koja uključuje hibride, lokacije i godine i njihovu interakciju. Pokazalo se da se cijeli Texas može podijeliti na dvije megaokoline – The High Plains kao jedna, i ostatak države, kao druga megaokolina. Analizom pojedinih parametara (visina biljke, visina klipa, otpornost na polijeganje, broj dana do metličanja, itd.) pokazalo se da je potrebno imati u osnovi različiti pristup kod oplemenjivanja, kao i kod testiranja hibrida, za ove dvije različite megaokoline u Texasu. Isto tako, po pitanju pouzdanosti procjene genetičkog potencijala testiranih hibrida, dovoljno je bilo testirati ih u dva ponavljanja i u dvije godine. Iznenađujuće je da nije bilo značajne genetske dobiti po pitanju prinosa, 11 godina unazad. Osim toga, neki od starijih hibrida pokazali su veći genetski potencijal od onih koji se sada umnožavaju i prodaju na tržištu.

Wedderburn (1993.) navodi da je izravna posljedica postavljanja megaokolinskih pokusa u organizaciji CIMMYT-a to da 13 % kukuruza posijanih u tropskom pojasu u sebi ima germplazmu koja je testirana u takvim pokusima i podrijetlom pripada CIMMYT-u. Kod izbora lokacija za multilokacijska testiranja uglavnom su glavni kriteriji određeni biotski ili abiotski stres, ili prinos. Svaka megaokolina može biti podijeljena na subregije, ali to ne umanjuje potrebu za multilokacijama jer je variranje uvjeta u jednoj subregiji, od godine do godine vrlo značajno. U novije vrijeme multilokacijski pokusi sve više stavljaju fokus na pojedina svojstva od interesa – različite otpornosti – na insekte, bolesti, sušu, itd. Megaokolinski pokusi svakako unapređuju i stabilnost izabranih hibrida za pojedinu lokaciju.

Babić i sur. (2008.), Mitrović i sur (2012.), navode da je postavljanje multiokolinskih pokusa esencijalno, osnovno, za proces oplemenjivanja.

1.1.2. Interakcija genotip x okolina

Genotip x okolina interakcija definira se kao različita ekspresija genotipa kroz okoline (Fox i sur., 1997.). Stoga nam srednja vrijednost prinosa zrna kroz okoline predstavlja odgovarajući pokazatelj genotipskih vrijednosti samo u pokusima gdje interakcija GxE nije značajna. Do genotipskih procjena za različite okoline dolazi se korištenjem različitih pokusnih dizajna i metoda analiza.

GxE interakcija je najvažniji faktor koji u programe oplemenjivanja uključuje:

1. Selekciju za široku ili specifičnu adaptaciju,
2. Izbor lokacije za selekciju,
3. Selekciju u ranim generacijama u stresnim i ne-stresnim okolinama,
4. Prelazak sa višeokolinskih pokusa sa većim brojem genotipova na ispitivanje malog broja linija intenzivnim testiranjem.

Godina i okolina nisu nezavisni faktori. Npr: produženi period bez kiše ima različite posljedice na pjeskovitom nego na težem tlu, a od velikog su značaja i promjene na istoj lokaciji u različitim godinama. Svi ovi efekti sadržani su u interakcijskim reakcijama. Najvažnije je koliko se vrijednosti genotipova mijenjaju kroz okoline. Jedan okolinski faktor nema isti utjecaj kao neki drugi. Interakcija GxL (genotip x lokacija) pokazuje rezultatske promjene genotipskih vrijednosti od lokacije do lokacije, u toj godini. Interakcija genotip x godina (GxY) pokazuje razlike u genotipskoj vrijednosti između

godina na svim lokacijama, dok interakcija GxExL pokazuje razlike genotipova kroz promjene od lokacije do lokacije, zavisno od godine, ili promjene genotipova koje su uvjetovane godišnjim promjenama pojedinih lokacija prema svima ostalima (Talbot, 1997.).

Falconer i MacKay (1996.) navodi da je postojanje interakcije između genotipa i okoline „rijetko važna komplikacija“ koja se često može zanemariti kod postavljanja poljskih pokusa. Najjednostavnija bi bila situacija kada ne bi bilo interakcije između genotipskih vrijednosti i okolinskih promjena jer bi tako bilo najlakše izabrati najbolje genotipove, po pravilu da je najbolji genotip na jednoj okolini najbolji na svim okolinama. No, takve situacije u praksi nemamo, već se susrećemo sa specifičnim razlikama među okolinama, što uvjetuje različitu reakciju genotipova. To znači da upravo ova heterogenost okolina uvjetuje drugačiji poredak istih genotipova u različitim okolinama, odnosno jedan dio interakcije genotip x okolina može se objasniti različitom osjetljivošću hibrida na različite uzgojne uvjete na okolinama.

Hallauer i sur. (1981.) interakciju genotipa i okoline (GE interakcija) definiraju kao različito ponašanje genotipova u različitim okolinama. Postojanje ove interakcije zahtijeva od oplemenjivača da procjeni genotipove u više različitih okolina i godina kako bi dobio višestruko rangiranje ispitivanih genotipova. Odnos komponenti interakcije GxE je varijabilan, od kulture do kulture, a zavisi i od okolina koje su uključene u ispitivanje. Ipak, vrijedi pravilo da ako je interakcija GxY veća od interakcije GxL, onda je interakcija GxYxL veća od obje. Nešto drugačiji je odnos kod ispitivanja koja se provode u više zemalja, sa većim brojem ispitivanih kultivara i više pokusa kroz više godina gdje su razlike u prinosu genotipova manje, tako da je interakcija GxY manja, odnosno kod ispitivanja na većem zemljopisnom području faktori vezani za lokaciju dobivaju na značenju (Riggs, 1986., prema Talbot, 1997.). Radilo se o ispitivanju 30 varijeteta ozimog ječma, na 13 lokacija, u 9 zemalja, u 3 godine, a rezultati su uspoređeni sa ispitivanjima tih istih kultivara u Engleskoj.

Zdunić i sur. (2010.) proučavali su strukturu interakcije genotip x okolina za prinos zrna Os hibrida kukuruza u megaokolinama Hrvatske i Turske. Ispitivano je 7 hibrida, na 6 lokacija. Pokazalo se da postoje 2 skupine hibrida sa različitim reakcijama u dvije megaokoline. Četiri hibrida (OSSK 515, OSSK 602, OSSK 713 i OSSK 644) imali su konstantno visoke vrijednosti prinosa kroz sve okoline. Preostala 3 hibrida nisu imala dosljednu reakciju kroz skupine lokacija.

Kroonenberg i Basford (1989.) navode kako je postojanje značajne interakcije genotip x okolina razlog usmjeravanja genetičke analize u nekoliko smjerova i otežava procjenu statističkih i genetičkih parametara, te čini složenim i problematičnim određivanje strategije za testiranje novih hibrida. Oni su proveli istraživanje u Australiji, na 58 linija soje, na 4 lokacije, u 2 ponavljanja, kroz 2 godine. Napravljena je trosmjerna analiza komponenti interakcije GxE. Rezultati su omogućili grupiranje genotipova sa sličnim karakteristikama.

Fox i Rosielle (1982.) navode da odnos između lokacija ima vrlo veliki utjecaj u oplemenjivanju svih biljnih vrsta, i to uvijek kad je GxE interakcija najveća komponenta varijacije. Najveći problem oplemenjivača bilja nije statistički značajna GxE interakcija već promjenjivi redoslijed testiranih kultivara u različitim okolinama. U svom su radu analizirali 51 pokus pšenice u zapadnom dijelu Australije.

Chapman i sur. (1997.) proučavali su nekoliko kasnih tropskih populacija kukuruza (La Posta Sequia, Pool 26 Sequia i Tuxpeno Sequia), selektiranih rekurentnom selekcijom kroz 6 - 8 godina, prema njihovoj otpornosti na sušu i prema potencijalu rodnosti, u 10 pokusa. Analiza varijance pokazala je da 97,9 % MS otpada na okoline (E), a ostatak MS interakcije GxE bio je gotovo 3 puta veći nego kod genotipova (G) samih. Linearnom regresijom objašnjava se 37 % interakcije GxE. Unutar svake populacije unaprijeđena je široka adaptabilnost (veći prosječni prinos) i ostvaren je skok (kroz cikluse selekcije) iz ne-tolerantne na sušu skupine genotipova, u skupinu tolerantnih na sušu.

Yuksel i Akcura (2012.) u pokusima sa ječmom, analizom varijance, ustanovili su da su okoline dominantni izvor varijacije, odnosno 86,9 % MS pripada okolinama, a zatim slijedi interakcija GxE.

Lin i Butler (1988.) navode da je veličina i stuktura interakcije GxE važna za oplemenjivački proces kod kukuruza. Istraživanje strukture GxE interakcije može pomoći oplemenjivačima kod identifikacije različitih adaptacijskih regija i u izboru reprezentativnih lokacija za svaku homogenu podregiju, kao i u razvoju učinkovitijih postupaka multilokacijskih testiranja genotipova.

Setimela (1997.) je ispitivao 15 hibrida kukuruza u dvije godine i na tri lokacije, u Botsvani, ispitujući stabilnost genotipova i interakciju genotipa i okoline. Dobio je rezultate koji pokazuju da su lokacije u najvećoj mjeri utjecale na prinos zrna, u većoj mjeri od godina, odnosno sezona testiranja.

Cooper i DeLacy (1994.) ističu, da kada bi imali predvidivu interakciju GxE kroz više godina istraživanja, unutar nekog određenog područja, to bi bilo moguće iskoristiti u oplemenjivanju biljaka na taj način da bi se slične okoline grupirale u veće podregije, a da bi se moglo napraviti i grupiranje genotipova uske adaptabilnosti koji bi bili adaptirani na njih.

Allard i Bradshaw (1964.) ističu da je svaka okolina za sebe jedinstvena zbog specifičnog sklopa predvidljivih i nepredvidljivih faktora, te je važno poznavati reakciju genotipa na okolinske uvjete.

Kamutando i sur. (2013.) proučavali su interakciju GxE i stabilnost i adaptabilnost 58 novih hibrida kukuruza, na 5 lokacija u Zimbabveu. Utvrdili su statistički značajno variranje prinosa ispitivanih hibrida, kao i značajnu interakciju GxE.

Flores i sur. (1998.) koristili su čak 22 različite metode (parametrijske, neparametrijske i multivarijatne) za analizu interakcije genotip x okolina. Osnovni podaci na koje su primjenjene ove tehnike bili su 15 kultivara graha, testiranih na 12 lokacija i 11 kultivara graška, testiranih na 16 lokacija. Sve metode podjeljene su u tri skupine:

1. Metode uglavnom povezane sa razinom prinosa i pokazuju malu ili nikakvu korelaciju sa parametrima stabilnosti,
2. Metode koje simultano koriste prinos i stabilnost, za reduciranje interakcije GxE,
3. Metode koje mjere samo stabilnost.

Karimizadeh i sur. (2012.) proučavali su stupanj interakcije genotipa i okoline, kod durum pšenice, da bi otkrili superiorne genotipove adaptirane na testirane lokacije. Dvadeset sorata testirano je na 5 lokacija, u tri godine. Efekti godina i interakcije godina x lokacija bili su statistički značajni ali efekat lokacija nije bio statistički značajan. Trofaktorijelna ANOVA pokazala je da je interakcija GxLxY bila visoko statistički značajna. Klasteriranje napravljeno na bazi linearne regresije pokazuje jasnu podjelu na tri skupine genotipova. U konačnici, izdvojena su 2 genotipa (G 8 i G 13) koji su predloženi za priznavanje u Iranu, u regijama sa dovoljnim količinama vode tijekom vegetacije pšenice.

Bindraban i sur. (2006.) navode da zbog jake interakcije genotipova i okolinskih uvjeta, prilikom pravljenja strategije oplemenjivanja u budućnosti, moramo se rukovoditi jednim multidisciplinarnim pristupom, koji uz oplemenjivanje, u ovaj proces uključuje i fiziogiju, statistiku i druge znanosti koje mogu doprinijeti ubrzavanju postupka križanja, selekcije i testiranja.

Atlin i sur. (2000.) utvrdili su da u malim, ciljanim regijama, je moguće iskoristiti lokalnu adaptaciju za povećanje dobiti od selekcije. Kod pokusa na više lokacija i na znatno većem prostoru, istraživanje nam daje veću preciznost procjene genotipova. Korištenjem korelacijskog modela utvrđene su korelacije prinosa hibrida kukuruza i heritabilnost podataka regija i subregija, te genotipova. Ovakvi rezultati mogu nam pomoći kod ispitivanja kultivara s obzirom na širinu njihove adaptiranosti na različite uvjete.

1.1.3. Parametri stabilnosti genotipova i lokacija

Stabilnost i adaptabilnost genotipova i okolina je problem koji trajno zaokuplja oplemenjivače. Za opisivanje stabilnosti razvijene su mnoge metode. Neke se temelje na varijanci GxE interakcije, neke na regresiji ili varijanci odstupanja od regresije, na koeficijentu determinacije, ekovalenci, itd.

Becker (1981.) definira dva različita koncepta stabilnosti – biološki i agronomski. Biološki koncept pretpostavlja sposobnost genotipa da zadrži jednake vrijednosti ispitivanih svojstava u različitim okolinama. Ovaj koncept nije odgovarajući kada se radi o kvantitativnim svojstvima jer se takva svojstva nalaze pod znatnim utjecajem okoline, ali ima vrijednost kod svojstava koja su manje ovisna o okolini. Ovaj koncept naziva se i statični koncept (Leon, 1985.; prema Becker i Leon, 1988.). Parametar stabilnosti koji prezentira reakciju genotipova baziranu na ovom konceptu stabilnosti je koeficijent regresije (b_i).

U okviru statičnog koncepta, stabilnost može biti prikazana i koeficijentom varijabilnosti (CV, %), u kombinaciji sa prosječnim prinosom (Francis i Kannenberg, 1978.).

Na osnovi prosjeka prinosa i prosjeka CV svi genotipovi uključeni u ispitivanje dijele se u 4 skupine stabilnosti:

1. skupina: visoki prinos, niska varijabilnost,
2. skupina: visoki prinos, visoka varijabilnost,
3. skupina: niski prinos, niska varijabilnost,
4. skupina: niski prinos, visoka varijabilnost.

Najbolji su genotipovi u prvoj skupini, a najmanje poželjni su genotipovi u četvrtoj skupini.

Agronomski koncept pretpostavlja predvidivu reakciju genotipa na okolinske uvjete. Stabilan je onaj genotip koji ne odstupa značajno od prosječne reakcije na okolinu. Ova reakcija ne mora biti jednaka za sve ispitivane genotipove ali važno je da se procjena reakcije genotipa podudara sa stvarnom reakcijom. Ovaj tip stabilnosti naziva se dinamičnim i kada razmatramo prinos i druga kvantitativna svojstva govorimo samo o ovome tipu stabilnosti. Parametar stabilnosti povezan sa ovim konceptom stabilnosti je varijanca odstupanja od regresije (s^2_{di}).

Metodu linearne regresije (koeficijent linearne regresije b_i), za opis specifičnih reakcija genotipova na varijabilne okoline prvi su koristili Stringfield i Salter (1934.) prema Becker i Leon (1988.). Ova metoda ponovo je korištena kada su je Finlay i Wilkinson (1963.) počeli ponovo koristiti u analizi stabilnosti kod ječma. Oni su vršili ispitivanja tijekom tri godine, na tri lokacije. Kao nezavisnu varijablu koristili su indeks okoline (prosjek svih genotipova u određenoj okolini), a kao zavisnu varijablu prosječni prinos svakog genotipa. Prema njima, genotip sa vrijednošću b_i=1,00 ima prosječnu stabilnost, kod genotipova gdje je b_i veći od 1,00 radi se o ispod prosječnoj stabilnosti. Genotipovi gdje je b_i manji od 1,00 smatraju se iznad prosječno stabilnim.

Eberhart i Rusell (1966.) su osim koeficijenta regresije b_i koristili još i varijancu odstupanja od regresije (s^2_{di}). Oni su smatrali da idealan genotip mora imati što veći prosječni prinos, koeficijent regresije b_i=1,00 i varijancu odstupananja od regresije s^2_{di}=0,00. Da bismo mogli donositi vjerodostojne zaključke prema vrijednostima s^2_{di} potreban je što veći broj okolina, dok se kod regresijskog koeficijenta zaključci mogu donositi i na manjem broju ali vrlo različitih okolina. Oni navode da hibridi sa vrijednošću $b_i \geq 1{,}00$ imaju obično prosječne prinose manje od ukupnog prosjeka i smatraju da postoji pozitivna veza između prosječnog prinosa i regresijskog koeficijenta.

Wricke (1962.) je predložio ekovalencu (W_i) kao parametar stabilnosti, a ona se izračunava kao suma kvadrata GxE interakcije za svaki genotip na svim okolinama. Što je manji udio pojedinog genotipa u GxE interakciji time je veća njegova ekovalenca, a time i veća stabilnost genotipa. Brojna iskustva (Becker (1981.), Wricke i Weber (1980.), Kang i Miler (1984.), Zdunić (1998.)) su pokazala da postoji visoka podudarnost između dobivenih vrijednosti s^2_{di} i W_i pa nije potrebno raditi paralelan izračun ova oba pokazatelja stabilnosti u istom istraživanju.

Shukla (1972.) predlaže korištenje varijance stabilnosti (δ^2_i) kao jednog parametra stabilnosti. Do nje dolazimo tako da ukupnu sumu kvadrata podijelimo za svaki genotip posebno. Genotip je stabilan ako je varijanca genotipa jednaka okolinskoj varijanci.

Lin i Beans, (1991.) prema Hill, Becker i Tigerstedt (1998.) definiraju 4 tipa stabilnosti.

- Prvi tip je statični model određivanja stabilnosti, gdje jednostavno uspoređujemo varijancu genotipova kroz okoline.
- Drugi tip već pripada dinamičnom modelu procjene stabilnosti i koristi analizu interakcije genotip x okolina (GxE). Statistički parametri koji se koriste su varijanca stabilnosti i ekovalenca.
- Treći tip koristi kod procjene stabilnosti odstupanje od regresije, a statistički parametri koji se koriste su regresijski koeficijent i varijanca odstupanja od regresije.
- Četvrti tip stabilnosti koji koristi tzv: multiokolinske pokuse, na velikom zemljopisnom području, pomoću čijih rezultata možemo vršiti usporedbe između genotipova po lokacijama i godinama i definirati na taj način stabilne genotipove.

Najčešće se razlika, odnosno varijabilnost, između genotipova i lokacija objašnjava kao posljedica specifičnih klimatskih faktora ili specifičnog porijekla samih genotipova i može se kontrolirati selekcijom specifičnih genotipova adaptiranih na određena područja. Ovaj tip stabilnosti koji se procjenjuje prema vrijednosti sume kvadrata genotipova kroz okoline i godine oslobađa tzv. homeostatske mogućnosti genotipova i nezavisan je od regesijske analize i srednje vrijednosti prinosa genotipova.

Becker i Leon (1988.) su kod više kultura (pšenica, zob, ječam) istraživali vezu između stabilnosti proučavane kod jednogodišnjih i višegodišnjih rezultata, s više parametara. Oni smatraju da je regresijski pristup najčešće korištena metoda za procjenu stabilnosti. Zaključuju da se kod njihovih pokusa niti jedna procjena stabilnosti na temelju jednogodišnjih rezultata ne može koristiti, jer je genotip x godina interakcija bila značajno veća od interakcije genotip x okolina.

Isti autori su ukazali na slabu ponovljivost (repeatability) parametara stabilnosti jednog genotipa kroz više godina. Šimić i sur. (2000.) su u svom istraživanju provedenom tijekom dvije godine (1995. i 1996.) na 9+7=16 lokacija u Hrvatskoj ukazali i na slabu ponovljivost parametara stabilnosti okolina kroz godine, na jednoj lokaciji. Stoga je

potrebno uključiti u analizu i učinak godine i odrediti ulogu pojedinih interakcija između lokacije, genotipa i godine. Uspoređujući vrijednost varijance parametara stabilnosti na jednoj lokaciji kroz više godina omogućeno je uspoređivanje dobijenih vrijednosti po godinama na istoj lokaciji, a isto tako moguće je i grupiranje okolina i lokacija kako bi se uvidjela povezanost pojedinih kombinacija lokacija – godina.

Sneller i sur. (1997.) također su istraživali ponovljivost nekih parametara stabilnosti kod soje i zaključili da je njihova ponovljivost kroz godine i lokacije niska. To objašnjavaju time da su lokacije bile nedovoljno udaljene jedne od drugih i da je selekcijski materijal u istraživanju bio vrlo uske genetske osnove.

Zdunić (1998.) je proveo dvogodišnja istraživanja stabilnosti i adaptabilnosti prinosa F1 generacije križanaca dobivene LxT križanjem elitnih inbred linija kukuruza. Istraživanja su izvršena na ukupno 16 lokacija tijekom 1995. i 1996. godine. Procjenjeni parametri kojima se opisuje stabilnost i adaptabilnost prinosa – koeficijent regresije, varijanca odstupanja od regresije i ekovalenca, omogućili su grupiranje genotipova u skupine, s obzirom na visinu, stabilnost i adaptabilnost prinosa. U pojedinačnim godinama istraživanja kao i na razini obje godine utvrđen je vrlo visoki stupanj povezanosti između parametara varijance odstupanja od regresije i ekovalence. Ovo ukazuje na mogućnost korištenja manjeg broja parametara za određivanje stabilnosti i adaptabilnosti prinosa (npr. samo koeficijenta regresije i ekovalence), a da se pri tome ne umanji preciznost procjene.

Sikora (1973.) je koristio koeficijent regresije kao parametar stabilnosti za procjenu dva dvolinijska hibrida kukuruza Poljoprivrednog instituta Osijek. Kod oba hibrida dobio je vrijednost b_i>1,00 i zaključio je da su ovi hibridi primjereniji za uzgoj na visoko prinosnim okolinama.

Adeyemo i Fakorede (1990.) su istraživali stabilnost 21 topcross hibrida kukuruza, 7 sorti i 7 sortnih hibrida. Kada su koristili b_i i s^2_{di} kao neovisne parametre stabilnosti, pronašli su 26, odnosno 28 stabilnih genotipova, no kada su navedeni parametri korišteni zajedno, tada je otkriveno samo 20 stabilnih genotipova. Otkrivena je značajna korelacija između visine prinosa i koeficijenta regresije, ali nije pronađena značajna korelacija između b_i i s^2_{di}.

Vasilj i Milas (1984.) su pruočavali korelacijske veze između različitih parametara stabilnosti kukuruza i pšenice. Nisu ustanovili nikakve korelacije između prinosa i parametara stabilnosti, dok su između b_i, s^2_{di} i W_i dobili visoko značajne korelacije. Zbog

toga autori za procjenu stabilnosti i adaptabilnosti preporučuju korištenje parametra Wrickea (W_i), jer je računanje ovog parametra znatno jednostavnije od ostalih.

Ilker i sur. (2009.) su u Turskoj proučavali 17 hibrida na 4 lokacije, tijekom 2005. i 2006. godine. Rezultati pokazuju da pri izboru najboljih lokacija u testiranom području zbog redundantnih podataka istraživanje bi moglo biti smanjeno za jednu lokaciju.
U istraživanju je rađena i procjena stabilnosti genotipova, i upravo ovaj kriterij omogućio je izdvajanje jednog eksperimentalnog hibrida kao najboljeg i preporučenog za dalji postupak registracije.

Mitrović i sur. (2012.) analizirali su stabilnost i adaptabilnost 19 eksperimentalnih hibrida Instituta iz Novog Sada, na 12 lokacija u sjevernoj Srbiji, koristeći metodu GGE (Genotype and Genotype by Environment Interaction) biplot i AMMI (Aditive main effects and multiplicative interactions). Pokazalo se da postoji sukladnost u procjeni stabilnosti kod primjene ove dvije metode, i da se obje mogu uspješno koristiti sa jednakom pouzdanošću dobivenih rezultata.

Perkins i Jinks (1960.) navode da je kod analiza ostvarenih rezultata više-okolinskih pokusa tipična podjela na genotipove, okoline i njihovu interakciju. Ako je interakcija GxE značajna – linarna regresija može biti korištena za ispitivanje stabilnosti genotipova kroz lokacije.

Federer i Scully (1993.) navode da se pod pojmom „okolina“ podrazumjeva jedan pokus, na jednoj lokaciji, u jednoj godini. Faktori koji jednu okolinu čine bitno različitom od druge su npr: tip tla, gnojidba, sadržaj vode itd. Kada želimo preciznije definirati neku okolinu, obično govorimo koji je od tih faktora prisutan i u kojem obimu – optimalnom, niskom ili previsokom. Tako dolazimo do termina „lokacija“ koji se veže upravo za faktore po kojima se ta lokacija razlikuje od drugih te godine. Važno je i kako genotipovi reagiraju na okoline u kojima se uzgajaju. Tu postoje 4 tipa reakcije genotipova:

1. Tip S1, gdje dolaze genotipovi koji imaju ujednačeno loš i nizak prinos, bez obzira na poboljšanje uzgojnih uvjeta. To su genotipovi koji nisu za visoko prinosne okoline.
2. Tip S2, gdje dolaze genotipovi čiji je prosječni prinos nešto bolji i kojima prinos djelomično raste poboljšavanjem uvjeta uzgoja ali ne značajno. To su stabilni i ne osobito prinosni genotipovi.

3. Tip S3, sa genotipovima koji imaju izrazito loš prinos na lošim okolinama i izrazito visok prinos na visoko prinosnim okolinama. To su nestabilni genotipovi, predodređeni za uzgoj samo u optimalnim uvjetima okoline.
4. Tip S4, u koji dolaze genotipovi sa najboljom reakcijom na okoline jer i na lošim okolinama ostvaruju dosta visoke prinose, a ti prinosi izrazito rastu poboljšavanjem uvjeta uzgoja.

Milas (1993.) i Gunjača (1997.) smatraju da najvažniji kriterij prilikom izbora metoda za procjenu stabilnosti genotipova treba biti jednostavnost i pouzdanost procjene. Uvjet za takav pristup jesu izbalansirani setovi osnovnih podataka.

Milas (1989.) je proučavao stabilnost hibrida kukuruza FAO skupina 200 i 500 tijekom tri godine, na više lokacija. Nije pronašao korelacije između parametara stabilnosti i prinosa, ali je utvrđena značajna korelacija između parametara stabilnosti (s^2_{di}, W_i, r_2). To navodi na zaključak da je svejedno koji ćemo od ovih parametara koristiti.

Liović i Kristek (2000.) su procjenjivali parametre stabilnosti kod šećerne repe, za prinos korjena, sadržaj šećera i prinos bijelog šećera, kod 3 lokacije, u dvije godine. Izračunati su W_i, b_i i s^2_{di}. Prema vrijednostima ovih parametara napravljeno je grupiranje genotipova. Pokazalo se da genotipovi sa visokim prinosom nemaju i visoku stabilnost prinosa.

Knezović i Gunjača (2002.) navode da se procjena vrijednosti nekog novog kultivara temelji na njegovoj sposobnosti da u različitim okolinskim uvjetima zadrži slične vrijednosti prinosa i drugih važnih svojstava. Što je interakcija nekog genotipa s okolinom manja, to je njegova stabilnost veća.

Marić i sur. (2007.) su analizirali stabilnost različitih genotipova pšenice u različitim okolinama. Nalaze da je stabilnost genotipova u različitim okolinama jedan od glavnih ciljeva u oplemenjivanju. Zaključuju da je za uspješnu selekciju stabilnih i visoko prinosnih genotipova potrebno u pokuse uključiti nekoliko lokacija, a odabir lokacija trebalo bi se vršiti prema nekoliko parametara stabilnosti.

1.1.4. Cluster i Pattern analiza dobivenih podataka

Pecina (1998.) navodi da korištenje multivarijatnih tehnika može biti korisno kako bi još bolje objasnili odnos okolina i genotipova. Postoje razne metode multivarijatnih analiza (npr: GGE biplot i AMMI).

Mungomery i sur. (1974.) integrirali su Principal component analizu (Goodchild i Boyd) i cluster analizu u Pattern analizu, koja radi klasifikaciju baziranu na interakciji GxE i može imati fokus na grupiranje genotipova, okolina ili oboje.

Delacy i sur. (1994.) navode da uz klasičan način korištenja linearne regresije za analizu ostvarenih rezultata genotipova kroz više okolinske pokuse, postoji alternativni pristup ovakvoj analizi, a to je Pattern analiza. Ona se sastoji od komplementarnih postupaka klasifikacije (klasteriranja) i ordinacije. Klasteriranjem otkrivamo genotipove sa sličnim uzorkom reakcija kroz okoline. Postupak ordinacije omogućuje uspješan uvid individualnih razlika i sličnosti unutar neke skupine kultivara.

Gauch i sur. (1997.) navode da je glavna statistička strategija za grupiranje lokacija u megaokoline Pattern analiza.

Šimić i sur. (2003.) koristili su Pattern analizu, kao varijantu cluster analize. Klasteriranje se koristi za pojednostavljenje seta podataka grupiranjem genotipova kroz sve okoline sa sličnom strukturom, odnosno razinom prinosa, kao i grupiranjem okolina kroz sve genotipove sa sličnom razinom prinosa. Analizirano je 24 hibrida kukuruza na 8 lokacija (Osijek, Bizovac, Đakovo, Karanac, Koprivnica, Kutjevo, Vukovar i Feričanci), tijekom 1998. i 1999.godine. Rezultati ukazuju na postojanje odvojenih skupina, kako genotipova, tako i lokacija. Ispitivani genotipovi imali su sličnu strukturu reakcija na prinos zrna na 4 lokacije (Osijek, Bizovac, Kutjevo i Đakovo), što ukazuje da ove lokacije daju redundantne informacije o prinosu te se one mogu svesti na samo jednu lokaciju.

Zdunić i sur. (2010.) koristili su veličinu i strukturu (Pattern) interakcije genotip x okolina, za diskontinuirana uzgojna područja Hrvatske i Turske. Pattern analiza, kao varijanta cluster analize poslužila je da bi se pojednostavio set podataka grupiranjem jedinica sa sličnom reakcijom na određeno obilježje. Pattern analiza otkrila je da postoje dvije skupine hibrida koje različito reagiraju u dvije megaokoline. Tako u skupini HIGH nalaze se 4 hibrida OS515, OSSK602, OS713 i OSSK644, s konstantno visokim srednjim vrijednostima kroz sve okoline. Skupina MID nije imala dosljednu reakciju kroz skupine lokacija (3 hibrida). Analiza strukture interakcije GxE za prinos zrna kod OS hibrida otkrila je da postoje odvojene skupine kako genotipova, tako i lokacija.

Chapman i sur. (1997.) u svom pokusu sa tropskim populacijama kukuruza korištenjem cluster analize napravili su izdvajanje ranijih i kasnijih genotipova tolerantnih na sušu. Istom tom analizom omogućeno je i grupiranje okolina na one sušne, srednje sušne, kao i visoko prinosne, vodom dobro opskrbljene lokacije.

DeLacy i sur. (1996.) navode da internacionalni oplemenjivački programi (kao CIMMYT) često uključuju veliki broj okolina koje predstavljaju veliki izazov za oplemenjivače (osobito zbog postojanja vrlo različitih biotskih i abiotskih stresova).

Pattern analiza može identificirati lokacije koje su slične prema razlikama između genotipova i moguće je koristiti dobivene podatke za direktnu ili indirektnu selekciju.

Hausmann i sur. (2001.) koristili su Pattern analizu kod proučavanja interakcije GxE u vezi otpornosti afričkog sirka na štetnika *Striga hermonthica (Del.).* Upotrebom ove analize jasno je odvojena lokacija u Maliju od one u Keniji, a isto tako unutar analiziranih 36 F2 populacija sirka identificirane su skupine sa različitom razinom adaptacije.

Yuksel i Akcura (2012.) koristili su Pattern analizu kod analiziranja prinosa 24 kultivara ječma (sa 2 i sa 6 redi zrna) uzgajanih na 26 različitih okolina u Turskoj, u vremenu od 2004. do 2008. godine. Genotipovi su grupirani u 5 klastera. Dva 6-redna ječma (Kiral i Cetin) i dva 2-redna ječma (Sahin i Aydan) bili su vrlo adaptirani na visoko prinosne okoline, a sorte kasnije vegetacije i visokog habitusa (Karatay, Ince, Kalayci, Ozdemir, Tokak i Keser) bile su adaptirane na većinu proučavanih lokacija.

Azad i sur. (2012.) u svom istraživanju u Bangladešu, proučavali su 30 inbred linija kukuruza, prema 13 parametara, tijekom 2010. i 2011. godine. Cilj je bio korištenjem multivarijatnih tehnika proučiti genetsku divergentnost između njih. Sve linije, korištenjem cluster analize, svrstane su u 6 odvojenih klastera, a distanca unutar klastera bila je mala, što znači da je ta podjela bila učinkovita i objektivna jer su unutar tih klastera inbred linije bile relativno bliske. Budući da je za unapređenje proizvodnje kukuruza u Bangladešu, a i u toj regiji uopće, najznačajniji problem dobijanje, unapređivanje i održavanje roditeljskih inbred linija, ovo je istraživanje imalo za cilj svrstati inbred linije u različite heterotične skupine, što bi predstavljalo osnovu za stvaranje hibrida. Izdvojeno je 6 inbred linija sa srednjom ili većom genetskom udaljenošću.

Abou–El–Fittouh i sur. (1969.) su još prije 45 godina koristili cluster analizu kao alat za klasifikaciju lokacija, prema minimalnim unutar–klasterskim interakcijama genotipa i lokacija, kod pokusa sa pamukom (*Gossypium hirsutum L.*).

Khavari Khorasani i sur. (2011.) analizirali su 34 hibrida kukuruza na 21 karakteristiku, kroz pokuse provedene u Iranu, tijekom 2009. godine. 28 hibrida dobiveni su križanjem poznatih iranskih populacija, a 6 su bili single-cross hibridi. Pri analizi koristili su multivarijatne tehnike analize. Na osnovi cluster analize 34 hibrida svrstana su

u 7 glavnih skupina, a svaka od tih skupina imala je dvije ili više podskupina. Na osnovi ovih rezultata, moguće je preporučiti međusobno križanje između genotipova iz različitih klastera.

Babić i sur. (2008.) proučavali su strukturu interakcije GxE, kod 12 hibrida kukuruza, na 31 lokaciji. U analizi podataka, korištenjem Pattern analize, kvadratna Euklidova distanca korištena je kao mjera udaljenosti za Wardovu metodu klasteriranja. Hibridi su grupirani u 5 klastera, a lokacije u 11 klastera. Prvi korak u grupiranju lokacija bilo je njihovo svrstavanje u podskupine prema zemljopisnoj blizini, tipu tla, količini padalina i agrotehnici. Ovaj tip klasifikacije može biti korišten kod definiranja megaokolina. Za manje uzgojne regije, za veću pouzdanost dobivenih rezultata, potrebno je koristiti još neke tehnike analize podataka (u prvom redu AMMI). U takvim analizama iskustvo oplemenjivača je od velikog značaja, jer izbor lokacija za testiranje na taj način vrši se više u smjeru stvaranja mreže lokacija za testiranje koje daju pouzdane rezultate, nego u smjeru smanjenja broja lokacija.

Sabaghnia i sur. (2012.) su koristili cluster analizu, kao učinkovitu, za izdvajanje informacija o strukturi interakcije GxE. Ukupno 18 sorata pšenice, bilo je ispitivano na 5 lokacija, u tri godine. Ispitivana je i stabilnost ovih kultivara. Primjenjene su 4 tehnike cluster analize.

Prema prvoj tehnici, koja se bazira na linearnoj regresiji, i koja koristi i presijecanje i nagib krivulje, napravljeno je grupiranje u 6 različitih skupina genotipova. Druga tehnika grupiranja, također na osnovi linearne regresije, na bazi parametara nagiba, grupirala je sorte u 3 skupine. Treća tehnika grupiranja, koja se bazira na ANOVI i grupiranje vrši prema sličnosti efekata genotipova i njihove interakcije sa okolinom, rezultirala je sa 5 skupina sorata, kao i 4 metoda klasteriranja koja se bazira samo na interakciji GxE.

Različiti genotipovi bili su najbolji prema različitim pristupima procjene stabilnosti. Prema dinamičnom konceptu stabilnosti, najbolji su bili genotipovi 1 i 16, a prema statičnom modelu, najstabilniji su bili genotipovi 8, 12 i 14.

Subramanian i Subbaraman (2010.) pročavali su 38 inbred linija kukuruza, na 25 morfoloških svojstava. Korištenjem Euklidove distance i pomoću UPGMA dendrograma sve linije grupirane su u 4 skupine, 4 klastera. Važno je da grupiranje genotipova nije bilo uvjetovano njihovim geografskim porjeklom. Maksimalna genetska divergentnost dobivena je kod dvije linije – UMI 551 i UMI 696. Široka divergencija između klastera

može se koristiti u daljem oplemenjivanju, u prvom redu korištenjem ovih inbred linija kao roditelja u križanjima.

Babić i sur. (2011.) proučavali su 15 komercijalnih hibrida na tri ciljane okoline. Korištenjem multivarijatne tehnike grupiranja (AMMI) utvrđeno je da su 3 hibrida (ZP677, ZP570, ZP732) ostvarila maksimalne prinose na ovim ciljanim lokacijama, odnosno da je i na relativno malom prostoru moguće iskoristiti usku adaptiranost genotipova, da bi se postigao napredak u oplemenjivanju.

Kroonenberg i sur. (1995.) su napravili trosmjernu, (genotipovi, lokacije i godine) mješanu, metodu klasteriranja koju su potpuno objasnili i prvi primjenili Basford i McLachlan 1985. godine. 14 hibrida kukuruza koji se nalaze na listi priznatih kultivara u Nizozemskoj, testirani su u 4 regije, od 1984. - 1990. godine. Osnovni cilj bio je grupiranje hibrida u homogene skupine, sa istim načinom reagiranja na promjene kroz različite lokacije. Dobivena su 3 klastera, sa 6, 5 i 3 hibrida.

1.2. Cilj istraživanja

Na osnovi dobivenih rezultata ispitivanja 22 hibrida (20 hibrida Poljoprivrednog instituta Osijek i 2 strana standarda), tijekom 2010. i 2011. godine – na 2 lokacije u Hrvatskoj i na 4 (dva roka sjetve na svakoj) lokacije u Turskoj, mjerenjem ostvarenog prinosa suhog zrna (t/ha), cilj istraživanja je:

1. Analizirati rezutate po pojedinoj okolini (ukupno 20 okolina = dvije lokacije u Hrvatskoj i četiri u Turskoj, dva roka sjetve na svakoj, kroz dvije godine), kao i u kombiniranoj analizi varijance kroz svih 20 okolina dvofaktorijelnom i trofaktorijelnom analizom varijance.

2. Odrediti značenje interakcije hibrid x okolina i utvrditi odnose među okolinama i hibridima uporabom univarijatne i multivarijatne biometrijske tehnike.

3. Provesti analizu parametara stabilnosti hibrida i okolina.

4. Identificirati homogene adaptacijske regije (megaokoline) za proučavane hibride i izdvojiti reprezentativne okoline za svaku podregiju na osnovi „pattern“ analize.

5. Utvrditi značenje i primjenjivost ovih rezultata u praktičnom oplemenjivanju kukuruza.

2. MATERIJAL I METODE RADA

Dvadeset i dva hibrida kukuruza su posijani tijekom 2010. i 2011. godine, na 2 lokacije u Hrvatskoj (Osijek i Karanac) te na 4 lokacije u Turskoj. Lokacije u Turskoj su Adana, Mersin, Manisa i Altinova.

Lokacije za testiranje i u Hrvatskoj i u Turskoj birane su u parovima, na relativno bliskom zemljopisnom području i sa vrlo sličnim tipom tla i klimatskim uvjetima (Osijek i Karanac, Adana i Mersin te Altinova i Manisa) da bi se izbjegla mogućnost da cijela jedna regija, zbog nepredviđenih vremenskih uvjeta ne bi bila bez ijednog rezultata u godinama ispitivanja.

Termin okolina veže se za efekte po kojima se ta okolina razlikuje od drugih te godine (tip tla, agrotehnika proizvodnje, klimatski uvjeti). Za veću točnost podataka, promjene broja godina u kojima se provodi ispitivanje ima veću važnost u odnosu na broj promjena lokacija. Na primjer, trogodišnji pokus na tri lokacije ima veću preciznost nego jednogodišnji pokus na devet lokacija. Međutim, kako je u praksi broj godina provođenja pokusa uglavnom limitiran zbog visokih troškova, dobit u preciznosti rezultata pokusa uglavnom se postiže povećanjem broja lokacija. Ali, gdje je broj lokacija velik, na primjer veći od 5, male promjene u broju lokacija imaju ograničene efekte na preciznost pokusa i same promjene u cijeni izvođenja pokusa proporcionalne su broju lokacija uključenih u ispitivanje. Promjena u broju ponavljanja u pokusu (osobito ako je broj ponavljanja iznad tri) ima relativno mali utjecaj na preciznost dobivenih rezultata (Jambrović, 2001.).

U ovom istraživanju bilo je samo dva ponavljanja, zbog organizacijskih teškoća pri postavljanju mikropokusa u Turskoj, gdje to i nije uobičajena praksa.

2.1. Poljski pokusi

U Hrvatskoj su odabrane dvije lokacije za postavljanje poljskih pokusa. To su Osijek i Karanac. Obje su lokacije na istočnom dijelu Hrvatske, sa tlom sličnih karakteristika (smeđe lesivirano tlo), i sa vrlo sličnom količinom oborina i njihovim rasporedom tijekom vegetacijskog perioda kukuruza. Kako je i prije navedeno, cilj je bio imati bar dvije lokacije po jednoj potencijalnoj megaokolini, koje su reprezentativne za to područje. Sjetva pokusa na ovim lokacijama bila je obavljena u obje godine u optimalnim rokovima, tj. u razdoblju između 20. i 30. travnja.

Pokusi su posijani po slučajnom bloknom rasporedu, u 2 ponavljanja. Sjetva je obavljena ručno, razmak između redova je 70 cm, unutar reda 22,5 cm. Osnovna parcela je 2 reda, dužine 5 m, odnosno površine 7 m^2. Razmak između ponavljanja je 1 m.

Tablica 2. Hibridi koji se nalaze u pokusu.

Hibrid broj	Hibrid
1.	Os 7798/2 x Os 942
2.	Os 1965 x Os 622448
3.	Os 438MP x Os 1309/2 = OSSK 613
4.	Os 7728/3 x Os 942
5.	Os 1600/1186/3 x Os 7728/3
6.	OsKLT-14 x Os 942
7.	Os 2295-304 x Os L201/1
8.	Os 7798/2 x Os 758To240-3
9.	OsKLT-14 x Os 621023BO
10.	Os 334275/13 x Os 3467
11.	Os 334275/13 x Os 621023BO
12.	KLTB73Č x Os 156BO
13.	Os 7798/2 x Os 622448 = Toni
14.	Os 7728/3 x Os 758TO240-3
15.	Os 7728/3 x Os 156BO
16.	Os 7728/3 x Os 622448 = Leonid
17.	OsMP33 x Os 1309/2/5
18.	Os 2236 x Os 622448
19.	OSSK 515
20.	OSSK 602
21.	Shemal
22.	PR31G98

U pokusu je ukupno bilo 22 hibrida FAO skupina 500 i 600. To je bio praktično jedan od osnovnih kriterija kod izbora hibrida – njihova dužina vegetacije. Naime, u istočnom dijelu Hrvatske postoje povoljni uvjeti za uzgoj hibrida kasnih vegetacijskih skupina za zrno i oni ovdje mogu ostvariti svoj potencijal rodnosti. To je u velikoj mjeri ovisno o klimatskim uvjetima i primjenjenoj agrotehnici ali višedesetljetni uzgoj ovih hibrida na ovom području pokazao je da se kasni hibridi uspješno siju na području istočne Slavonije. Drugi kriterij kod izbora hibrida za ove pokuse bili su preliminarni rezultati kod većine ovih hibrida u vegetacijskoj godini 2009. u Hrvatskoj. Tada su za sjetvu u

slijedećoj sezoni odabrani hibridi sa najboljim rezultatima. Od hibridia pod rednim brojevima 1 - 18, samo je hibrid pod brojem 3 – OSSK 613 registriran u Hrvatskoj, dok su svi ostali hibridi eksperimentalni. Hibridi pod brojevima 19 = OSSK 515, 20 = OSSK 602, 21 = Shemal i 22 = PR31G98 su standardni hibridi, prema kojima se uspoređuje prinos svih ostalih hibrida u pokusu. Osnovni kriterij zašto su baš oni izabrani za standarde je njihova proširenost i prepoznatljivost u proizvodnji, u tim područjima. Važno je reći, da je OSSK 515 standard specifičan baš za Hrvatsku, dok je OSSK 602 registriran i proizvodi se uspješno i u Hrvatskoj i u Turskoj. Standard PR31G98 je hibrid kompanije Pioneer, a Shemal je hibrid turske selekcijske kuće Polen-tohum iz Manise.



Slika 1. Oplemenjivačka stanica Poljoprivrednog instituta Osijek i turske kompanije Tareks – u Altinovi.

Lokacije za sjetvu pokusa u Turskoj također su odabrane u parovima, kako bi bile zastupljene potencijalne dvije megaokoline. Prvi par lokacija bile su Adana i Mersin. To je južni dio središnje Turske, gdje su uvjeti za uzgoj kukuruza vrlo povoljni i gdje se postižu u prosjeku najviši prinosi, kako merkantilnog kukuruza, tako i u proizvodnji sjemena kukuruza u Turskoj. Drugi par lokacija bio je Manisa i Altinova. To su lokacije na jugozapadnom dijelu Turske, međusobno udaljene oko 200 km, sličnih proizvodnih uvjeta.

Lokacija Altinova ujedno je i zajednička selekcijska stanica Poljoprivrednog instituta Osijek i turske kompanije Tareks (slika 1.).

Sjetva u Turskoj obavlja se u dva roka – prvi je na lokacijama Adana i Mersin tijekom travnja, a na lokacijama Altinova i Manisa u prvoj dekadi svibnja. U obje godine prva sjetva je obavljena u optimalnim rokovima. Odmah nakon sjetve obavlja se navodnjavanje polja kišenjem, da bi se obezbjedilo ravnomjerno nicanje usjeva. Kada je kukuruz u fazi 4 - 6 listova usjev se ogrće i tako se stvaraju uvjeti za daljnja navodnjavanja (natapanjem) tijekom vegetacije - u 6 - 8 navrata (slika 2.). Drugi rok sjetve u Turskoj je obično tijekom lipnja u Adani i Mersinu, odnosno početkom srpnja u Altinovi i Manisi. U obje godine sjetva je obavljena u optimalnim rokovima.



Slika 2. Ogrnuti usjevi kukuruza, neposredno pred cvatnju, 2010. godine u Altinovi.

Obilježavanje pokusa napravljeno je bijelim etiketama privjesnicama, jednako na svim lokacijama. Pokusi na turskim lokacijama bili su pod redovitom kontrolom oplemenjivača iz Osijeka, kao i turskih kolega iz Tareksa (slike 3., 4., 5. i 6.).



Slika 3. Obilježavanje pokusa etiketama privjesnicama u Turskoj 2011.godine.



Slika 4. Pregled pokusa neposredno pred cvatnju – Altinova, 2011. godine.



Slika 5. Sjetvenik sa pedigreom hibrida koji su bili u pokusima u Hrvatskoj i Turskoj 2010. i 2011. godine.



Slika 6. Turska lokacija Altinova,srpanj 2011. godine – dvopolje, pšenica – kukuruz.

Berba se obavljala ručno i u Hrvatskoj i u Turskoj. Berba u Hrvatskoj je obavljena u drugoj dekadi mjeseca listopada, u obje godine, na obje lokacije. U Turskoj, berba prvog roka sjetve obavljena je koncem kolovoza na lokacijama Adana i Mersin, te u prvoj dekadi rujna na lokacijama Altinova i Manisa. Rokovi za berbu kukuruza iz drugog roka sjetve bili su konac listopada, odnosno sredina studenog u Turskoj (slike 7., 8. i 9.).



Slika 7. Ručna berba pokusa u drugoj sjetvi, Turska, Altinova, 2011. godine.



Slika 8. Berba kukuruza iz drugog roka sjetve, Turska, Altinova, studeni 2011. godine.



Slika 9. Ocjena pokusa u Altinovi, neposredno pred berbu, studeni 2011. godine.



Slika 10. Ručno krunjenje uzoraka klipova, druga berba, Altinova, studeni 2011. godine.

Svi klipovi, u oba ponavljanja, sa parcelice od 7 m^2, bili su izvagani a zatim je iz uzorka od 10 klipova napravljena odvaga i izračun postotka oklaska, te vlaga zrna, uz pomoć vlagomjera Dickey John GAC 2000. Standard vlage zrna i u Hrvatskoj i u Turskoj bio je 14 %. Prilikom berbe drugog roka sjetve u Altinovi, zbog nešto višeg postotka vlage u zrnu moralo se krunjenje uzoraka klipova napraviti ručno (slika 10.).

Standard vlage zrna i u Hrvatskoj i u Turskoj bio je 14 %, tako da se srednja vrijednost prinosa hibrida iz jedne godine, sa svih lokacija mogla izračunati odmah tijekom druge berbe u studenom u Turskoj (slika 11.).



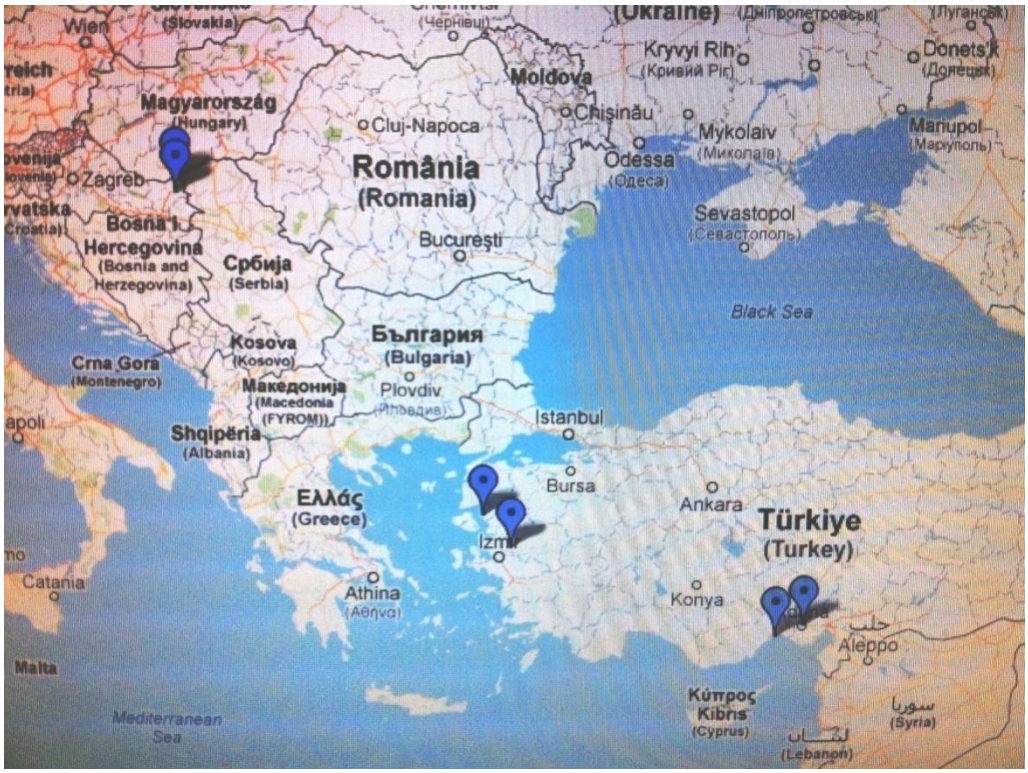
Slika 11. Laboratorij oplemenjivačke stanice u Altinovi, studeni 2011. godine.

Generalno gledano, sama agrotehnika, uključujući obradu tla, gnojidbu, sjetvu, ostvarene sklopove i berbu bila je korektno provedena gotovo na svim lokacijama. To znači da se sijalo na tlima sa napravljenom dubokom jesenskom brazdom (u Hrvatskoj), u optimalnim rokovima, sa dosta uspješnim suzbijanjem korova primjenom odgovarajućih herbicida (izuzev u 2. sjetvi 2010. godine u Turskoj, na lokaciji Mersin), uz provedenu jednu ili dvije kultivacije sa prihranom, te da je berba napravljena na vrijeme, nakon što su svi hibridi ušli u fazu fiziološke zriobe.

Problem je predstavljao dosta veliki napad kukuruznog moljca prilikom 2. sjetve u Turskoj, zbog nepridržavanja plodoreda u pojedinim slučajevima. Isto tako, posebno na lokaciji Altinova, događalo se da je zbog nagnutosti terena na jednu stranu, raspored dodane vode tijekom navodnjavanja bio neujednačen, što je izazvalo značajne promjene u ostvarenim prinosima, osobito između ponavljanja.

2.1.1. Zemljopisna pozicija lokacija za pokuse, u Hrvatskoj i Turskoj

Na slici 12. označene su lokacije za testiranje u Hrvatskoj i Turskoj. Vidljivo je da su birane u parovima, na relativno bliskom zemljopisnom području a time i sličnim klimatskim uvjetima (Osijek i Karanac, Adana i Mersin te Altinova i Manisa).



Slika 12. Zemljopisna karta pokusnih lokacija u Hrvatskoj i Turskoj.

U Hrvatskim pokusima – Osijek ima točnu poziciju na 45˚ 32̀ sjeverne zemljopisne širine (szš), i na 18˚ 44̀ istočne zemljopisne dužine (izd), a u Turskoj pozicija Adane je 37˚ 00̀ szš i 35˚ 16̀ izd, te Manise - 38˚ 37̀ szš i 27˚ 25̀ izd. Podaci o zemljopisnom položaju uzeti su za jednu lokaciju od parova lokacija, u Hrvatskoj i Turskoj – koje su zemljopisno i agroekološki vrlo slične, npr: Osijek od para Osijek – Karanac, Adana od para Adana – Mersin i Manisa, od para Manisa – Altinova. Isto je učinjeno i kod agroekoloških pokazatelja proizvodnje, u poglavlju koje slijedi.

2.2. Agroekološki uvjeti proizvodnje u 2010. i 2011. godine, u Hrvatskoj i Turskoj

Klimatske prilike tijekom vegetacije kukuruza imaju vrlo veliki značaj na ostvarene prinose analiziranih hibrida. Podaci o ukupnoj količini oborina i njihovoj distribuciji tijekom kalendarske godine u 2010. i 2011. posebno su značajni kada analiziramo uvjete u Turskoj jer se kukuruz u područjima Turske proizvodi isključivo uz navodnjavanje. Hibridi kukuruza u takvim uvjetima mogu, uz pravilnu i izbalansiranu gnojidbu, ostvariti gotovo maksimalan urod, prema svom kapacitetu rodnosti, a što nije slučaj kod suhog ratarenja, koje se u proizvodnji kukuruza provodi u cijeloj Europi, pa i u Hrvatskoj. To nas navodi i na potrebu provođenja selekcijskog programa za ovakve specifične proizvodne uvjete, i stvaranje novih inbred linija i hibrida koji mogu biti konkurentni prinosima drugih selekcijskih kuća.

Ono što možemo prvo uočiti iz tablice 3. je da su prosječne temperature zraka u Osijeku u obje ispitivane godine bile vrlo slične, sa nešto toplijim 9. mjesecom 2011. u odnosu na 2010. godinu, ali tada je praktično kukuruz završio vegetaciju i to nije rezultiralo nikakvim posljedicama na urod zrna. Ono što drastično odstupa od višegodišnjeg prosjeka (oko 700 mm oborina za Osijek) je izuzetno velika količina oborina tijekom 2010. godine, čak 1038,2 mm i čak 234 mm oborina tijekom 6. mjeseca, što je prouzročilo praktično elementarnu nepogodu u vidu poplavljenih polja pod kukuruzom. Pokusne parcele nisu bile pod vodom, ali su bile na površinama praktično zasićenim vodom do maksimuma. Sasvim suprotna bila je po oborinama 2011. godina, sa samo 422,2 mm oborina ukupno (uz vrlo sušni 8. mjesec sa samo 4,6 mm kiše) što je izazvalo stres kod kukuruza u vidu suše tijekom najvažnijih faza razvoja, ne toliko u cvatnji, koliko u oplodnji i početku perioda nalijevanja zrna. Možemo zaključiti da niti jedna od ove dvije godine nije bila prosječna i tipična za uzgoj kukuruza u ovom podneblju.

U Turskoj, na lokaciji Adana, (tablica 4.), koja se nalazi istočnije i južnije od lokacije Manisa, tijekom 2010. godine zabilježena je za 1,5 ˚C viša prosječna temperatura zraka nego godinu poslije, sa vrlo visokim temperaturama tijekom 7., 8., i 9. mjeseca, gotovo 30 ˚C u prosjeku. Ono što može zavarati nekoga tko gleda samo prosječne količine oborina (praktično za sve dijelove Turske gdje se uzgaja kukuruz) je da npr. Adana tijekom 2010. godine ima ukupno 571,3 mm oborina što se čini dovoljnom količinom za proizvodnju kukuruza, ali problem je distribucija tih oborina – jer glavnina kiše pada

tijekom siječnja i veljače, a u vegetacijskom razdoblju proizvodnje kukuruza (4. - 9. mjesec) padne vrlo malo oborina, nedovoljno da bi biljke uopće mogle preživjeti a kamoli dati odgovarajući, isplativi urod. Tijekom vegetacije kukuruza u Adani tijekom 2010. godine, od 6. - 9. mjeseca, palo je samo 3,8 mm kiše. To čini navodnjavanje neizbježnim faktorom za ovu proizvodnju u takvim klimatskim uvjetima. U godini 2011. bilo je znatno više kiše nego godinu prije – 758,2 mm, opet sa izrazitim manjkom (samo 4,1 mm) od 7. - 9. mjeseca, kada kukuruz cvjeta i oplođuje se te formira urod zrna.

Na lokaciji Manisa (tablica 5.), 2010. godina bila je toplija u prosjeku za 2,1 ˚C nego slijedeća 2011. Budući da je ova lokacija značajno sjevernija nego Adana, period najviših prosječnih temperatura (oko 30 ˚C) traje kraće, obično 7., i 8. mjesec. Isto tako, zbog zemljopisnog položaja, ukupna količina oborina ovdje je veća nego u Adani. Posebno odskače godina 2010. gdje je bilo čak 1075,2 mm oborina, ali opet sa izrazitim manjkom tijekom 7. i 8. mjeseca (samo 2,0 mm kiše). Konačno, tijekom 2011. godine, od ukupno 758,2 mm oborina, tijekom 7. i 8. mjeseca u Manisi nije pao niti jedan mm kiše.

Tablica 3. Klimatološki podaci za Osijek (oborine (mm) i prosječne mjesečne temperature zraka (˚C)) u 2010. i 2011. godini.

		I	**II**	**III**	**IV**	**V**	**VI**	**VII**	**VIII**	**IX**	**X**	**XI**	**XII**	**X**
2010.	(˚C)	-0,8	1,4	6,8	12,4	16,5	20,4	23,2	21,7	15,6	9,1	8,9	0,3	11,2
2010.	(mm)	83,9	58,6	22,2	71,1	120,8	234	31,5	110,8	108,4	67.1	56.3	73,5	1038
2011.	(˚C)	1,1	0,7	6,4	13,2	16,7	20,8	22,2	23,0	20,3	10,6	2,3	3,4	11,7
2011.	(mm)	23,6	18,4	37,1	19,4	81,2	49,9	73,9	4,6	15,9	28,7	0,4	69,1	422,2

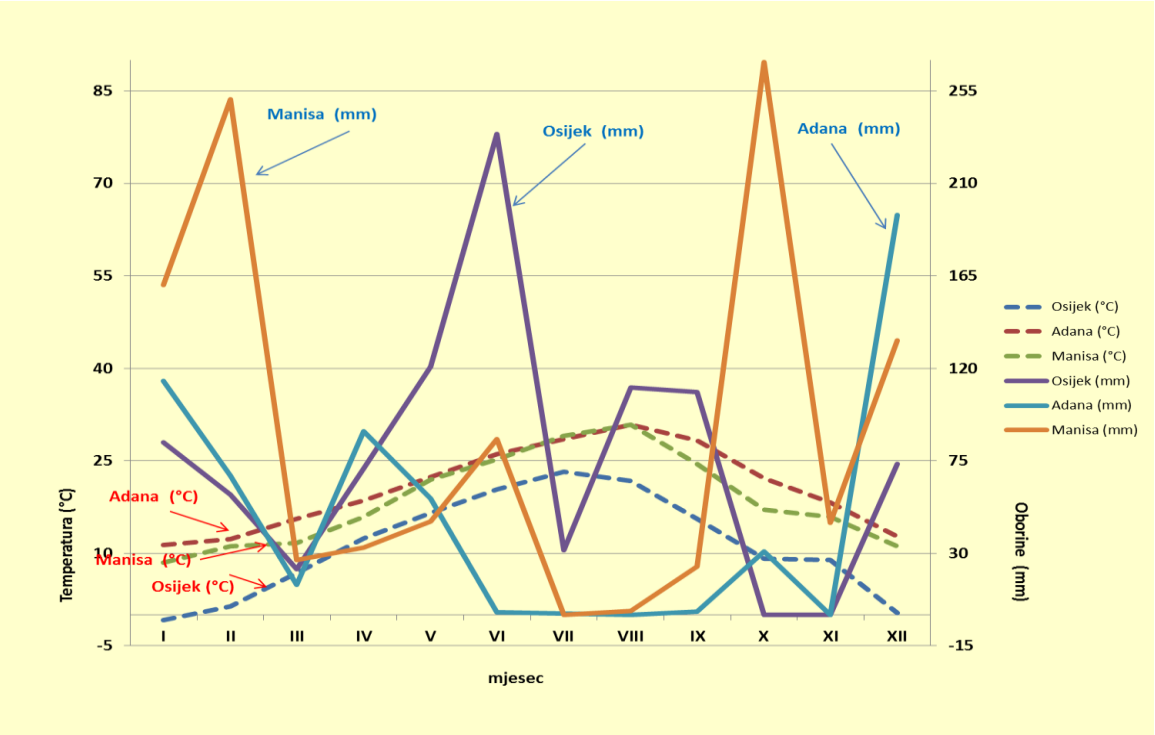
Tablica 4. Klimatološki podaci za Adanu (oborine (mm) i prosječne mjesečne temperature zraka (˚C)) u 2010. i 2011. godini.

		I	**II**	**III**	**IV**	**V**	**VI**	**VII**	**VIII**	**IX**	**X**	**XI**	**XII**	**X**
2010.	(˚C)	11,3	12,3	15,6	18,6	22,4	26,1	28,5	30,8	28,3	22,2	18,2	12,7	20,6
2010.	(mm)	113,9	67,6	14,8	89,3	56,6	1,4	0,7	0,0	1,7	30,8	0,0	194,5	571,3
2011.	(˚C)	10,1	10,9	13,5	16,6	21,4	25,6	28,6	29,5	27,3	20,8	12,4	13,0	19,1
2011.	(mm)	76,5	92,4	107	78,3	105,6	49,4	0,0	0,0	4,1	5,8	44,1	195,0	758,2

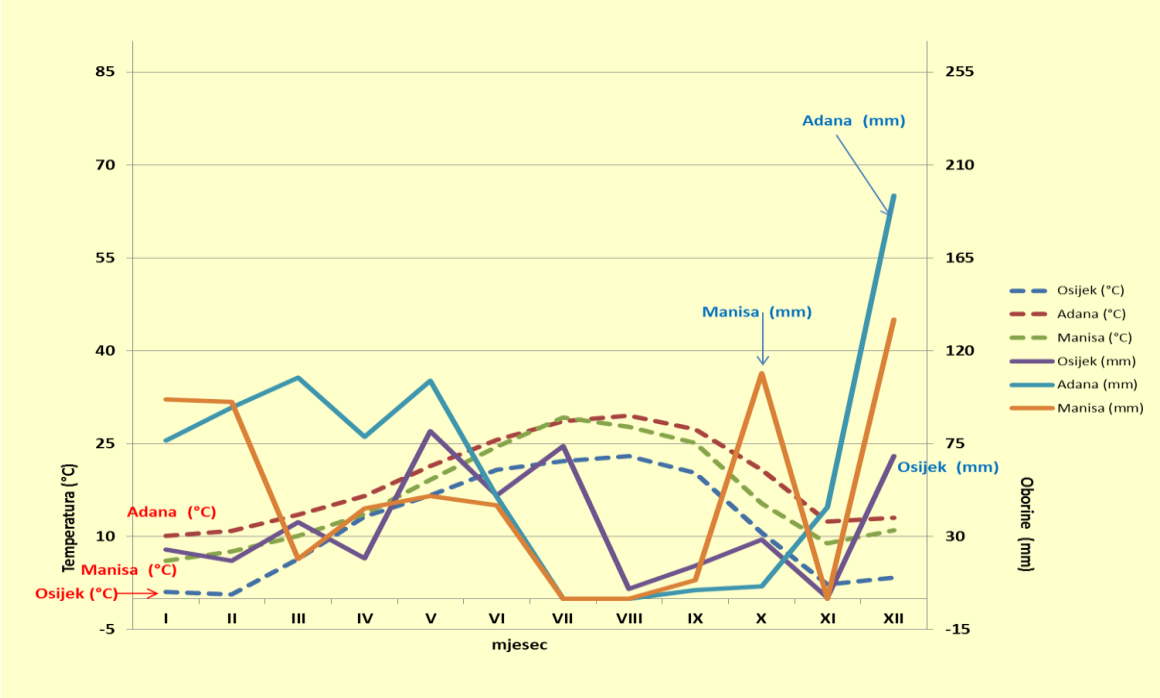
Tablica 5. Klimatološki podaci za Manisu (oborine (mm) i prosječne mjesečne temperature zraka (˚C)) u 2010. i 2011. godini.

		I	II	III	IV	V	VI	VII	VIII	IX	X	XI	XII	X
2010.	(˚C)	8,5	11,1	11,7	15,9	22	25,2	29,1	30,9	24,5	17,1	15,9	11,1	18,6
2010.	(mm)	160,6	251	26,8	32,8	45,6	85,6	0,0	2,0	23,6	269	44,8	133,7	1075
2011.	(˚C)	6,1	7,6	10,1	13,6	19,2	24,5	29,2	27,7	25,1	15,4	8,9	11,0	16,5
2011.	(mm)	96,4	95,2	19,3	43,6	49,7	45,0	0,0	0,0	8,8	109	0,0	135,0	602,2

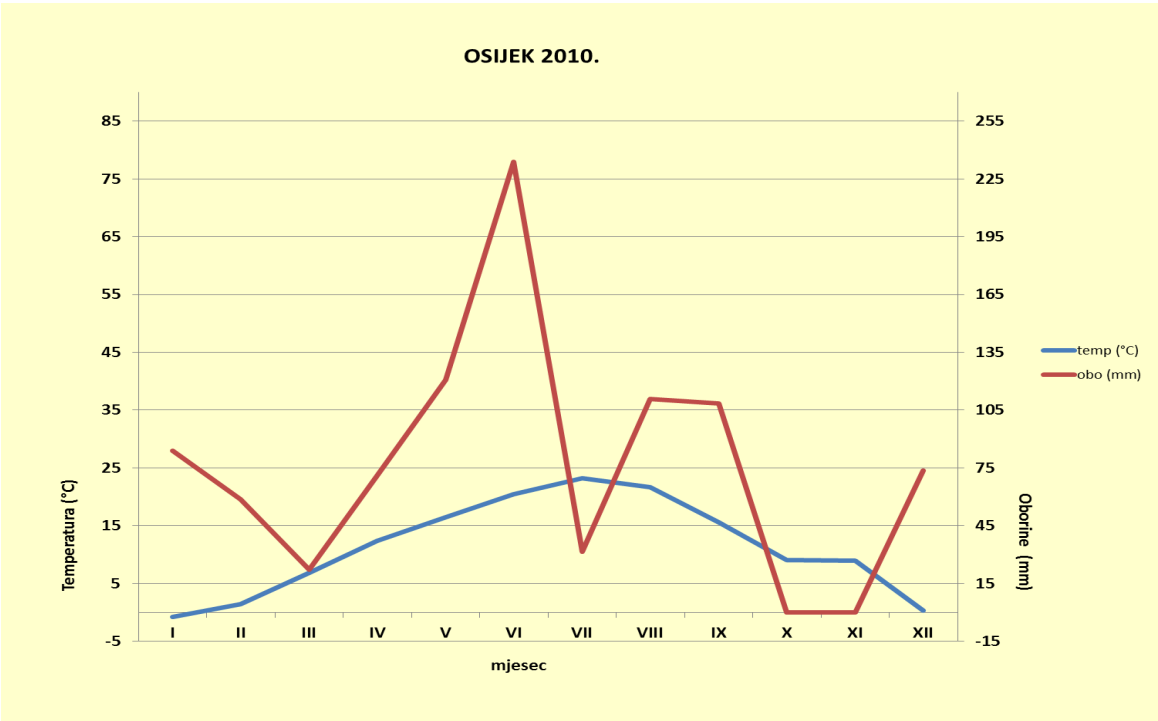
Klima dijagrami po Walteru (grafikoni 1. – 8.) vrlo slikovito pokazuju upravo navedeno stanje iz tablica. Sve situacije kada je krivulja temperature zraka iznad krivulje oborina (posebno tijekom vegetacijskog perioda uzgoja kukuruza (od 4. do 9. mjeseca)), predstavljaju problem u vidu nedostatnih količina oborina što, ovisno o fazi razvoja kukuruza, može nanijeti manje ili veće štete u konačnici na urod zrna kukuruza ispitivanih hibrida. Još jednom je vidljivo da kronični nedostatak oborina u Turskim lokacijama tijekom 6., 7., i 8. mjeseca praktično onemogućava proizvodnju kukuruza bez navodnjavanja.



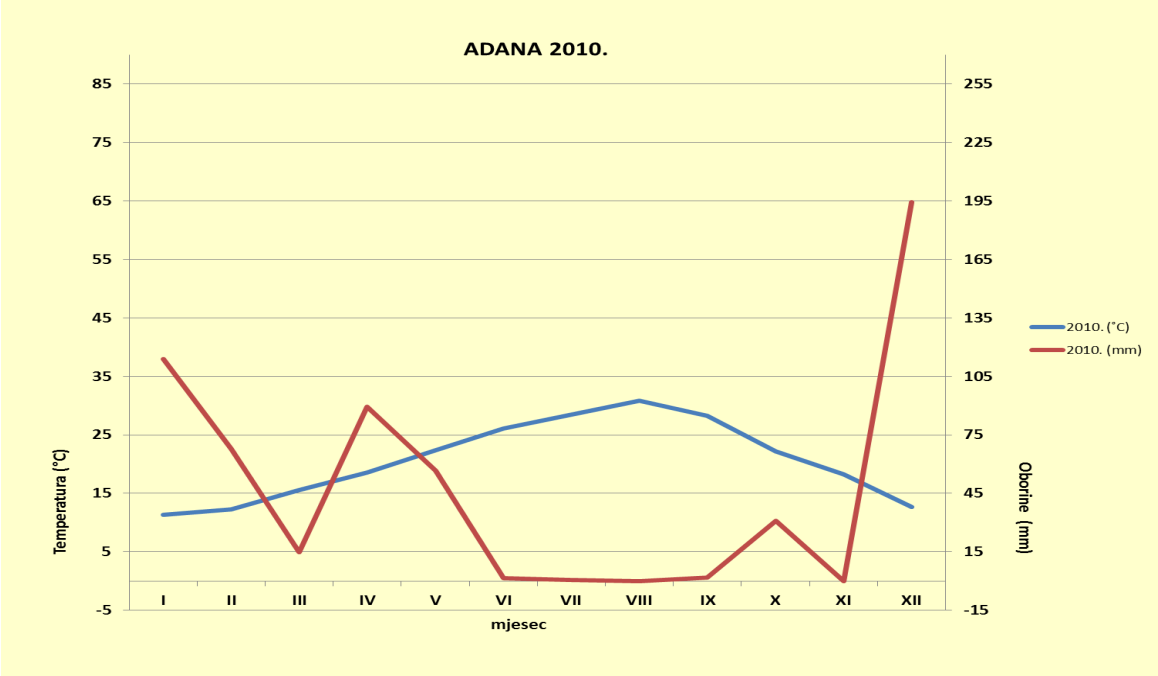
Grafikon 1. Skupni klimadijagram po Walteru za 2010. godinu za područja provođenja pokusa (Osijek, Adana i Manisa).



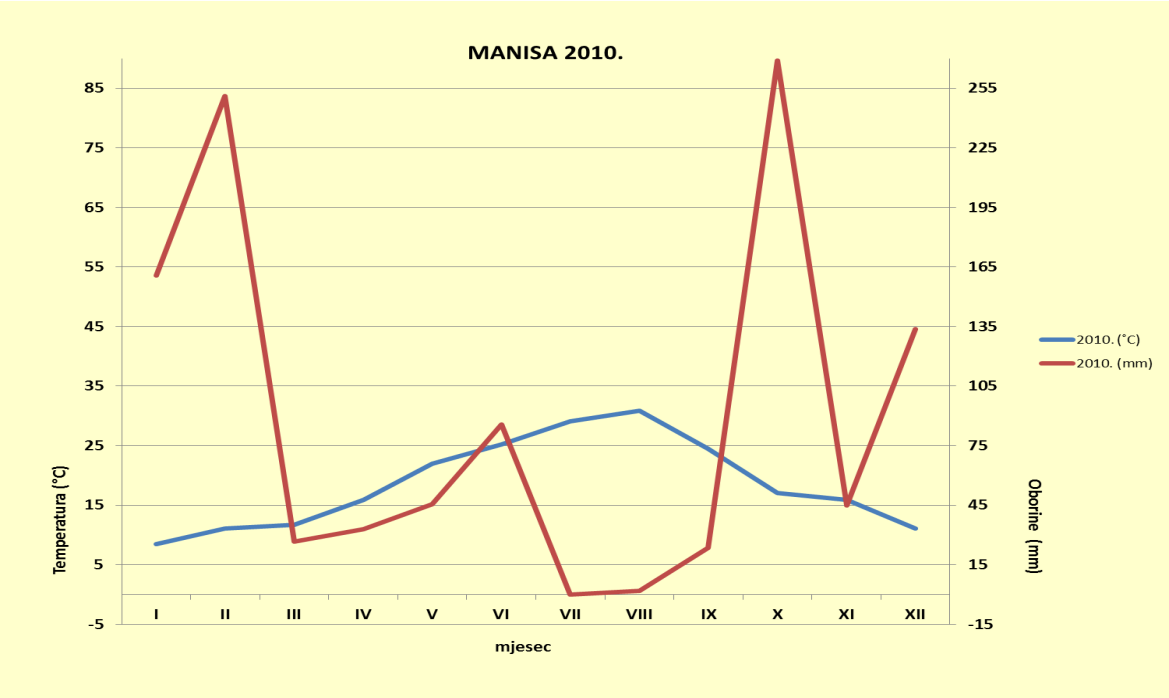
Grafikon 2. Skupni klimadijagram po Walteru za 2011. godinu za područja provođenja pokusa (Osijek, Adana i Manisa).



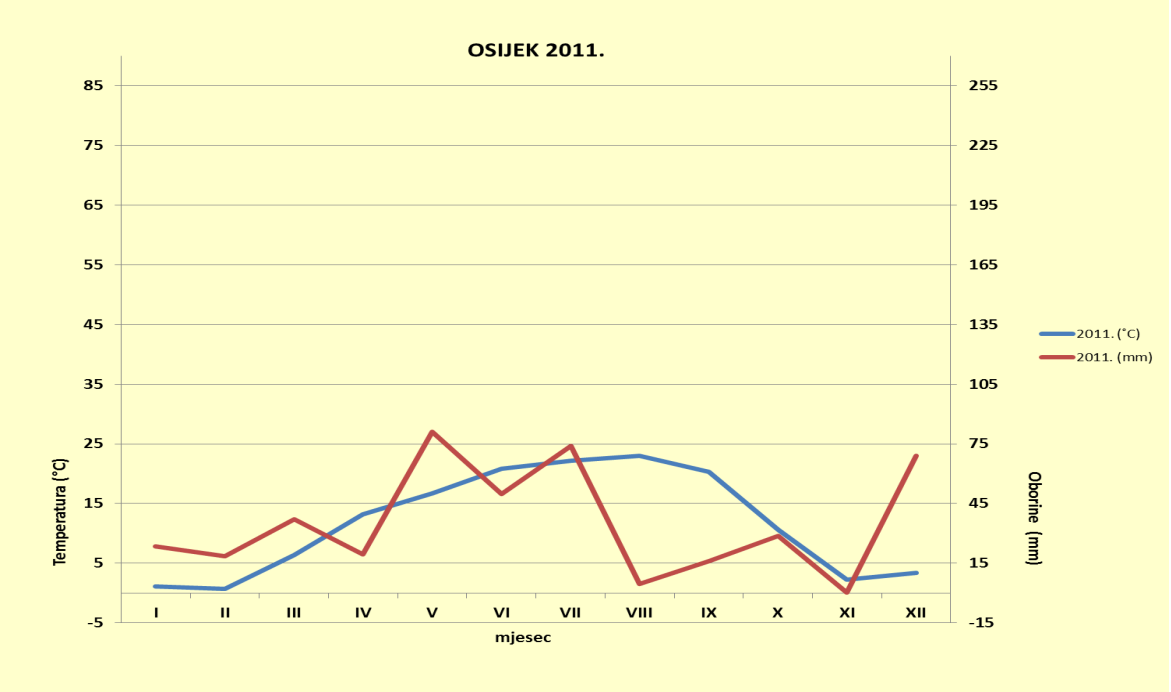
Grafikon 3. Klimadijagram po Walteru za 2010. godinu za Osijek.



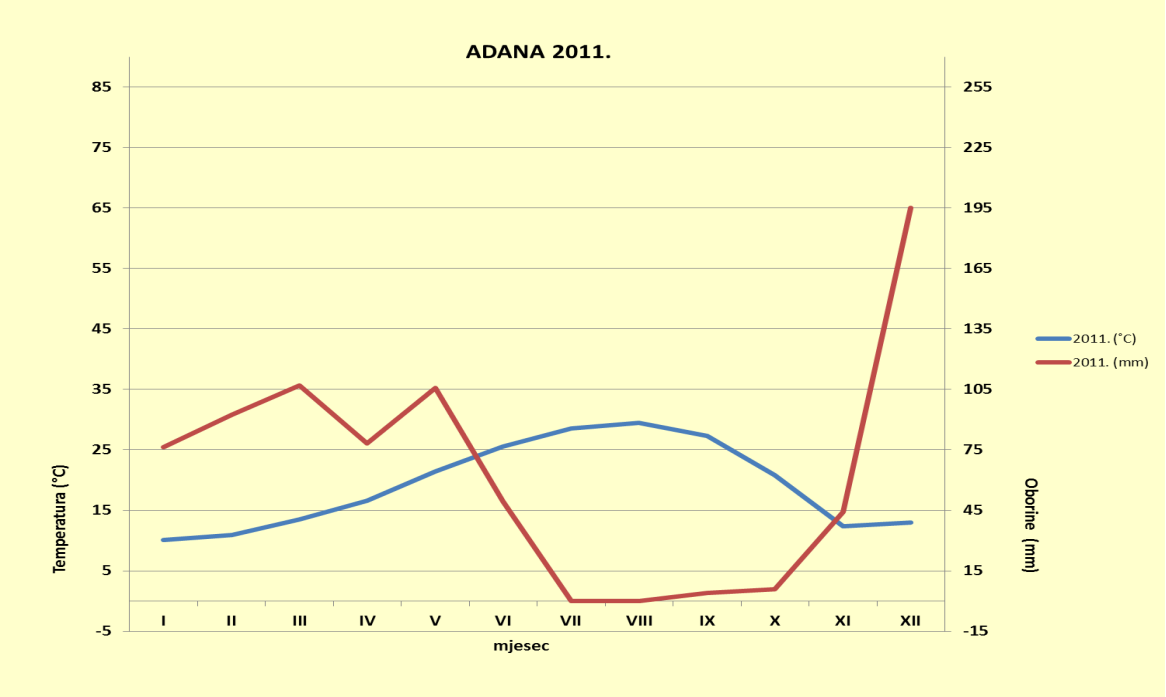
Grafikon 4. Klimadijagram po Walteru za 2010. godinu za Adanu.



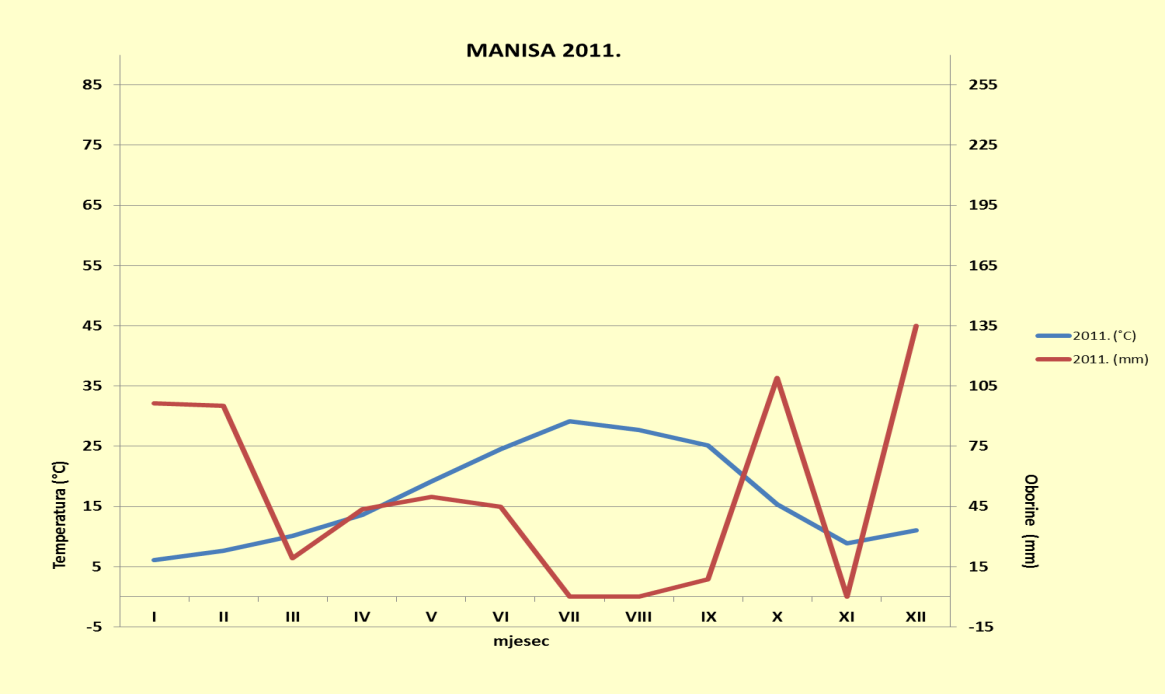
Grafikon 5. Klimadijagram po Walteru za 2010. godinu za Manisu.



Grafikon 6. Klimadijagram po Walteru za 2011. godinu za Osijek.



Grafikon 7. Klimadijagram po Walteru za 2011. godinu za Adanu.



Grafikon 8. Klimadijagram po Walteru za 2011. godinu za Manisu.

2.3. Metode biometričke analize

Zbog nedovoljnog sklopa biljaka u pokusu, iz izračuna su izostavljene ukupno 3 okoline – Adana – 1. sjetva 2010. godine, Adana – 1. sjetva 2011. godine i Mersin 2011. – 2. sjetva.

Svi podaci obrađeni su univarijatnom analizom varijance (ANOVA) uz t - test za ocjenu značajnosti razlika srednjih vrijednosti hibrida i okolina. Provedena je ANOVA za pojedinačne okoline (sveukupno 12 analiza), te kombinirana ANOVA kroz svih 12 okolina koristeći dvofaktorijelne i trofaktorijelne modele koje uključuju okoline i hibride, odnosno lokacije, godine i hibride kao glavne izvore variranja, te njihove interakcije. Rastavljenjem dvofaktorijelne interakcije hibrid x okolina izačunata su dva parametra stabilnosti svih hibrida: regresijski koeficijent i devijacija od regresije.

Od multivarijatnih tehnika koristi se “Pattern“ analiza. Teorijsku podlogu ovog postupka razradili su Wishart (1969.) i DeLacy i sur. (1996.).

Statistička analiza provest će se pomoću programskih paketa PLABSTAT (Utz, 1995.), GEBEI i STATISTICA.

2.3.1. Dvofaktorijelni i trofaktorijelni model ANOVA-e za lokacije i genotipove

Dvofaktorijelni model ANOVA-e uključuje u izračun lokacije, genotipove i interakciju genotip x lokacije (tablica 6.).

Tablica 6. Dvofaktorijelni model ANOVA–e po lokacijama.

Izvori Varijabilnosti	**Stupnjevi slobode**
Lokacije	E – 1
Genotipovi	G – 1
Genotipovi x lokacije	(G – 1)(E – 1)
Pogreška	GE(G – 1)(E – 1)

Kod trofaktorijelne ANOVA-e, u izračun osim lokacija i genotipova ulazi i godina kao faktor. To povlači za sobom i međusobne interakcije ova tri faktora (tablica 7.).

Tablica 7. Trofaktorijelni model ANOVA-e za genotipove koji se istražuju na nekoliko lokacija i u nekoliko godina.

Izvori Varijabilnosti	**Stupnjevi slobode**
Lokacije	L – 1
Godine	Y – 1
Genotipovi	G – 1
Godine x lokacije	(Y – 1)(L – 1)
Genotipovi x lokacije	(G – 1)(L – 1)
Genotipovi x godine	(G – 1)(Y – 1)
Genotipovi x godine x lokacije	(G – 1)(Y – 1)(L – 1)
Pogreška	YL(G – 1)(Y – 1)(L – 1)

2.3.2. Koeficijent regresije (b_i)

Koeficijent regresije (Finlay i Wilkinson, 1963.) predstavlja odnos *i*–tog genotipa prema različitim okolinama, odnosno specifičnu reakciju pojedinog genotipa na okolinske uvjete. Genotipovi karakterizirani s b_i oko 1 ocjenjuju se kao prosječno stabilni u svim okolinama. Ako uz to imaju i visok prosjek svojstva, smatraju se široko adaptabilnim, a ako je prosjek nizak onda su slabe adaptabilnosti. Vrijednosti b_i>1 ukazuju na ispodprosječnu stabilnost i veću prilagodljivost visokoprinosnim okolinama, dok su vrijednosti b_i<1 pokazatelj iznadprosječne stabilnosti i veće neosjetljivosti na promjene okoline, odnosno ukazuju na specifičnu prilagodljivost niskoprinosnim okolinama.

Koeficijent regresije se računa iz izraza:

$$b_i = \sum_{j=1}(x_{ij} - \bar{x}_i)(\bar{x}_j - \bar{x}_{..}) / \sum_{j=1}(\bar{x}_j - \bar{x}_{..})^2$$

$\boldsymbol{b}_i$ – koeficijent regresije,

$\boldsymbol{x}_{ij}$ - prosjek i-tog genotipa na j-toj lokaciji,

$\bar{\boldsymbol{x}}_i$ – zbroj prinosa i-tog genotipa na svim lokacijama,

$\bar{\boldsymbol{x}}_j$ – zbroj prinosa svih genotipova na j-tom lokalitetu,

$\bar{\boldsymbol{x}}_{..}$ – ukupan prosjek svih genotipova na svim lokalitetima.

2.3.3. Varijanca odstupanja od regresije (s^2_{di})

Varijanca odstupanja od regresije dobivena je iz sume kvadratnih razlika između očekivanih i dobivenih prinosa pa stoga predstavlja parametar stabilnosti koji se odnosi na nepredvidljivi dio varijabilnosti nekog genotipa (Becker i Leon, 1988.).

$$s^2_{di} = \frac{1}{(E-2)}\left[\sum_{j=1}(x_{ij} - x_i - x_j + x_{..})^2 - (b_i - 1)^2 \sum_{j=1}(x_j - x_{..})^2\right]$$

–

s^2_{di} – varijanca odstupanja od regresije,

b_i – koeficijent regresije,

E – broj okolina,

x_{ij} – prosjek *i*-tog genotipa na *j*-toj lokaciji,

x_i – zbroj prinos *i*-tog genotipa na svim lokacijama,

x_j – zbroj prinosa svih genotipova na *j*-tom lokalitetu,

$x_{..}$ – ukupan prosjek prinosa svih genotipova na svim lokalitetima.

Isti autori navode da su prema ovom parametru stabilni oni genotipovi koji imaju niže s^2_{di} vrijednosti. Ovaj parametar stabilnosti je u funkciji broja okolina, odnosno potrebno je imati što više okolina u istraživanju s minimalnim brojem ponavljanja da bi se dobile objektivne vrijednosti s^2_{di}.

2.3.4. Cluster i Pattern analiza

Izraz cluster analysis obuhvaća određeni broj različitih algoritama i metoda grupiranja predmeta slične vrste u pripadajuće kategorije. Ova analiza jednostavno otkriva pojedine cjeline, strukture unutar podataka, bez objašnjenja zašto one postoje.

Nakon što je izračunata suma kvadrata (MS) i podijeljena između G, E i GxE, testirana je, uključujući pogrešku (Fox i Rosielle, 1982.). Prije cluster analize potrebno je standardizirati matricu uroda unutar okolina čime je okolinski efekt, koji ima najveće značenje, uklonjen, i ostatak podijeljen sa standardnom devijacijom unutar okolina. Pattern analiza koristi standardiziranu matricu, u ovom slučaju matricu uroda zrna. Standardizacija je provedena po formuli:

$$Yij = (Yij - Jj) / Sd$$

Yij – prosječna vrijednost i-tog genotipa i j-te okoline,

Jj – grupa j-tih okolina,

Sd – standardna devijacija unutar okolina.

Standardizacija okolina vodi u grupiranje onih okolina koje su slične prema poretku genotipova. Genotipovi unutar neke skupine imaju slične vrijednosti promatranih svojstava, u ovom slučaju prinosa.

Hijerarhijsko udruživanje klastera korištenjem sume kvadrata (Ward, 1963.) kao kriterija fuzije ili udruživanja, bilo je primjenjeno na matricu, odnosno u jedan dio dendrograma, i članovi ili skupine pridruženi su u nove skupine unutar određenih suma kvadrata. Dendrogrami su napravljeni na osnovi udruživanja nivoa ispitivane sličnosti u uzorku nekog svojstva između genotipova (npr: reakcija na okoline) ili između okolina (npr: u zapaženim razlikama među genotipovima).

Iz standardizirane matrice uroda, izračuna se kvadrat Euklidove distance za genotipove i lokacije, (kao mjera različitosti nekog svojstva, potrebna nadopuna Wardovoj metodi):

$$d^2 = \sum_{i=1}^{n} (x_{1i} - x_{2i})^2$$

$\boldsymbol{d^2}$ – kvadrat Euklidove distance,

$\boldsymbol{x_{1i}}$ – opažanja *i*-tog genotipa ili *j*-te lokacije,

$\boldsymbol{x_{2i}}$ – opažanja *i*-tog genotipa ili *j*-te lokacije.

3. REZULTATI ISTRAŽIVANJA

U tablici 8. prikazani su rezultati analize varijance za prinos zrna na lokacijama Osijek i Karanac, tijekom 2010. godine. Vidljivo je da je prinos značajno varirao po ponavljanjima u Osijeku, gdje je ta varijacija statistički visoko značajna, uz P<0,01. Osnovni razlog zašto se to dogodilo u Osijeku je vrlo velika količina kiše tijekom ove godine i budući da je pokusno polje bilo praktično zasićeno vodom, i male razlike između ponavljanja (više ili manje vode) imale su za posljedicu variranje ostvarenog prinosa po ponavljanjima. U Karancu to nije bio slučaj. Statistički značajno variranje prinosa zabilježeno je na lokaciji Karanac, uz P<0,05.

Tablica 8. ANOVA za prinos zrna po lokacijama Osijek i Karanac u 2010. godini.

Izvor variranja	Stupnjevi slobode	Prosječno kvadratno odstupanje (MS)	
		Osijek	Karanac
Repeticija	1	6.3703**	3.6340
Hibrid	21	1.1704	4.0567*
Ostatak	21	0.7240	1.8295

** F test značajan na razini P>0,01
* F test značajan na razini P>0,05

U tablici 9. nalazi se pregled ostvarenih prinosa ispitivanih hibrida na lokacijama Osijek i Karanac u 2010. godini. Na lokaciji Osijek ostvarena je srednja vrijednost prinosa svih hibrida – 12,23 t/ha, što je za 2,05 t/ha više nego u Karancu. Niti jedan hibrid nije bio statistički značajno rodniji od srednje vrijednosti prinosa pokusa, ali dva su hibrida ostvarila prinos veći od 13 t/ha – hibrid pod rednim brojem 5 – 13,36 t/ha i jedan od hibrida koji predstavlja standardni hibrid za provjeru ostalih hibrida u pokusu – PR31G98 – 13,15 t/ha. Niti jedan hibrid nije imao statistički značajno manji prinos, ali hibridi pod brojevima 4 – 10,66 t/ha i 19 – 10,82 t/ha ostvarili su osjetno niže prinose od srednje vrijednosti pokusa.

U Karancu je zabilježen veći raspon variranja prinosa ispitivanih hibrida, što je vidljivo i iz tablice 8. Nema statistički značajno rodnijih hibrida, a najviši prinos ostvario je hibrid standard pod rednim brojem 22 – PR31G98 – 12,29 t/ha, a slijede ga hibridi pod brojem 15 – 12,11 t/ha i 16 – 12,09 t/ha.

U tablici 9. nalazi se pregled ostvarenih prinosa ispitivanih hibrida na lokacijama Osijek i Karanac u 2010. godini. Na lokaciji Osijek ostvarena je srednja vrijednost prinosa svih hibrida – 12,23 t/ha, što je za 2,05 t/ha više nego u Karancu. Niti jedan hibrid nije bio statistički značajno rodniji od srednje vrijednosti prinosa pokusa, ali dva su hibrida ostvarila prinos veći od 13 t/ha – hibrid pod rednim brojem 5 – 13,36 t/ha i jedan od hibrida koji predstavlja standardni hibrid za provjeru ostalih hibrida u pokusu – PR31G98 – 13,15 t/ha. Niti jedan hibrid nije imao statistički značajno manji prinos, ali hibridi pod brojevima 4 – 10,66 t/ha i 19 – 10,82 t/ha ostvarili su osjetno niže prinose od srednje vrijednosti pokusa.

U Karancu je zabilježen veći raspon variranja prinosa ispitivanih hibrida, što je vidljivo i iz tablice 8. Nema statistički značajno rodnijih hibrida, a najviši prinos ostvario je hibrid standard pod rednim brojem 22 – PR31G98 – 12,29 t/ha, a slijede ga hibridi pod brojem 15 – 12,11 t/ha i 16 – 12,09 t/ha.

Isto tako, nema niti hibrida čiji bi prinos bio statistički značajno niži. Najniži prinos u pokusu imao je hibrid pod brojem 9 – 7,47 t/ha, a vrlo niske prinose ostvarili su i hibridi broj 5 – 8,06 t/ha, 20 – 8,44 t/ha, 10 – 8,61 t/ha i 12 – 8,63 t/ha. Raspon variranja prinosa, od najvišeg – 12,29 t/ha do najnižeg – 7,47 t/ha bio je čak 4,82 t/ha.

Tablica 9. Srednje vrijednosti prinosa zrna (t/ha) po lokacijama Osijek i Karanac u 2010. godini.

Hibrid	Osijek	Karanac
1	12,37	11,08
2	12,78	10,08
3	12,95	11,62
4	10,66	9,13
5	13,36	8,06
6	12,98	9,40
7	12,78	9,54
8	11,19	9,30
9	11,28	7,47
10	12,36	8,61
11	12,70	11,19
12	11,72	8,63
13	11,82	11,60
14	12,60	11,60
15	12,12	12,11
16	12,32	12,09
17	12,90	10,39
18	12,54	10,28
19	10,82	10,28
20	11,42	8,44
21	12,28	10,69
22	13,15	12,29
Prosjek	12,23	10,18
LSD 0,05	1,77	2,81

U tablici 10. prikazani su rezultati analize varijance za prinos zrna na lokacijama u Turskoj – 1. sjetva tijekom 2010. godine. Zbog problema sa nedovoljnim sklopom hibrida, u obračun nije uvrštena lokacija Adana. Statistički značajno variranje prinosa po ponavljanjima bilo je na lokaciji Altinova, uz $P<0,01$. Izravni uzrok ovog variranja je neravnomjeran raspored dodane vode tijekom navodnjavanja, kada su jedni hibridi imali

višak, a drugi manjak vode tijekom vegetacije. Između ispitivanih hibrida prinos je statistički značajno varirao na lokaciji Mersin, uz P<0,05.

Tablica 10. ANOVA za prinos zrna po lokacijama Altinova, Manisa i Mersin - 1. sjetva u 2010. godini.

Izvor variranja	Stupnjevi slobode	Prosječno kvadratno odstupanje (MS)		
		Altinova	Manisa	Mersin
Repeticija	1	18.3051**	0.0120	1.9484
Hibrid	21	2.8888	6.5731	2.7404*
Ostatak	21	1.8461	6.3181	1.0605

** F test značajan na razini P>0,01
* F test značajan na razini P>0,05

U tablici 11. nalazi se pregled ostvarenih prinosa hibrida tijekom 1. sjetve u Turskoj, u 2010. godini. Daleko najveći ostvareni prinos ostvaren je na lokaciji Manisa – 15,01 t/ha, ali i uz najveće variranje prinosa unutar pokusa (LSD 0,05 = 5,23).

Hibrid sa najvišim prinosom (iako ne i statistički značajnije prinosniji od srednje vrijednosti prinosa pokusa) u Manisi bio je standardni hibrid PR31G98 – 18,07 t/ha. Ovako visoki prinosi (kako u srednjoj vrijednosti prinosa, tako i kad gledamo najviši ostvareni prinos u ovom pokusu) rezultat su poklapanja niza povoljnih činjenica tijekom vegetacije - ostvareni 100 % sklop, ujednačena i izbalansirana gnojidba, pridržavanje plodoreda (zbog izbjegavanja jačeg napada kukuruznog moljca), te ravnomjeran raspored dodane vode tijekom navodnjavanja u redove ispitivanih hibrida.

Visinom prinosa u ovom pokusu ističu su i hibrid pod rednim brojem 3 – 17,35 t/ha, te standardni hibrid broj 21 – Shemal – 16,86 t/ha, zatim hibridi broj 12 – 16,68 t/ha, 2 – 16,39 t/ha, 16 – 16,14 t/ha i 20 – 16,13 t/ha. Izrazito najniži prinos ostvario je hibrid broj 15 – 10,13 t/ha, a osjetno niže prinose od srednje vrijednosti pokusa ostvarili su i hibridi 4 – 12,51 t/ha, 6 – 12,64 t/ha i 19 – 13,10 t/ha.

Srednja vrijednost prinosa hibrida na lokaciji Mersin bila je 11,20 t/ha. Najviši prinos (i statistički značajno viši) ostvarili su hibridi broj 2 – 13,50 t/ha, 8 – 13,37 t/ha i 1 – 13,17 t/ha. Nizak prinos u Mersinu imali su hibridi broj 4 – 9,72 t/ha i broj 6 – 9,97 t/ha, ali ne statistički značajno.

Tablica 11. Srednje vrijednosti prinosa zrna (t/ha) po lokacijama Altinova, Manisa i Mersin – 1. sjetva u 2010. godini.

Hibrid	Altinova	Manisa	Mersin
1	8,07	14,05	13,17
2	9,98	16,39	13,50
3	9,33	17,35	12,30
4	7,28	12,51	9,72
5	8,37	15,17	11,14
6	6,84	12,64	9,97
7	9,13	14,95	10,08
8	8,87	14,93	13,37
9	8,91	14,07	10,19
10	8,72	15,25	10,57
11	7,27	14,10	10,32
12	6,43	16,68	10,78
13	9,57	15,71	10,71
14	9,06	15,56	12,35
15	7,96	10,13	10,44
16	10,95	16,14	10,65
17	9,82	15,75	10,50
18	8,71	14,63	11,42
19	9,50	13,10	10,50
20	9,85	16,13	12,55
21	10,98	16,86	11,85
22	9,45	18,07	10,41
Prosjek	8,87	15,01	11,20
LSD 0,05	2,83	5,23	2,14

Najniža srednja vrijednost prinosa u 1. sjetvi u Turskoj 2010. godine, ostvarena je na lokaciji Altinova – 8,87 t/ha. To se dogodilo zbog problema u distribuciji vode prilikom navodnjavanja i pojedini hibridi imali su višak, a pojedini manjak vode tijekom vegetacije. Stoga je ostvareni prinos na ovoj lokaciji bio niži u prvoj sjetvi nego u 2. sjetvi (tablica 13.). To u pravilu nije slučaj, već je prinos u prvoj sjetvi viši od prinosa u drugoj sjetvi, u

istoj godini, na istoj lokaciji, za 30 – 35 %. Visinom prinosa izdvojili su se standardni hibrid 21 – 10,98 t/ha i hibrid broj 16 – 10,95 t/ha. Izrazito nizak prinos ostvarili su hibridi broj 12 - 6,43 t/ha i broj 6 – 6,84 t/ha, ali to nije bio i statistički značajno niži prinos.

U tablici 12. prikazani su rezultati analize varijance za prinos zrna na lokacijama u Turskoj – 2. sjetva tijekom 2010. godine. Zabilježeno je statistički značajno variranje prinosa po ponavljanjima na lokaciji Altinova. Između ispitivanih hibrida prinos je statistički značajno varirao na lokaciji Mersin, uz P<0,01 a zabilježena su i značajna variranja prinosa hibrida na lokaciji Altinova, na razini P<0,05.

Tablica 12. ANOVA za prinos zrna po lokacijama Altinova, Manisa, Mersin i Adana – 2. sjetva u 2010. godini.

Izvor variranja	Stupnjevi slobode	Prosječno kvadratno odstupanje (MS)			
		Altinova	Manisa	Mersin	Adana
Repeticija	1	2.5805*	0.8909	0.0683	1.2699
Hibrid	21	4.7011*	5.4683	3.4742**	1.6737
Ostatak	21	2.4269	1.3715	0.4011	1.0342

** F test značajan na razini P>0,01
* F test značajan na razini P>0,05

Iz tablice 13. možemo uočiti da je najviša srednja vrijednost uroda ispitivanih hibrida u 2. sjetvi u Turskoj, u 2010. godini bila na lokaciji Adana – 12,32 t/ha. Najveći prinos ima član pokusa broj 12 – 13,73 t/ha a prinos iznad 13 t/ha imala su još 4 hibrida, broj 21 – 13,47 t/ha, broj 5 – 13,38 t/ha, broj 14 – 13,23 t/ha i broj 22 – 13,03 t/ha. Niti jedan od tih prinosa nije bio statistički značajno veći od srednje vrijednosti prinosa pokusa. Jedini hibrid sa statistički značajno nižim prinosom i jedini koji je imao prinos manji od 10 t/ha bio je hibrid broj 4 – 9,69 t/ha.

Tablica 13. Srednje vrijednosti prinosa zrna (t/ha) po lokacijama Altinova, Manisa, Mersin i Adana - 2. sjetva u 2010. godini.

Hibrid	Altinova	Manisa	Mersin	Adana
1	9,72	8,47	2,89	12,28
2	10,64	12,27	6,31	12,52
3	11,16	10,29	6,51	12,36
4	9,12	8,82	3,49	9,69
5	8,28	12,07	4,99	13,38
6	6,94	7,34	4,59	11,97
7	9,12	7,49	3,21	10,90
8	10,40	10,04	3,11	11,43
9	7,34	9,98	4,40	12,49
10	8,39	9,74	5,72	12,79
11	10,74	9,33	5,07	12,72
12	8,51	7,99	3,81	13,73
13	11,17	10,31	5,79	12,19
14	7,59	6,89	4,22	13,23
15	7,92	8,68	4,23	12,61
16	11,12	7,49	4,39	12,94
17	8,89	9,66	5,03	11,96
18	8,13	6,86	2,99	11,19
19	9,07	9,79	4,66	12,28
20	10,05	11,49	4,97	12,98
21	12,05	11,87	7,36	13,47
22	12,13	10,36	7,38	13,03
Prosjek	9,48	9,42	4,78	12,32
LSD 0,05	3,24	2,44	1,32	2,11

Na lokaciji Altinova ostvarena je srednja vrijednost prinosa od 9,48 t/ha. Najviše prinose, ali ne i statistički značajno različite od srednje vrijednosti prinosa pokusa, dali su hibridi standardi, 22 – 12,13 t/ha i 21 – 12,05 t/ha. Zatim, slijede 3 hibrida sa prinosima iznad 11 t/ha, broj 13 – 11,17 t/ha, 3 – 11,16 t/ha i 16 – 11,12 t/ha. Najniži prinos, ne i

statistički značajno niži – 6,94 t/ha, imao je hibrid broj 6, a prinose ispod 8 t/ha ostvarili su hibridi broj 9 – 7,34 t/ha, 14 – 7,59 t/ha i 15 – 7,94 t/ha.

U Manisi je ostvarena srednja vrijednost prinosa zrna hibrida od 9,42 t/ha. Prinosom dominiraju hibridi broj 2 – 12,27 t/ha i 5 – 12,07 t/ha, sa statistički značajno većim prinosom od srednje vrijednosti prinosa pokusa. Visoke prinose ostvarili su i hibridi broj 21 – 11,87 t/ha i 20 – 11,49 t/ha. Najniže prinose, statistički značajno niže, ostvarili su hibrid broj 18 – 6,86 t/ha i 16 – 6,89 t/ha.

Najniža srednja vrijednost prinosa u 2. sjetvi u Turskoj 2010. godine (a isto tako i najniža uopće ostvarena srednja vrijednost prinosa od svih provedenih lokacija i godina) zabilježena je na lokaciji Mersin – 4,78 t/ha. Ovako nizak prinos posljedica je kombinacije nedovoljnog sklopa ispitivanih hibrida i neuspjeha prilikom suzbijanja korova u pokusu.

Ipak, ovi su rezultati stavljeni u ukupnu analizu jer su članovi pokusa koji su nam poslužili kao standardi (broj 21 – 7,36 t/ha i 22 – 7,38 t/ha) i ovdje ostvarili najbolje rezultate, a odmah iza njih bili su hibridi broj 2 – 6,31 t/ha i 3 – 6,51 t/ha, koji su i na drugim lokacijama davali dobre rezultate, pa se činilo da iako nizak prinos hibrida, ipak ima vrijednost, i da je poredak hibrida više manje sličan kao i na drugim lokacijama te godine. Ova 4 hibrida ostvarila su i statistički značajno više prinose od srednje vrijednosti pokusa.

Najniži prinos (niži nego je to slučaj kod prinosa inbred linija u proizvodnji sjemena kukuruza) bio je kod broja 1 – 2,89 t/ha, broja 18 – 2,99 t/ha, te kod brojeva 7 – 3,28 t/ha i 8 – 3,11 t/ha. U svim tim slučajevima radilo se o statistički značajno nižim prinosima.

Tablica 14. ANOVA za prinos zrna po lokacijama Osijek i Karanac u 2011. godini.

Izvor variranja	Stupnjevi slobode	Prosječno kvadratno odstupanje (MS)	
		Osijek	Karanac
Repeticija	1	0.0538	0.0104
Hibrid	21	0.9435	2.0078
Ostatak	21	1.1835	1.2300

** F test značajan na razini P>0,01
* F test značajan na razini P>0,05

U tablici 14. prikazani su rezultati analize varijance za prinos zrna na lokacijama u Hrvatskoj tijekom 2011. godine. Nije zabilježeno statistički značajno variranje prinosa po

ponavljanjima ni u Osijeku ni u Karancu. Između ispitivanih hibrida prinos također nije statistički značajno varirao.

Tablica 15. Srednje vrijednosti prinosa zrna (t/ha) po lokacijama Osijek i Karanac u 2011. godini.

Hibrid	Osijek	Karanac
1	10,26	7,33
2	11,40	7,46
3	9,91	8,27
4	10,33	8,69
5	11,05	10,16
6	9,94	7,32
7	11,33	8,95
8	11,45	10,16
9	11,17	8,80
10	9,27	8,27
11	10,52	7,18
12	11,39	10,08
13	11,11	9,90
14	11,96	9,17
15	12,06	8,15
16	11,10	8,09
17	10,66	9,44
18	10,72	10,18
19	10,81	8,45
20	11,58	9,30
21	10,39	7,53
22	10,68	8,73
Prosjek	10,87	8,71
LSD 0,05	2,26	2,31

Tijekom 2011. godine dogodio se sušni period (tablica 3.) tijekom mjeseca kolovoza u Hrvatskoj, što je rezultiralo smanjenim prinosima hibrida kukuruza uključenih u ovo ispitivanje. Viša ostvarena srednja vrijednost prinosa bila je na lokaciji Osijek –

10,87 t/ha (tablica 15.). Jedino je hibrid broj 15 imao prinos iznad 12 t/ha – 12,06 t/ha što nije bilo i statistički značajno više, ali čak 10 hibrida imalo je prinos iznad 11 t/ha, i to je pokazatelj da je pokus dobro postavljen i proveden. To pokazuje i podatak iz tablice 14. gdje vidimo da nije bilo statistički značajnih razlika niti između ponavljanja, niti između prinosa hibrida. Najniži prinos, ne i statistički značajno, imao je hibrid 10 – 9,27 t/ha, a niskim prinosom izdvajaju se i hibrid broj 3 – 9,91 t/ha i 6 – 9,94 t/ha.

U Karancu je srednja vrijednost prinosa bila 8,71 t/ha. Najviše prinose, ne i statistički značajno, ostvarili su hibridi 5 i 8 sa istim prinosom od 10,16 t/ha, te hibridi 12 i 18 – također, sa istim prinosima – 10,08 t/ha. Čak 5 hibrida imalo je prinose niže od 8 t/ha, broj 11 – 7,18 t/ha, 6 – 7,32 t/ha, 1 – 7,33 t/ha, 2 – 7,46 t/ha i 21 – 7,53 t/ha, ali je to sve bilo u okviru statističke neznačajnosti.

U tablici 16. prikazani su rezultati analize varijance za prinos zrna na lokacijama u Turskoj – 1. sjetva tijekom 2011. godine. Zabilježeno je statistički značajno variranje prinosa po ponavljanjima na lokaciji Mersin, iz $P<0,05$. Između ispitivanih hibrida prinos je statistički značajno varirao na lokacijama Mersin i Manisa, uz $P<0,01$.

Tablica 16. ANOVA za prinos zrna po lokacijama Altinova, Manisa i Mersin – 1. sjetva u 2011. godini.

Izvor variranja	Stupnjevi slobode	Prosječno kvadratno odstupanje (MS)		
		Altinova	Manisa	Mersin
Repeticija	1	15.4856	0.8201	3.5608*
Hibrid	21	4.7264	5.5502**	2.6114**
Ostatak	21	11.0530	1.2187	0.8408

** F test značajan na razini P>0,01
* F test značajan na razini P>0,05

Tijekom 2011. godine, u prvoj sjetvi u Turskoj, nije bilo moguće koristiti podatke sa lokacije Adana zbog nedovoljnog sklopa ispitivanih hibrida. Na ostalim lokacijama (tablica 17.) ostvareni su vrlo visoke srednje vrijednosti prinosa. Najviši prinos ostvaren je u Altinovi – 15,86 t/ha. Za suho ratarenje gotovo nezamislivih 19,44 t/ha ostvario je hibrid broj 9. Čak 5 hibrida imalo je prinos veći od 17 t/ha, broj 11 – 17,78 t/ha, 3 – 17,48 t/ha, 13 – 17,58 t/ha, 16 – 17,40 t/ha i 22 – 17,24 t/ha. Svi ti prinosi bili su statistički neznačajno različiti od srednje vrijednosti pokusa. Osjetno niži prinos, ne i statistički značajno, od srednje vrijednosti pokusa imao je hibrid broj 18 – 12,61 t/ha.

Tablica 17. Srednje vrijednosti prinosa zrna (t/ha) po lokacijama Altinova, Manisa i Mersin – 1. sjetva u 2011. godini.

Hibrid	Altinova	Manisa	Mersin
1	15,13	14,69	12,95
2	16,18	14,87	15,10
3	17,48	18,23	14,95
4	16,19	15,32	14,01
5	14,33	15,08	15,08
6	14,75	13,83	14,86
7	15,04	14,40	13,99
8	14,55	13,16	13,41
9	19,44	15,60	14,49
10	16,52	13,92	13,96
11	17,78	16,33	14,75
12	15,91	14,67	10,93
13	17,58	13,53	14,96
14	14,28	13,90	13,83
15	16,37	18,49	13,23
16	17,40	15,29	12,22
17	14,97	13,47	14,84
18	12,61	16,48	15,36
19	14,73	13,53	12,95
20	15,20	18,48	14,14
21	15,34	17,18	15,68
22	17,24	16,43	14,88
Prosjek	15,86	15,31	14,12
LSD 0,05	6,91	2,30	1,91

Lokacija Manisa imala je srednju vrijednost prinosa od 15,31 t/ha.

Hibrid broj 3 imao je prinos od 18,23 t/ha, broj 15 – 18,49 t/ha a broj 20 – 18,48 t/ha. Ta tri hibrida imala su statistički značajno viši prinos od srednje vrijednosti pokusa. Prinos iznad 17 t/ha ima hibrid broj 21 – 17,18 t/ha. Iznad 16 t/ha prinos su ostvarili i

hibridi broj 11 – 16,33 t/ha, 18 – 16,48 t/ha i 22 – 16,43 t/ha. Niti jedan hibrid nije bio statistički značajno nižeg prinosa od srednje vrijednosti prinosa pokusa.

Srednja vrijednost prinosa u Mersinu bila je 14,12 t/ha. Niti jedan hibrid nije bio statistički značajno rodniji od prosjeka pokusa, a po visini prinosa prednjače brojevi 21 – 15,68 t/ha, 18 – 15,36 t/ha, 2 – 15,10 t/ha i 5 – 15,08 t/ha. Statistički značajno manji prinos od srednje vrijednosti pokusa imao je hibrid broj 12 – 10,93 t/ha, te broj 16 – 12,22 t/ha.

U tablici 18. prikazani su rezultati analize varijance za prinos zrna na lokacijama u Turskoj – 2. sjetva tijekom 2011. godine. Lokacija Mersin nije zadovoljila kriterije – sklop manji od 80 %, dosta korova, zakašnjelo vrijeme sjetve u odnosu na kukuruz u okruženju. Nije zabilježeno statistički značajno variranje prinosa po ponavljanjima niti na jednoj lokaciji. Između ispitivanih hibrida prinos je statistički značajno varirao na lokacijama Altinova i Manisa, uz P<0,01.

Tablica 18. ANOVA za prinos zrna po lokacijama Altinova, Manisa i Adana - 2. sjetva u 2011. godini.

Izvor variranja	Stupnjevi slobode	Prosječno kvadratno odstupanje (MS)		
		Altinova	Manisa	Adana
Repeticija	1	0.3483	0.021	2.6539
Hibrid	21	6.0435**	3.2629**	1.5934
Ostatak	21	1.4792	0.6364	2.3802

** F test značajan na razini P>0,01
* F test značajan na razini P>0,05

Najveći prinos u 2. sjetvi u Turskoj u 2011. godini (tablica 19.) ostvaren je na lokaciji Altinova – 11,91 t/ha. Samo jedan hibrid ostvario je prinos statistički značajno veći od srednje vrijednosti prinosa, broj 8 – 14,60 t/ha, a visinom prinosa ističu se i broj 3 – 14,04 t/ha i 17 – 14,05 t/ha. Veći broj hibrida ima statistički značajno niži prinos od srednje vrijednosti pokusa, broj 5 – 9,60 t/ha, 7 – 8,56 t/ha, 11 – 8,48 t/ha i broj 20 – 9,66 t/ha.

Na lokaciji Manisa ostvarena je srednja vrijednost prinosa hibrida od 10,64 t/ha. Hibridi pod brojevim 21 – 12,50 t/ha i 15 – 12,37 t/ha ostvarili su prinose statistički značajnije više od srednje vrijednosti prinosa pokusa. Isto tako, tri hibrida, broj 7 – 8,29 t/ha, broj 10 – 8,57 t/ha i broj 8 – 8,68 t/ha imala su statistički značajno niži prinos.

Tablica 19. Srednje vrijednosti prinosa zrna (t/ha) po lokacijama Altinova, Manisa i Adana – 2. sjetva u 2011. godini.

Hibrid	Altinova	Manisa	Adana
1	12,65	9,18	9,46
2	11,35	10,34	10,60
3	14,04	11,34	9,07
4	13,30	9,22	8,16
5	9,60	10,47	10,26
6	11,23	11,75	9,26
7	8,56	8,29	8,84
8	14,60	8,68	10,27
9	12,74	11,27	8,96
10	11,51	8,57	9,51
11	8,48	9,93	10,31
12	10,72	12,20	8,78
13	12,16	10,84	10,82
14	10,25	10,80	9,71
15	13,02	12,37	10,62
16	13,18	11,62	10,46
17	14,05	11,62	11,25
18	10,65	9,74	9,41
19	12,16	12,06	8,71
20	9,66	11,75	10,98
21	12,72	12,50	10,42
22	12,99	10,62	9,92
Prosjek	11,91	10,64	9,76
LSD 0,05	2,53	1,66	3,21

Na lokaciji Adana, srednja vrijednost prinosa bila je 9,76 t/ha. Prinos je svih hibrida bio vrlo ujednačen tako da niti jedan hibrid nije imao statistički značajno veći prinos od srednje vrijednosti pokusa, a isto tako, niti jedan hibrid nije značajno odstupao kao niže rodan u istom pokusu.

Skupna analiza varijance (tablica 20.) za sve lokacije i godine u Hrvatskoj i Turskoj ukazuje na to da su vrlo značajni izvori variranja i lokacije i genotipovi i interakcija GxE, uz P<0,01.

Tablica 20. Skupna ANOVA za sve okoline i godine (Hrvatska i Turska 1. i 2. sjetva) u 2010. i 2011. godini.

Izvor variranja	Stupnjevi slobode	Prosječno kvadratno odstupanje (MS)
Okolina - E	16	176.7300**
Hibrid - G	21	6.3906**
G x E	336	1.3868**
Pogreška	357	1.0022

** F test značajan na razini P>0,01
* F test značajan na razini P>0,05

Usporedba svih okolina u obje godine prema srednjoj vrijednosti prinosa zrna ispitivanih hibrida (tablica 21.) ukazuje na vrlo veliko variranje, veliki raspon ostvarenih prinosa između okolina. Najveći ostvareni prinosi, u pravilu, ostvareni su u prvoj sjetvi u Turskoj, gdje su uglavnom postojali uvjeti za ostvarivanje genetskog potencijala hibrida, i gdje je podbačaj u prinosu uglavnom bio posljedica promašaja u agrotehnici (nagib terena i problemi sa navodnjavanjem (Altinova 2010. godine)) i zakašnjenje u terminu sjetve (Mersin, 2010. godine). U većini slučajeva srednja vrijednost prinosa na takvim okolinama je statistički značajno veća od srednje vrijednosti prinosa svih ostalih okolina, sa najvećim prinosom od 15,86 t/ha u Altinovi 2011. godine. Srednja vrijednost prinosa hibrida na svim okolinama, u obje godine bila je 11,22 t/ha.

Osim 1. sjetve u Turskoj, statistički značajno viši prinos od srednje vrijednosti prinosa pokusa ostvaren je na okolinama Osijek 2010. – 12,23 t/ha i Adana 2010., 2. sjetva – 12,32 t/ha.

Okoline sa statistički značajno nižim prinosom od srednje vrijednosti prinosa svih okolina bile su, prije svega Mersin, 2010., 2.sjetva – 4,78 t/ha, Karanac 2010. – 10,18 t/ha, Altinova 2010., 1. sjetva – 8,87 t/ha, Altinova 2010., 2.sjetva – 9,48 t/ha, Manisa 2010., 2.sjetva – 9,42 t/ha, Karanac 2011. – 8,71 t/ha i Adana 2011., 2.sjetva – 9,76 t/ha. Isto tako, vidljivo je da je u obje godine srednja vrijednost prinosa hibrida bila veća u Osijeku nego u Karancu. U 2010. godini razlika je bila čak 2,05 t/ha, a u 2011. godini ta razlika bila je 1,86 t/ha. Vrlo je uočljivo i da je prinos hibrida u drugoj sjetvi u Turskoj značajno niži od

onoga u prvoj sjetvi, na istoj lokaciji, u istoj godini. Radi se o razlici od 4 - 5 t/ha, kada govorimo o godinama i okolinama koje su imale optimalne uvjete za postizanje prinosa (Manisa 2010., 1. sjetva – 15,21 t/ha prema Manisa 2010., 2. sjetva – 9,42 t/ha, Manisa 2011. godina, 1. sjetva – 15,31 t/ha, prema Manisa 2011. godine, 2. sjetva – 10,64 t/ha, Altinova 2011., 1. sjetva – 15,86 t/ha, prema Altinova 2011. godine, 2. sjetva – 11,81 t/ha). To je smanjenje prinosa od 35 - 40 % u 2. sjetvi u odnosu na prvu.

Tablica 21. Srednje vrijednosti prinosa zrna hibrida (t/ha) po okolinama u Hrvatskoj i Turskoj u 2010. i 2011. godini.

Okolina	Oznaka okoline	Brojčana oznaka okoline	Srednja vrijednost prinosa zrna
Osijek 2010.	OS 2010	1	12,23
Karanac 2010.	KA 2010	2	10,18
Altinova 2010/1. sjetva	ALT 2010/1	3	8,87
Manisa 2010/1. sjetva	MAN 2010/1	4	15,21
Mersin 2010/1. sjetva	MER 2010/1	5	11,20
Altinova 2010/2. sjetva	ALT 2010/2	6	9,48
Manisa 2010/2. sjetva	MAN 2010/2	7	9,42
Mersin 2010/2. sjetva	MER 2010/2	8	4,78
Adana 2010/2. sjetva	AD 2010/2	9	12,32
Osijek 2011.	OS 2011	10	10,87
Karanac 2011.	KA 2011	11	8,71
Altinova 2011/1. sjetva	ALT 2011/1	12	15,86
Manisa 2011/1. sjetva	MAN 2011/1	13	15,31
Mersin 2011/1.sjetva	MER 2011/1	14	14,12
Altinova 2011/2. sjetva	ALT 2011/2	15	11,81
Manisa 2011/2. sjetva	MAN 2011/2	16	10,64
Adana 2011/2. sjetva	AD 2011/2	17	9,76
Sred. vrij. prinosa svih okol.			11,22
LSD 0,05			0,70

Ako analiziramo srednju vrijednost prinosa zrna hibrida, kroz sve okoline u Hrvatskoj i Turskoj, u obje godine (tablica 22.), veliki broj hibrida uklopljen je u ukupnu

srednju vrijednost prinosa svih hibrida od 11,22 t/ha. Statistički značajno veći prinos od srednje vrijednosti prinosa imaju samo tri hibrida – broj 21, standardni hibrid Shemal – 12,30 t/ha, broj 22, standardni hibrid PR31G98 – 12,22 t/ha i hibrid broj 3, OSSK 613 – 12,19 t/ha.

Tablica 22. Srednje vrijednosti prinosa zrna hibrida (t/ha) na svim okolinama u Hrvatskoj i Turskoj u 2010. i 2011. godini.

Hibrid	Prinos
1	10,75
2	11,87
3	12,19
4	10,33
5	11,23
6	10,27
7	10,39
8	11,11
9	11,09
10	10,80
11	11,11
12	10,76
13	11,75
14	10,94
15	11,47
16	11,61
17	11,48
18	10,70
19	10,79
20	11,70
21	12,30
22	12,22
prosjek	11,22
LSD 0,05	0,79

Kada analiziramo obje godine, na obje lokacije u Hrvatskoj (tablica 23.), skupna analiza varijance ukazuje nam na okoline kao izvor statistički značajnih razlika u ostvarenim prinosima ispitivanih hibrida, uz P<0,01. U skladu sa navedenim, iz tablice 21., ne postoji značajna razlika u ostvarenim prinosima u Osijeku i Karancu, u obje godine. Interakcija GxE bila je značajna na razini P<0,05.

Tablica 23. Skupna ANOVA za okoline u Hrvatskoj (Osijek i Karanac) u 2010. i 2011. godini.

Izvor variranja	Stupnjevi slobode	Prosječno kvadratno odstupanje (MS)
Okolina – E	3	47.2621**
Hibrid – G	21	1.0148
G x E	63	1.0273*
Pogreška	84	0.7611

** F test značajan na razini P>0,01
* F test značajan na razini P>0,05

U tablici 24. prikazane su srednje vrijednosti prinosa hibrida na hrvatskim lokacijama u obje godine. U odnosu na srednju vrijednost prinosa hibrida na svim okolinama – 11,22 t/ha, pokazalo se da je srednja vrijednost prinosa hibrida u Hrvatskoj niža – 10,50 t/ha. Zanimljivo je da je uvjerljivo najviši prinos ostvario standardni hibrid pod brojem 21 – Shemal – 12,30 t/ha, koji nije registriran i ne proizvodi se nigdje u Europi, pa tako ni u Hrvatskoj.

Statistički značajno viši prinos nije ostvario niti jedan drugi hibrid uključen u ispitivanje. Statistički značajno niži prinos također nije imao niti jedan hibrid, što ukazuje na okoline kao glavni izvor variranja (tablica 23.).

Tablica 24. Srednje vrijednosti prinosa zrna hibrida (t/ha) na svim okolinama u Hrvatskoj u 2010. i 2011. godini.

Hibrid	Prinos
1	10,26
2	10,43
3	10,69
4	9,70
5	10,66
6	9,91
7	10,65
8	10,52
9	9,68
10	9,63
11	10,40
12	10,45
13	11,11
14	11,11
15	10,90
16	10,85
17	10,93
18	10,09
19	10,18
20	10,22
21	12,30
22	11,21
Prosjek	10,50
LSD 0,05	1,43

Kada analiziramo obje godine, oba roka sjetve i sve lokacije u Turskoj (tablica 25.), skupna analiza varijance ukazuje nam na okoline i hibride kao izvor statistički značajnih razlika u ostvarenim prinosima ispitivanih hibrida, uz $P<0,01$. Interakcija GxE bila je značajna na razini $P<0,05$.

Tablica 25. Skupna ANOVA za sve okoline u Turskoj (1. i 2. sjetva) u 2010. i 2011. godini.

Izvor variranja	Stupnjevi slobode	Prosječno kvadratno odstupanje (MS)
Okolina – E	12	218.7765**
Hibrid – G	21	7.3767**
G x E	252	1.4255*
Pogreška	273	1.0764

** F test značajan na razini P>0,01
* F test značajan na razini P>0,05

Srednja vrijednost prinosa svih ispitivanih hibrida na svim okolinama u Turskoj, u obje godine ispitivanja, bila je 11,45 t/ha (tablica 26.), što je za 0,95 t/ha više nego srednja vrijednost prinosa na hrvatskim okolinama (tablica 24.). Ponovo je po prinosu najbolji standardni hibrid pod brojem 21 – Shemal, sa prinosom – 12,94 t/ha. Još dva hibrida imaju statistički značajno više prinose od srednje vrijednosti prinosa pokusa – to su hibrid broj 3 – 12,65 t/ha i hibrid broj 22 – 12,53 t/ha. Prinos statistički značajno ispod srednje vrijednosti prinosa pokusa imali su hibridi 4 – 10,53 t/ha, 6 – 10,38 t/ha i 7 – 10,31 t/ha.

Tablica 26. Srednje vrijednosti prinosa zrna hibrida (t/ha) na svim okolinama u Turskoj u 2010. i 2011. godini.

Hibrid	Prinos
1	10,90
2	12,31
3	12,65
4	10,53
5	11,40
6	10,38
7	10,31
8	11,29
9	11,53
10	11,17
11	11,33
12	10,86
13	11,95
14	10,82
15	11,58
16	11,83
17	11,68
18	10,63
19	11,00
20	12,17
21	12,94
22	12,53
Prosjek	11,45
LSD 0,05	0,92

Kada analiziramo prinose zrna sa turskih okolina samo iz prve sjetve, u obje godine (tablica 27.), vidimo da su statistički značajan izvor variranja bile i okoline i hibridi, uz $P<0,01$. Interakcija GxE nije bila statistički značajna.

Tablica 27. Skupna ANOVA za okoline u Turskoj (1. sjetva) u 2010. i 2011. godini.

Izvor variranja	Stupnjevi slobode	Prosječno kvadratno odstupanje (MS)
Okolina - E	5	171.1841**
Hibrid - G	21	3.4264**
G x E	105	1.5890
Pogreška	126	1.5219

** F test značajan na razini P>0,01
* F test značajan na razini P>0,05

Srednja vrijednost prinosa hibrida iz prve sjetve u Turskoj, u obje godine (tablica 28.) bila je najviša od svih analiziranih grupiranja prinosa, po okolinama ili po godinama – 13,43 t/ha. Samo jedan hibrid ostvario je statistički značajno viši prinos od srednje vrijednosti prinosa pokusa i to hibrid Poljoprivrednog instituta Osijek, pod brojem 3 – OSSK 613 – 14,94 t/ha.

Tablica 28. Srednje vrijednosti prinosa zrna hibrida (t/ha) na svim okolinama u Turskoj – 1. sjetva, u 2010. i 2011. godini.

Hibrid	Prinos
1	13,01
2	14,34
3	14,94
4	12,51
5	13,19
6	12,15
7	12,93
8	13,05
9	13,78
10	13,16
11	13,43
12	12,57
13	13,68
14	13,16
15	13,52
16	13,77
17	13,23
18	13,20
19	12,39
20	14,39
21	14,65
22	14,41
Prosjek	13,43
LSD 0,05	1,44

Po pitanju skupne ANOVA-e za drugu sjetvu, za obje godine (tablica 29.), vidljivo je da su statistički značajni izvori variranja bile i okoline i hibridi i interakcija GxE, uz $P<0,01$.

Tablica 29. Skupna ANOVA za okoline u Turskoj (2. sjetva) u 2010. i 2011. godini.

Izvor variranja	Stupnjevi slobode	Prosječno kvadratno odstupanje (MS)
Okolina - E	6	134.0341**
Hibrid - G	21	5.0451**
G x E	126	1.3445**
Pogreška	147	0.6944

** F test značajan na razini P>0,01
* F test značajan na razini P>0,05

Srednja vrijednost prinosa hibrida u drugoj sjetvi, u obje godine bila je 9,74 t/ha (tablica 30.). Samo je jedan hibrid ostvario statistički značajno viši prinos od srednje vrijednosti prinosa pokusa. To je standardni hibrid broj 21 – Shemal – 11,48 t/ha. Hibridi broj 7 – 8,06 t/ha i broj 18 – 8,42 t/ha, imali su statistički značajno niži prinos. Visina ostvarenog prinosa u drugoj sjetvi i poredak hibrida slični su prinosima i poretku hibrida na okolinama u Hrvatskoj (tablica 24.).

Tablica 30. Srednje vrijednosti prinosa zrna hibrida (t/ha) na svim okolinama u Turskoj – 2. sjetva, u 2010. i 2011. godini.

Hibrid	Prinos
1	9,09
2	10,58
3	10,68
4	8,83
5	9,86
6	8,87
7	8,06
8	9,79
9	9,60
10	9,46
11	9,53
12	9,39
13	10,47
14	8,81
15	9,92
16	10,17
17	10,35
18	8,42
19	9,82
20	10,27
21	11,48
22	10,92
Prosjek	9,74
LSD 0,05	1,23

U tablici 31. vidljivo je da su dvofaktorijelnom ANOVA-om kao statistički značajan izvor variranja potvrđeni i okoline i hibridi, kao i interakcija hibrid x okolina, uz $P<0,01$.

Tablica 31. Dvofaktorijelni model ANOVA–e po okolinama, za prinos zrna.

Izvor variranja	Stupnjevi slobode	Suma kvadrata (SS)	Varijanca	F vrijednosti
Okolina - E	16	2827.6803	7.9701	127.43**
Hibrid - G	21	134.2024	0.2943	4.61**
G x E	336	465.9762	0.3847	1.38**
Pogreška	357	357.7791	1.0022	

** F test značajan na razini P>0,01
* F test značajan na razini P>0,05

Skupna trofaktorijelna analiza varijance prikazana je u tablici 32. Napravljena je nakon balansiranja podataka, pri čemu u izračun nije ušla okolina Mersin 2010., 2. sjetva. To znači da je svaka okolina imala podatke u slijedu godina (2010. i 2011.) ili u slijedu dvije sjetve, u dva roka u Turskoj, u tijeku jedne godine, osim okoline Mersin 2010., 2. sjetva. Stoga pri izračunu kod trofaktorijelne analize, ova okolina nije ušla u obračun jer bi došlo do debalansa podataka i rezultati ovako provedene analize ne bi bili pouzdani. Ova analiza ukazuje na godine, okoline i hibride kao statistički vrlo značajne izvore variranja. Isti je slučaj i kod interakcije okolina x godina (LxY). Kod interakcija hibrid x okolina (GxL) i hibrid x godina (GxY) nije ostvarena statistička značajnost interakcija, dok je interakcija hibrida, godina i okolina (GxLxY) bila statistički značajna, uz P<0,05.

Tablica 32. Trofaktorijelni model ANOVA–e po okolinama, za prinos zrna.

Izvor variranja	Stupnjevi slobode	Suma kvadrata (SS)	Varijanca	F vrijednosti
Godina - Y	1	91,8308	0,5139	66,42**
Okolina - L	7	1032,4098	3,3206	106,68**
Hibrid - G	21	116,4510	0.2602	4,01**
LxY	7	732,8750	4,6961	75,73**
GxY	21	40,3683	0,0675	1,39
GxL	147	203,6560	0,0015	1,00
GxLxY	147	203,2245	0,3303	1,31*
Pogreška	336	353,5266	1,0522	

** F test značajan na razini P>0,01
* F test značajan na razini P>0,05

Provedena je i analiza varijance za procjenu interakcije hibrid x okolina. Neaditivnost je testirana Tukey testom. Preporučuje se da se pri svim kombiniranim analizama provede test aditivnosti za procjenu opravdanosti provedbe analize varijance i nužne transformacije podataka pri korištenju linearnog modela.

Procjenjena je i vrijednost heterogenosti regresije hibrida i okolina. Tukey testom aditivnosti (1949.), gdje je stupanj slobode zajedničke regresije c, df=1, testirano je jesu li genotipski efekti povezani aditivno ili multiplikativno sa okolinskim efektima. U većini slučajeva u praksi, imamo aditivni model ove interakcije, osim kada u poretku hibrida kod pokusa na više okolina imamo velike razlike. Tada se mora raditi logaritamska transformacija podataka.

Procjene stabilnosti, u prvom redu hibrida, a isto tako i okolina, baziraju se na različitoj reakciji hibrida na promjene okoline, odnosno na različitoj interakciji hibrid x okolina. Zbog toga je prije samog izračuna pojedinih parametara koji nam govore o stabilnosti, analizom varijance potvrđeno postojanje ove interakcije.

Tukey test aditivnosti (tablica 33.) nije imao statistički značajne vrijednosti, odnosno kod analize podataka može se primjeniti linearni, odnosno aditivni model. Vrijednost heterogenosti regresije hibrida nije bila statistički značajna, za razliku od vrijednosti heterogenosti regresije okolina, uz P<0,01. To je pokazatelj da heterogenost regresije potječe od okolina, odnosno od lokacija.

Tablica 33. Složena ANOVA interakcije GxL, s Tukey-testom neaditivnosti za 2010. i 2011. godinu.

Izvor variranja	Stupnjevi slobode	Prosječno kvadratno odstupanje (MS)
GxL	336	1.3868
Tukey test neaditivnosti	1	0.2821
Heterogenost regr. hibrida	20	1.1544
Heterogenost regr. okolina	15	2.9124**
Odstupanje od regresije	300	1.3297

** F test značajan na razini P>0,01
* F test značajan na razini P>0,05

Vrijednosti heterogenosti regresije za hibride (tablica 34.) za obje godine pokusa nisu bile statistički značajne, u odnosu na ukupnu interakciju. U ukupnoj interakciji hibrida i okolina vrijednost heterogenosti regresije hibrida obuhvaća 5,28 % od ukupne interakcije.

Tablica 34. Analiza varijance za hibride u 2010. i 2011. godini.

Izvor variranja	Stupnjevi slobode	Prosječno kvadratno odstupanje (MS)
Heterogenost regr. hibrida	21	1.1129
Odstupanje od regresije	315	1.4051

** F test značajan na razini P>0,01
* F test značajan na razini P>0,05

Vrijednosti heterogenosti regresije za okoline (tablica 35.) za obje godine pokusa, nisu bile statistički značajne, u odnosu na ukupnu interakciju. U ukupnoj interakciji hibrida i okolina vrijednost heterogenosti regresije okolina obuhvaća 10,41 % od ukupne interakcije.

Tablica 35. Analiza varijance za okoline u 2010. i 2011. godini.

Izvor variranja	Stupnjevi slobode	Prosječno kvadratno odstupanje (MS)
Heterogenost regr. okolina	16	2.7480
Odstupanje od regresije	320	1.3188

** F test značajan na razini P>0,01
* F test značajan na razini P>0,05

Procjenjene vrijednosti parametara stabilnosti (koeficijent regresije b_i i varijanca odstupanja od regresije s^2_{di}), uz srednju vrijednost prinosa ispitivanih hibrida, u obje godine i na svim okolinama prikazane su u tablici 36. U obje godine istraživanja LSD testom nađene su značajne razlike između koeficijenata regresije što pokazuje da ovdje postoje značajne razlike u stabilnosti prinosa ispitivanih hibrida.

Tablica 36. Parametri stabilnosti i srednja vrijednost prinosa hibrida (t/ha) u 2010. i 2011. godini.

Hibrid	Sred. vrij. prinosa	b_i	s^2_{di}
1	10,75	1.057	1.07
2	11,87	0.922	1.09
3	12,19	1.126	1.08
4	10,33	1.040	1.22
5	11,23	0.927	1.70
6	10,27	1.001	1.09
7	10,39	1.034	1.15
8	11,11	0.898	2.08
9	11,09	1.175	1.76
10	10,80	0.984	0.79
11	11,11	1.092	1.67
12	10,76	1.073	1.99
13	11,75	0.889	0.74
14	10,94	0.959	1.39
15	11,47	1.139	1.56
16	11,61	1.023	1.54
17	11,48	0.892	0.91
18	10,70	1.043	1.76
19	10,79	0.805	0.58
20	11,70	1.012	1.80
21	12,30	0.908	1.33
22	12,22	1.001	1.19
Prosjek	11,29		
LSD 0,05	0,79	0.28	

Bartletov test (prema Snedecor i Cochran, 1989.) za s^2_{di} – iznosio je 16,25 i nije bio statistički značajan.

Prema pristupu Eberharta i Russella (1966.) idealan hibrid mora imati što veću srednju vrijednost prinosa, koeficijent regresije b_i=1,00 i varijancu odstupanja od regresije s^2_{di}=0,00. U prvu skupinu hibrida (tablica 37.) dolaze oni koje možemo nazvati stabilnima.

Takvi hibridi imaju vrijednosti b_i=1,00 te niske vrijednosti s^2_{di}. U ovom slučaju niske vrijednosti s^2_{di} znače one vrijednosti koji su manje ili oko 1,00. Srednja vrijednost prinosa ovakvih hibrida uglavnom je na razini srednjih vrijednosti prinosa svih hibrida u svim okolinama. Srednja vrijednost prinosa svih hibrida bila je 11,22 t/ha, a hibridi u skupini stabilnih hibrida imaju baš takve prinose, ili nešto više od srednjih vrijednosti. Među prije navedenim hibridima, na osnovi srednje vrijednosti prinosa sa svih okolina i u obje godine od hibrida koji zaslužuju dalja testiranja i eventualni postupak registracije (brojevi 2, 3, 13, 15 i 16), među stabilne hibride ušao je hibrid pod brojem 13 = Os 7798/2 x Os 622448, pod imenom Toni i hibrid pod brojem 2 = Os 1965 x Os 622448. Osim njega, stabilan je i Os hibrid broj 17, te hibridi standardi, Shemal i PR31G98, pod brojevima 21 i 22. Svi oni imaju viši prinos od srednje vrijednosti prinosa. Stabilnim su (prema ovim parametrima procjene stabilnosti) proglašeni i hibridi sa prinosima ispod srednjih vrijednosti prinosa. To je slučaj kod hibrida broj 10 i 19, te osobito kod hibrida broj 6, koji ima najniži prinos u cijelom setu ispitivanih hibrida. Hibrid Shemal, sa najboljim prinosom, ima dobru vrijednost b_i, ali mu je vrijednost s^2_{di} previsoka da bi ga mogli proglasiti jednim od najstabilnijih hibrida u pokusu.

Tablica 37. Stabilni i visoko prinosni hibridi.

Hibrid	Prinos 2010. – 2011. godine (t/ha)	b_i	s^2_{di}
10 = Os 334275/13 x Os 3467	10,80	0,984	0,79
13 = Os 7798/2 x Os 622448	11,75	0,889	0,74
17 = OsMP33 x Os 1309/2/5	11,48	0,892	0,91
19 = OSSK 515	10,79	0,805	0,58
6 = Os KLT-14 x Os 942	10,27	1,001	1,09
2 = Os 1965 x Os 622448	11,87	0,922	1,09
21 = Shemal	12,30	0,908	1,33
22 = PR31G98	12,22	1,001	1,19

Drugu skupinu hibrida čine nestabilni hibridi, koji imaju vrijednosti b_i<1,00 a vrijednost s^2_{di} značajno veću od 0,00. Ovakvi hibridi uglavnom pokazuju srednju vrijednost prinosa u niskoprinosnim okolinama, odnosno na razini srednjih vrijednosti svih hibrida ili viši od njega, a u visokoprinosnim okolinama prinos im je u rangu srednjih vrijednosti ili nešto niži. Prema Finlay i Wilkinsonu (1963.) to su hibridi koji se

preporučuju za uzgoj u nisko prinosnim okolinama (tablica 38.). U ovu skupinu spadaju tri hibrida – pod brojem 5, 8 i 14.

Tablica 38. Nestabilni i nisko prinosni hibridi.

Hibrid	Prinos 2010. – 2011. godine (t/ha)	b_i	s^2_{di}
5 = Os 1600/1186/3 x Os 7728/3	11,23	0,927	1,70
8 = Os 7798/2 x Os 758TO240-3	11,11	0,898	2,08
14 = Os 7728/3 x Os 758TO240-3	10,94	0,959	1,39

Kao suprotnost ovoj drugoj skupini nestabilnih hibrida, imamo nestabilne hibride sa vrijednostima $b_i<1,00$ i s^2_{di} sa vrijednostima značajno većim od 0,00. Srednja vrijednost prinosa ovih hibrida je na razini srednje vrijednosti prinosa svih hibrida ili viša od toga, na visoko prinosnim okolinama, a na nisko prinosnim okolinama prinos im je na razini srednjih vrijednosti prinosa ili niži. To su hibridi koji se preporučuju za uzgoj na visoko prinosnim okolinama (tablica 39.). Hibrid broj 3 je treći po srednjoj vrijednosti prinosa u cijelom setu hibrida i ima smisla što se nalazi u ovoj skupini. Sva tri ostala hibrida, pod brojevima 1, 4 i 7 ostvarili su prinose ispod razine srednjih vrijednosti prinosa, a prema ovim prametrima procjene stabilnosti svrstani su u skupinu hibrida preporučenih za uzgoj u visoko prinosnim okolinama.

Tablica 39. Nestabilni i visoko prinosni hibridi.

Hibrid	Prinos 2010. – 2011. godine (t/ha)	b_i	s^2_{di}
1 = Os 7798/2 x Os 942	10,75	1,057	1,07
3 = Os 438 MP x Os 1309/2	12,19	1,126	1,08
4 = Os 7728/3 x Os 942	10,33	1,040	1,22
7 = Os 2295-304 x Os L201/1	10,39	1,034	1,15

Osim ove tri skupine hibrida koje se dosta jasno mogu definirati, postoje i hibridi kod kojih je vrijednost parametara stabilnosti takva da ih ne možemo jasno svrstati niti u jednu skupinu (tablica 40.). Ovi hibridi, u pravilu imaju $b_i>1,00$ kao u skupini nestabilnih ali visoko prinosnih hibrida, ali i vrlo visoku vrijednost s^2_{di} kao nestabilni i niskoprinosni hibridi (tablica 38.). Po visini srednje vrijednosti prinosa kroz godine i okoline, u ovu

skupinu uglavnom dolaze hibridi koji imaju srednje vrijednosti prinosa gotovo iste kao što su i srednje vrijednosti prinosa svih hibrida u pokusu – 11.22 t/ha, ili neznatno viši ili neznatno niži prinos od njih.

Tablica 40. Hibridi sa neujednačenim parametrima stabilnosti, kroz godine i okoline.

Hibrid	Prinos 2010. – 2011. godine (t/ha)	b_i	s^2_{di}
9 = Os KLT-14 x Os 621023BO	11,09	1,175	1,76
11 = Os 334275/13 x Os 621023BO	11,11	1,092	1,67
12 = Os KLTB73Č x Os 156BO	10,76	1,073	1,99
15 = Os 7728/3 x Os 156BO	11,47	1,139	1,56
16 = Os 7728/3 x Os 622448	11,61	1,023	1,54
18 = Os 2236 x Os 622448	10,70	1,043	1,76
20 = OSSK 602	11,70	1,012	1,80

Isti parametri stabilnosti korišteni su i za procjenu stabilnosti okolina u ovom istraživanju (tablica 41.). U obje godine istraživanja LSD testom nađene su značajne razlike između koficijenata regresije što pokazuje da ovdje postoje značajne razlike u stabilnosti prinosa hibrida po okolinama.

Tablica 41. Parametri stabilnosti okolina i srednja vrijednost prinosa hibrida (t/ha) na svim okolinama u 2010. i 2011. godini.

Okolina	Srednja vrijednost prinosa zrna	b_i	s^2_{di}
Osijek 2010.	12,23	0.313	0.58
Karanac 2010.	10,18	1.033	1.71
Altinova 2010./1. sjetva	8,87	1.308	0.84
Manisa 2010./1. sjetva	15,21	1.885	0.82
Mersin 2010./1. sjetva	11,20	0.643	1.27
Altinova 2010./2. sjetva	9,48	1.815	1.17
Manisa 2010./2. sjetva	9,42	1.738	1.68
Mersin 2010./2. sjetva	4,78	1.694	0.69
Adana 2010./2. sjetva	12,32	0.797	0.63
Osijek 2011.	10,87	0.120	0.49
Karanac 2011.	8,71	0.151	1.05
Altinova 2011./1. sjetva	15,86	0.919	2.15
Manisa 2011./1. sjetva	15,31	1.333	2.21
Mersin 2011./1. sjetva	14,12	0.639	1.21
Altinova 2011./2. sjetva	11,81	0.960	2.81
Manisa 2011./2. sjetva	10,64	1.034	1.29
Adana 2011./2. sjetva	9,76	0.919	0.50
Prosjek	11,22		
LSD 0,05	0,70	1,14	

Bartletov test (prema Snedecor i Cochran 1989.) za s^2_{di} – iznosio je 38,82** i bio je statistički značajan.

Kao i hibridi, i okoline se mogu svrstati u 4 skupine.

U prvu skupinu okolina (tablica 42.) dolaze one koje možemo nazvati stabilnima i nisko varijabilnim. Takve okoline imaju vrijednosti b_i=1,00 te niske vrijednosti s^2_{di}. Takva bi bila lokacija Adana, oba puta u drugoj sjetvi, u obje godine ispitivanja. Tim više, šteta je što kod obje sjetve u 1. roku (i tijekom 2010. i 2011. godine) ova lokacija nije mogla biti korištena u ukupnom izračunu jer nije zadovoljavala kriterije po pitanju sklopa.

Tablica 42. Nisko varijabilne i stabilne okoline u Hrvatskoj i Turskoj, 2010. i 2011. godine.

Okolina	Srednja vrijednost prinosa 2010. – 2011. godine (t/ha)	b_i	s^2_{di}
Adana 2010./2. sjetva	12,32	0,797	0,63
Adana 2011./2. sjetva	9,76	0,919	0,50

Okoline sa vrijednostima b_i=1,00 i s^2_{di} >0,00 nazivamo nestabilnim i niskoprinosnim (tablica 43.). U takve možemo ubrojiti 3 potpuno međusobno nevezane okoline, kako zemljopisno, tako i prema godinama i rokovima sjetve. To su Karanac 2010., Altinova 2010./1. sjetva i Manisa 2011./2. sjetva.

Tablica 43. Nestabilne i niskoprinosne okoline u Hrvatskoj i Turskoj, 2010. i 2011. godine.

Okolina	Srednja vrijednost prinosa 2010. – 2011. godine (t/ha)	b_i	s^2_{di}
Karanac 2010.	10,18	1,033	1,71
Altinova 2010./1. sjetva	8,87	1,308	0,84
Manisa 2011./2. sjetva	10,64	1,034	1,29

Kao suprotnost ovoj drugoj skupini nestabilnih okolina, imamo nestabilne okoline sa vrijednostima b_i<1,00 i s^2_{di} sa vrijednostima značajno većim od 0,00. To su okoline nestabilne ali pogodne za ostvarivanje visokih prinosa (tablica 44.). U ovu skupinu okolina dolaze isto vrlo raznorodne okoline, ali sa dominacijom 2011. godine (4 od 5 tih okolina su u istoj godini). U ovoj skupini je i okolina Altinova 2011./1. sjetva, koja je imala najviši ostvareni prinos od svih u pokusu.

Tablica 44. Nestabilne i visokoprinosne okoline u Hrvatskoj i Turskoj, 2010. i 2011. godine.

Okolina	Srednja vrijednost prinosa 2010. – 2011. godine (t/ha)	b_i	s^2_{di}
Mersin 2010./1. sjetva	11,20	0,643	1,27
Karanac 2011.	8,71	0,151	1,05
Altinova 2011./1. sjetva	15,86	0,919	2,15
Mersin 2011./1. sjetva	14,12	0,639	1,21
Altinova 2011./2. sjetva	11,81	0,960	2,81

Najveći broj okolina (7 od ukupno 17) možemo ubrojiti u skupinu okolina koje imaju neujednačene vrijednosti ova dva parametra stabilnosti. Prisutne su gotovo sve moguće kombinacije parametara:

- oba niska – Osijek 2010. i 2011.,
- visoka vrijednost b_i i relativno niska vrijednost s^2_{di} – Manisa 2010./1. sjetva, Mersin 2010./2. sjetva, Altinova 2010./2. sjetva,
- visoka vrijednost b_i i visoka vrijednost s^2_{di} – Manisa 2011./1. sjetva i Manisa 2010./2. sjetva.

Tu se nalaze okoline sa najnižim prinosom – Mersin 2010./2. sjetva, ali i Manisa 2011./1. sjetva kao jedna od najprinosnijih okolina u istraživanju.

Tablica 45. Okoline sa neujednačenim parametrima stabilnosti, kroz godine i okoline u Hrvatskoj i Turskoj, 2010. i 2011. godine.

Okolina	Srednja vrijednost prinosa 2010. – 2011. godine (t/ha)	b_i	s^2_{di}
Osijek 2010.	12,23	0,313	0,58
Manisa 2010./1. sjetva	15,21	1,885	0,82
Altinova 2010./2. sjetva	9,48	1,815	1,17
Manisa 2010./2. sjetva	9,42	1,738	1,68
Manisa 2011./1. sjetva	15,31	1,333	2,21
Mersin 2010./2. sjetva	4,78	1,964	0,69
Osijek 2011.	10,87	0,120	0,49

U tablici 46. nalazi se pregled korelacijskih koeficijenata između srednje vrijednosti prinosa zrna sa pojedinih okolina, kao i između pojedinih okolina. Niti kod jedne okoline nije zabilježena visoko značajna korelacija povezanosti prinosa, iz godine u godinu, na istoj lokaciji. Samo u manjem broju slučajeva ustanovljena je statistički značajna ili vrlo značajna korelativna povezanost prinosa sa pojedinih okolina.

Statistički značajno (uz $P<0,05$) povezani su prinosi sa okolina:

- Altinova 2010./1. sjetva i Altinova 2010./2. sjetva – uz korelacijski koeficijent 0,55,
- Manisa 2010./1. sjetva i Altinova 2010./2. sjetva – 0,60,
- Altinova 2010./2. sjetva i Mersin 2010./2. sjetva – 0,57,
- Mersin 2010./2. sjetva i Adana 2010./2. sjetva – 0,53,

- Mersin 2010./2. sjetva i Mersin 2011./1. sjetva – 0,51,
- Adana 2010./2. sjetva i Manisa 2011./2. sjetva – 0,58.

Statistički vrlo značajnu korelacijsku povezanost prinosa (uz $P<0,01$) sa okolinama imamo samo u dva slučaja:

- Manisa 2010./1. sjetva i Mersin 2010./2. sjetva – 0,62,
- Manisa 2010./2. sjetva i Mersin 2010./2. sjetva – 0,66.

Neočekivano je da je u najvećem broju slučajeva (5 od ukupno 8) značajnu ili vrlo značajnu korelativnu povezanost prinosa imala okolina Mersin 2010./2. sjetva – koja se po visini prinosa (to je okolina sa najnižim prosjekom prinosa u cijelom pokusu – 4,78 t/ha – tablica 24.) nikako ne uklapa niti sa jednom drugom okolinom, bez obzira na godinu ili rok sjetve.

Tablica 46. Korelacijski koeficijenti između srednje vrijednosti prinosa zrna sa pojedinih okolina.

Okolina	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
1	1,00																
2	0,32	1,00															
3	0,07	0,29	1,00														
4	0,40	0,32	0,52	1,00													
5	0,05	0,07	0,31	0,34	1,00												
6	0,07	0,49	**0,55***	**0,60***	0,30	1,00											
7	-0,01	-0,21	0,40	0,37	0,33	0,47	1,00										
8	0,35	0,27	0,47	**0,62****	0,02	**0,57***	**0,66****	1,00									
9	0,30	0,06	0,19	**0,56***	0,15	0,21	0,39	**0,53***	1,00								
10	-0,19	0,07	0,12	0,14	0,21	-0,11	-0,04	-0,27	0,09	1,00							
11	-0,19	-0,32	-0,02	0,17	0,01	-0,20	-0,03	-0,30	-0,12	0,39	1,00						
12	-0,11	0,12	0,06	0,19	-0,29	0,31	0,23	0,40	0,24	-0,10	-0,33	1,00					
13	0,09	0,20	0,11	0,33	0,08	0,26	0,23	0,29	0,25	0,08	-0,21	0,22	1,00				
14	0,42	0,03	0,29	0,09	0,04	0,18	0,43	**0,51***	-0,13	-0,29	.0,10	-0,03	0,21	1,00			
15	-0,27	0,27	0,26	0,11	0,12	0,26	0,13	0,14	-0,14	-0,18	-0,04	0,23	-0,03	-0,07	1,00		
16	-0,08	0,21	0,25	0,31	-0,09	0,07	0,20	0,39	**0,58***	0,29	-0,05	0,17	0,38	-0,12	0,19	1,00	
17	0,28	0,25	0,49	0,44	0,21	0,34	0,44	0,42	0,39	0,34	0,11	0,03	0,16	0,32	0,02	0,33	1,00

** F test značajan na razini P<0,01

* F test značajan na razini P<0,05

Ponovljivost parametara stabilnosti i kod hibrida i kod okolina, iz godine u godinu bila je uglavnom niska.

Isto tako, redoslijed hibrida i njihova klasifikacija u skupine razlikuje se kad koristimo b_i ili s^2_{di}. Ova dva parametra stabilnosti procjenjuju hibride i okoline na različite načine, odnosno putem različitih vrijednosti. Da bi se utvrdila međusobna povezanost između pojedinih parametara i odnos prinosa sa parametrima stabilnosti, izračunati su korelacijski koeficijenti, skupno, za obje godine, kod okolina i hibrida.

Iz tablice 47. možemo vidjeti da za hibride nije dobivena statistički značajna korelacija između srednje vrijednosti prinosa i parametara stabilnosti, dok je između ova dva parametra stabilnosti korelacija bila statistički značajna, uz $P<0,05$.

Tablica 47. Korelacijski koeficijenti srednje vrijednosti prinosa i parametara stabilnosti hibrida.

Godina	2010./2011.	
	b_i	s^2_{di}
Prinos	-0,111	0,037
s^2_{di}	0,414*	

** F test značajan na razini P>0,01
* F test značajan na razini P>0,05

Iz tablice 48. možemo vidjeti da za okoline nije dobivena statistički značajna korelacija niti između srednje vrijednosti prinosa i parametara stabilnosti, kao niti između ova dva parametra stabilnosti.

Tablica 48. Korelacijski koeficijenti srednje vrijednosti prinosa i parametara stabilnosti okolina.

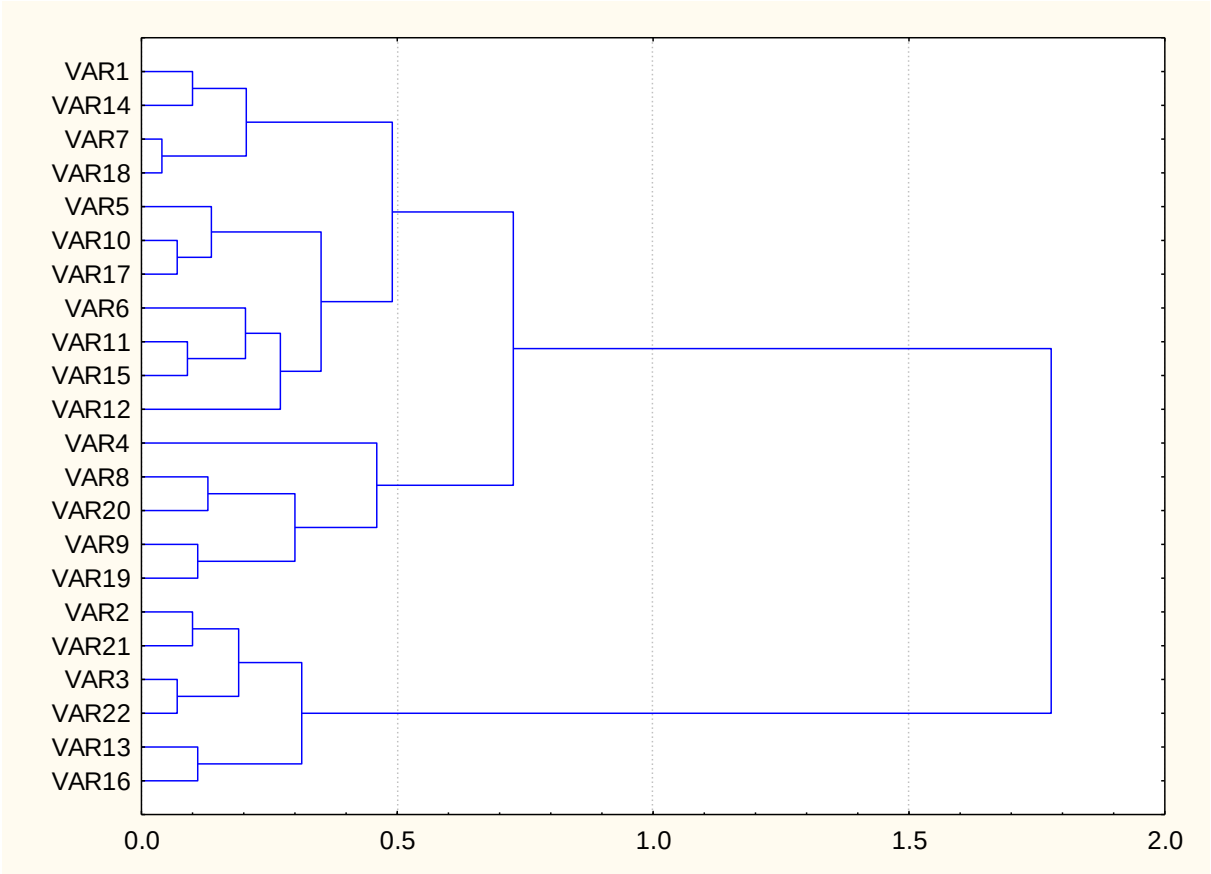
Godina	2010./2011.	
	b_i	s^2_{di}
Prinos	- 0,079	0,365
s^2_{di}	0,175	

** F test značajan na razini P>0,01
* F test značajan na razini P>0,05

Vidimo da je korelacija između koeficijenta regresije i varijance odstupanja od regresije nisko signifikantna za hibride i nesignifikantna za okoline, sa vrijednostima 0,175 i 0,414.

Na slici 13. prikazano je grupiranje hibrida u skupine, primjenom Pattern analize, prema Wardovoj metodi. Osnovni kriterij bila je visina prinosa, tijekom 2010. godine, na ukupno 9 okolina u Hrvatskoj i Turskoj.

Sve hibride dijelimo na dvije osnovne skupine: visokoprinosne i niskoprinosne hibride. U 2010. godini u skupinu visokoprinosnih hibrida grupirano je 6 hibrida (2, 3, 13, 16, 21, 22). Ova skupina hibrida ima dvije podskupine ili klastera. U skupinu nisko prinosnih hibrida svrstani su svi ostali hibridi u pokusu. Ovdje je prisutno tri podskupine hibrida koji su međusobno slično reagirali kroz 2010. godinu, i kroz okoline. U dendrogramu, vidljivo je da su među visoko prinosnim hibridima vrlo blisku reakciju na okoline te godine pokazali hibridi pod brojevima 2 i 21 ili 3 i 22, a kod nisko prinosnih hibrida, međusobno vrlo sličnu reakciju po pitanju prinosa kroz okoline pokazali su hibridi pod brojevima 7 i 18, zatim 10 i 17 i sl.

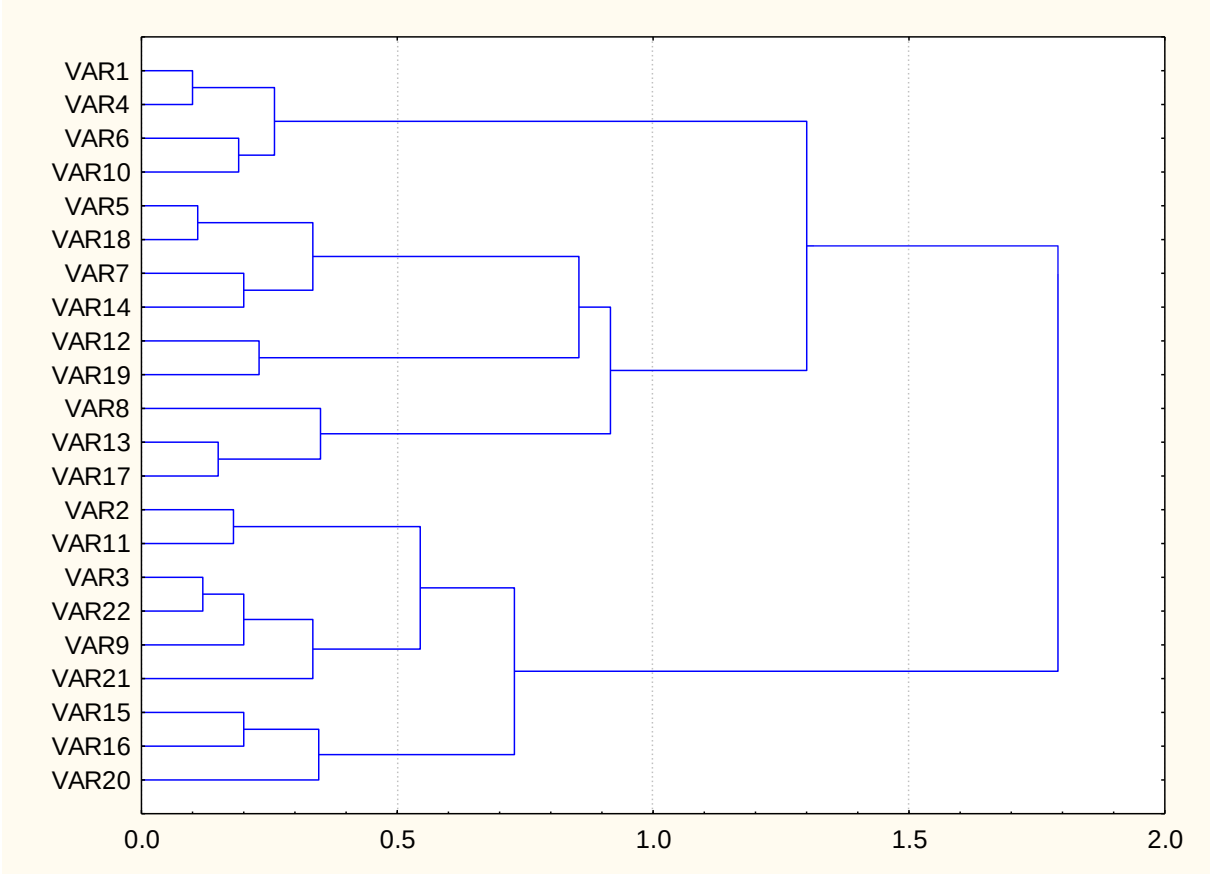


Slika 13. Grupiranje hibrida prema visini prinosa u 2010. godini.

Na slici 14. prikazano je također grupiranje hibrida u skupine, primjenom Pattern analize, tijekom 2011. godine, na ukupno 8 okolina u Hrvatskoj i Turskoj. Svi hibridi dijele se ponovno na dvije osnovne skupine: visokoprinosni i niskoprinosni hibridi.

U 2011. godini u skupinu visokoprinosnih hibrida grupirano je 9 hibrida (2, 3, 9, 11, 15, 16, 20, 21, 22). Hibridi koji su ponovo u istoj ovoj skupini i drugu godinu za redom su 2, 3, 16, 21 i 22. Ova skupina hibrida ima dvije podskupine hibrida sa međusobno vrlo sličnim reakcijama na pojedine okoline tijekom 2011. godine. Ponovno su vrlo blisku reakciju po pitanju prinosa pokazali hibridi pod brojem 3 i 22.

U skupinu nisko prinosnih hibrida svrstani su svi ostali hibridi u pokusu. Ovdje su prisutne tri podskupine hibrida koji su međusobno slično reagirali kroz okoline tijekom 2011. godine. Nije se ponovilo grupiranje istih hibrida u iste podskupine kao u 2010. godini niti u jednom slučaju.



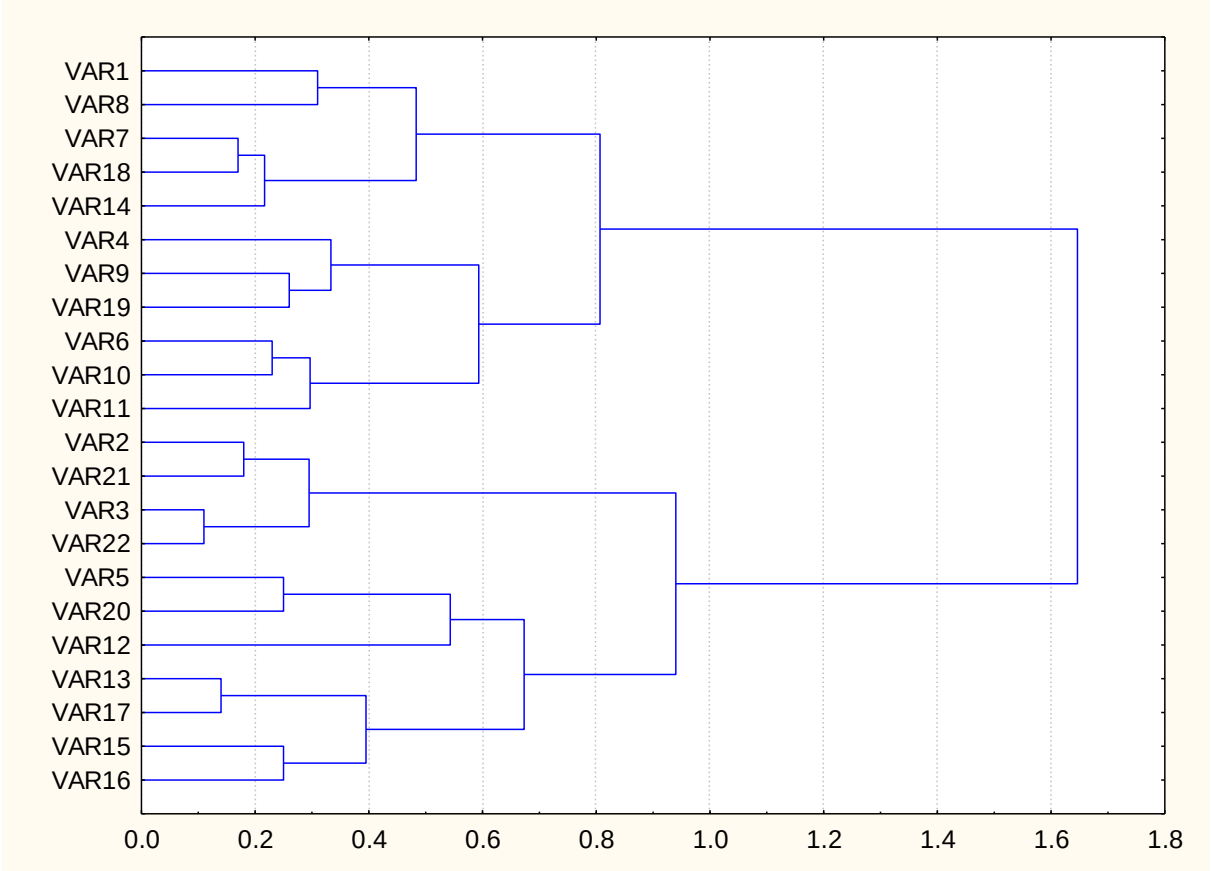
Slika 14.Grupiranje hibrida prema visini prinosa u 2011. godini.

Slika 15. je skupni dendrogram za 2010. i 2011. godinu, za ukupno 17 okolina. Pokazuje ponovno jasno grupiranje hibrida na dvije osnovne skupine: visokoprinosni i niskoprinosni hibridi.

U skupinu visokoprinosnih hibrida grupirano je 11 hibrida (2, 3, 5, 12, 13, 15, 16, 17, 20, 21, 22). Hibridi koji su ponovo u istoj ovoj skupini i u skupnoj analizi za obje godine su 2, 3, 16, 21 i 22. To su hibridi koji u sva tri analizirana slučaja visoko prinosni. Ova skupina hibrida ima dvije podskupine hibrida sa međusobno vrlo sličnim reakcijama

na pojedine okoline tijekom obje godine. Ponovno su vrlo blisku reakciju po pitanju prinosa pokazali hibridi pod brojem 2 i 21 te 3 i 22.

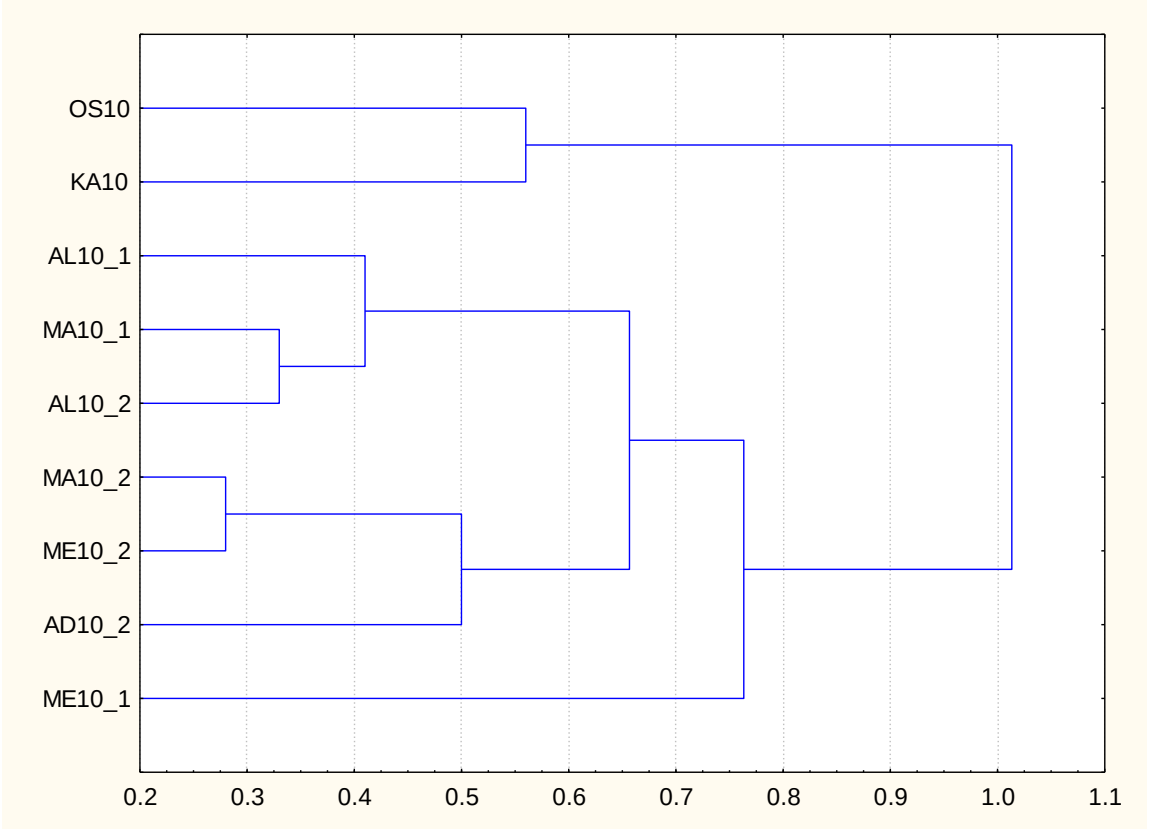
U skupinu nisko prinosnih hibrida svrstani su svi ostali hibridi u pokusu. Ovdje su prisutne dvije podskupine hibrida koji su međusobno slično reagirali kroz okoline tijekom obje godine. Samo su hibridi pod brojevima 7 i 18 bili vrlo međusobno bliski, kao i 2010. godine.



Slika 15. Grupiranje hibrida prema visini prinosa u 2010. i 2011. godini.

Kada se radi o okolinama i njihovom grupiranju, na slici 16. nalazi se pregled grupiranja okolina prema visini prinosa, tijekom 2010. godine, i u Hrvatskoj i u Turskoj. Jasno je vidljiva podjela na dvije cjeline, odnosno dvije međusobno odvojene megaokoline – Hrvatsku i Tursku.

Okoline u Hrvatskoj (Osijek i Karanac) pokazale su se kao izdvojena cjelina u odnosu na okoline u Turskoj, nevezano za rok sjetve u Turskoj. U Turskoj se te godine formiralo praktično, tri podskupine ili klastera. U jednu ulaze lokacija Altinova, sa oba roka sjetve i Manisa, 1. sjetva. Drugu skupinu okolina čine Manisa, Mersin i Adana – sve u drugoj sjetvi. Kao zasebna okolina izdvojen je Mersin.



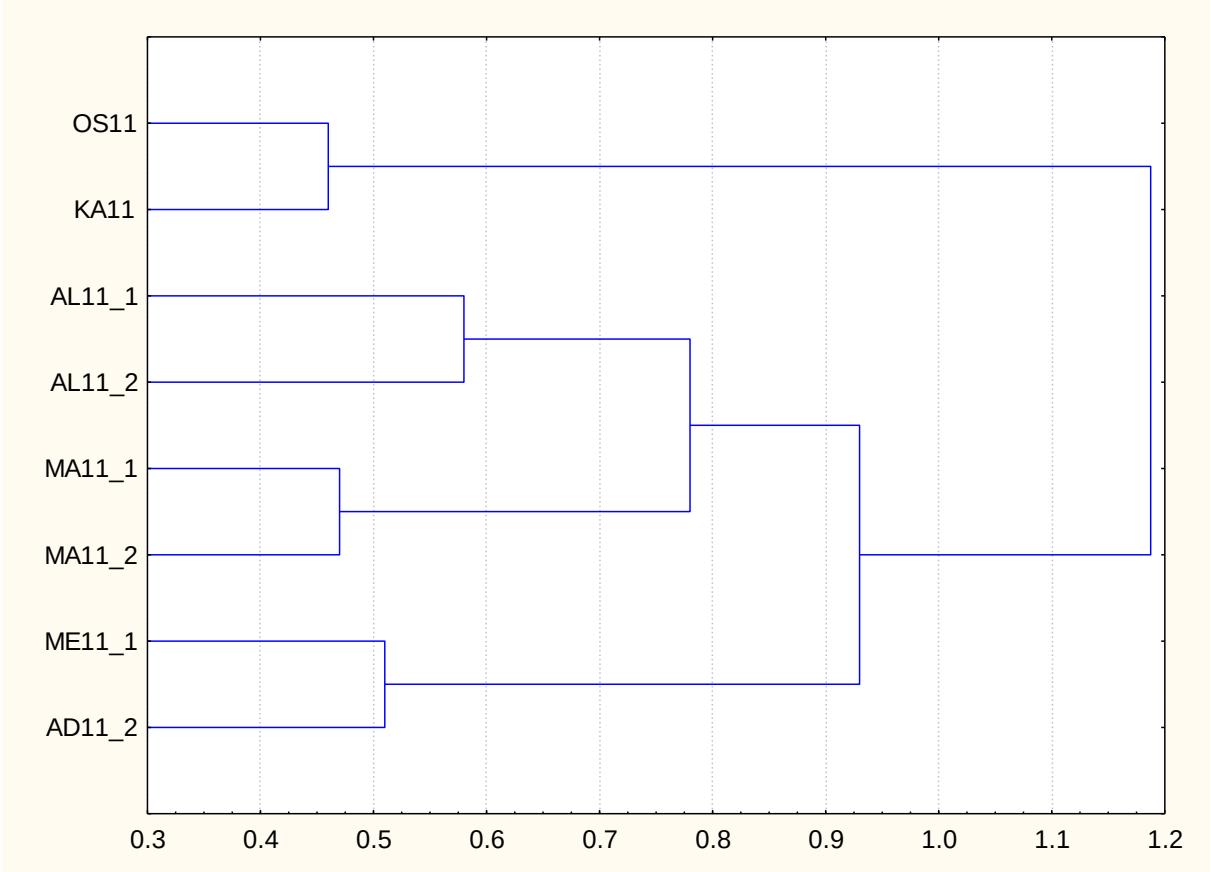
Slika 16. Grupiranje okolina prema visini prinosa u 2010. godini.

Na slici 17. nalazi se pregled grupiranja okolina prema visini prinosa, tijekom 2011. godine, u obje zemlje. Ovaj puta radilo se o 8 okolina. Ponovo je vidljiva podjela na dvije cjeline, odnosno dvije međusobno odvojene megaokoline – Hrvatsku i Tursku. Okoline u Hrvatskoj (Osijek i Karanac) bile su grupirane odvojeno od okolina u Turskoj. U Turskoj se te godine formiralo tri podskupine ili klastera. Ono što je bilo navješteno tijekom 2010. godine, došlo je do izražaja i tijekom 2011. godine, ali na malo drugačiji način. Okoline je moguće grupirati i u Turskoj. Ovaj puta same lokacije po sebi predstavljaju zasebne, odvojene cjeline, neovisno o roku sjetve. U prvu skupinu okolina ulazi Altinova, sa oba roka sjetve. Drugu skupinu okolina čini Manisa, sa oba roka sjetve. Samo u trećoj skupini, nalaze se okoline koje nisu međusobno bliske – Mersin, 1. sjetva i Adana, 2. sjetva.

Hibrid stvoren u Osijeku, pod brojem 3 = OSSK 613, imao je najviši ostvareni prinos, tijekom zbirnog obračuna, za prvi rok sjetve, u obje godine. To je bilo prilično neočekivano, jer u prvoj sjetvi dolazi do izražaja maksimalni kapacitet rodnosti nekog

hibrida, ali pokazalo se da nije nemoguće. To otvara novi zahtjev – za što obuhvatnijom mrežom lokacija za testiranje hibrida u Turskoj, iz koje bi onda podaci bili dovoljno pouzdani i ne bi ostavljali dvojbe, po pitanju vjerodostojnosti.

Slično ovom istraživanju, Ilker i sur. (2009.) izdvojili su samo jedan od 17 ispitivanih hibrida (uključujući i standarde) kao najbolji od ispitivanih (ne i bolji od standarda), i preporučili ga za daljnji postupak registracije u Turskoj. Radilo se o hibridu jedne od stranih kompanija koje nisu imale vlastiti oplemenjivački program u Turskoj i pokazalo se da ostvariti rezultat bolji od standardnih hibrida rasprostranjenih u Turskoj nije nimalo lak i jednostavan zadatak.



Slika 17. Grupiranje okolina prema visini prinosa u 2011. godini.

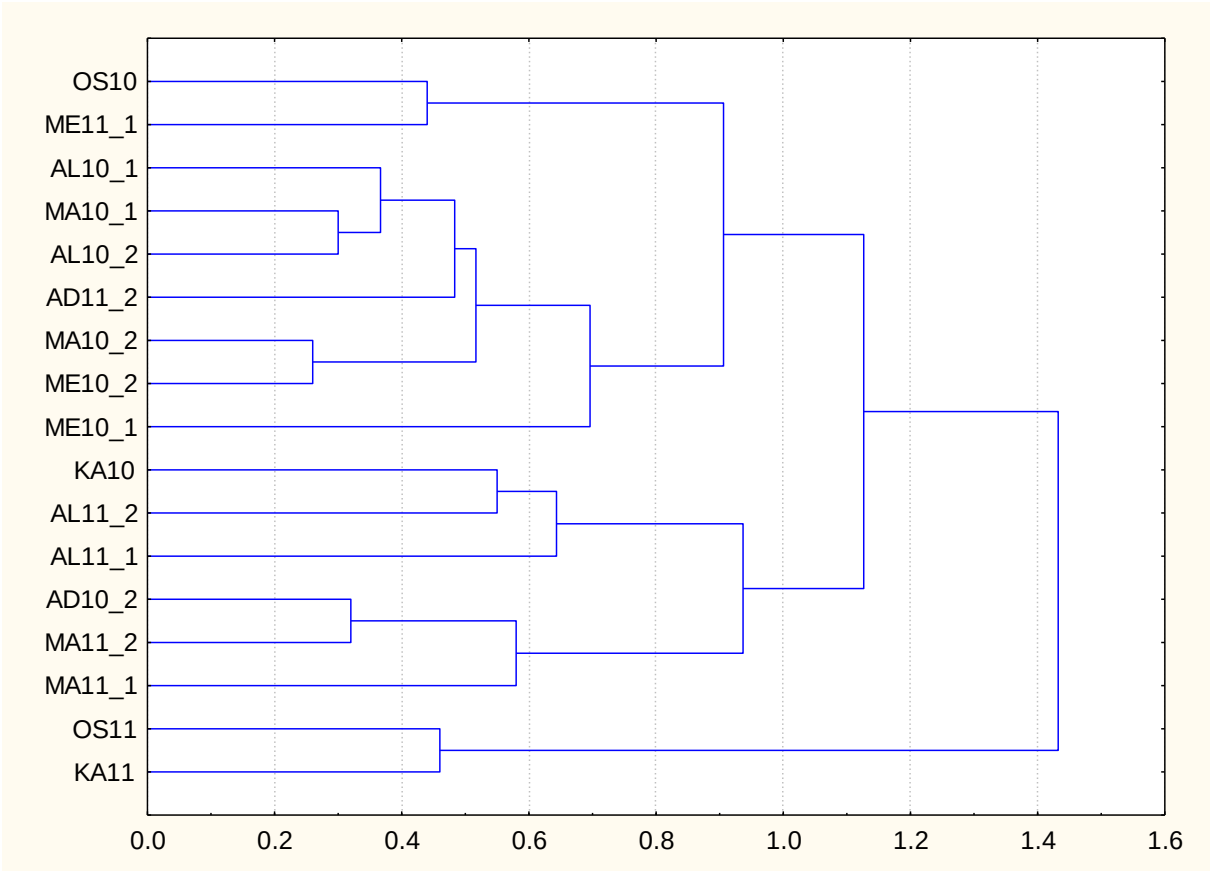
Na slici 18. nalazi se pregled grupiranja okolina prema visini prinosa, skupno, za 2010. i 2011. godinu, i u Hrvatskoj i u Turskoj.

Ponovo je vidljiva podjela na dvije cjeline, odnosno dvije međusobno odvojene megaokoline – Hrvatsku i Tursku, ali ne tako jasno kao kada se radi o rezultatima pojedinačnih godina. Lokacije u Hrvatskoj (Osijek i Karanac) pokazale su se kao izdvojena cjelina u odnosu na lokacije u Turskoj, ali samo za 2011. godinu. Ostatak

okolina podijelio se u dvije zasebne, po godinama djelomično bliske ali međusobno ipak heterogene podskupine okolina.

U prvu skupinu ulaze Osijek 2010., te 6 okolina iz 2010. godine – Altinova 1. i 2. sjetva, Manisa, 1. i 2. sjetva, Mersin, 1. i 2. sjetva. Tu spadaju i okoline iz 2011. godine – Mersin, 1. sjetva i Adana, 2. sjetva. Iako se okoline nalaze u istoj podskupini, njihova međusobna bliskost (zahvaljujući tehnici ordinacije, kao i kod hibrida) često puta nije logičan slijed pojedinačnih godina. Npr: bliski su rezultati sa okolina u Osijeku 2010. godine i Mersinu 2011., 1. sjetva, zatim odvajaju se podaci iz Manise 2010. godine u dvije podskupine, a bili su međusobno bliski i slično.

Drugu veliku podskupinu u skupnom izračunu čini 6 okolina. Tu su međusobno bliski Karanac 2010. i Altinova 2011., 1. i 2. sjetva, te Adana 2010., 2. sjetva i Manisa 2011., 1. i 2. sjetva.



Slika 18. Grupiranje okolina prema visini prinosa u 2010. i 2011. godini, sa svih 17 okolina.

Na slici 19. nalazi se pregled grupiranja okolina prema visini prinosa, skupno, za 2010. i 2011. godinu, i u Hrvatskoj i u Turskoj, ali sa ukupno 16 okolina. Iz izračuna je

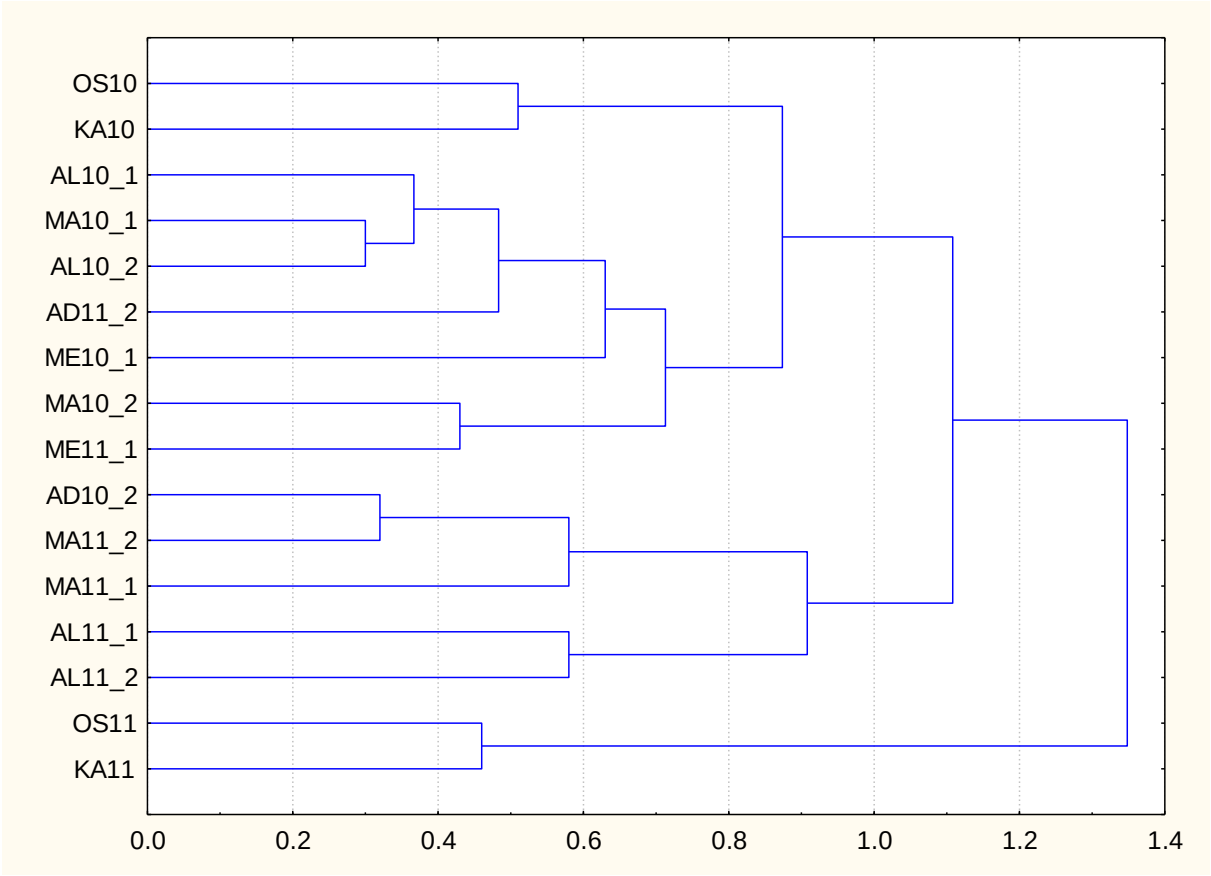
izdvojena okolina Mersin 2010. godine, 2. sjetva. Osnovni razlog bio je potreba balansiranja podataka, kao kod trofaktorijelne ANOVA-e.

Podjela na dvije cjeline, odnosno dvije međusobno odvojene megaokoline – Hrvatsku i Tursku ostala je i dalje. Okoline u Hrvatskoj (Osijek i Karanac) ostale su izdvojena cjelina u odnosu na okoline u Turskoj, ali samo za 2011. godinu. To je praktično jedna megaokolina, za sebe. Ostatak okolina zadržao je podjelu na dvije zasebne, po godinama djelomično bliske podskupine okolina.

Glavna razlika u odnosu na sliku 18., sa okolinom Mersin 2010. godina, 2. sjetva, je ponovno spajanje okolina u Hrvatskoj u 2010. godini, što je i u pojedinačnim godinama bio slučaj.

U prvu skupinu ulaze Osijek i Karanac 2010., te 5 okolina iz 2010. godine – Altinova 1. i 2. sjetva, Manisa, 1. i 2. sjetva te Mersin, 1. sjetva. Tu spadaju i okoline iz 2011. godine – Mersin, 1. sjetva i Adana, 2. sjetva. Međusobna bliskost okolina ni ovaj put nije logičan slijed pojedinačnih godina. Npr: bliski su rezultati sa okolina u Manisi 2010. godine, 2. sjetva i Mersinu 2011., 1. sjetva, podaci iz Manise 2010. godine ponovno se odvajaju u dvije podskupine itd.

Drugu veliku podskupinu u skupnom izračunu čini 5 okolina. Tu je situacija potpuno ista kao na slici 7. (izuzev Karanca 2010. godine), odnosno ponovno su međusobno bliski Altinova 2011., 1. i 2. sjetva, te Adana 2010., 2. sjetva i Manisa 2011., 1. i 2. sjetva.



Slika 19. Grupiranje okolina prema visini prinosa u 2010. i 2011. godini, sa 16 okolina (bez okoline Mersin, 2010./2).

4. RASPRAVA

Analizom izvora variranja kroz godine i lokacije, možemo uočiti da je na hrvatskim lokacijama tijekom kišne 2010. godine zabilježeno statistički značajno variranje čak i između ponavljanja u Osijeku, a isto tako i između hibrida u Karancu (tablica 8.). U slijedećoj, 2011. godini, koja je bila sušna, nije bilo uopće značajnog variranja niti između ponavljanja, niti među hibridima (tablica 14.).

Kod turskih lokacija, tijekom prve sjetve u 2010. godini postojala je statistički značajna razlika u prinosima između ponavljanja na lokaciji Altinova (zbog viška vode na dijelu polja) (tablica 10.). Da je tu postojao problem vidi se i po tome što je u Altinovi 2010. godine postignut manji prosječni prinos hibrida nego u drugoj sjetvi, što nije bio slučaj niti kod jedne druge lokacije (tablice 11. i 13.). Ponavljanja su bila izvor statistički značajnih razlika i u 2011. - na lokaciji Mersin.

Što se tiče 2. sjetve u Turskoj, tijekom 2010. godine, statistički značajan izvor variranja bila su ponavljanja u Altinovi, a statistički vrlo značajna izvor variranja bili su hibridi na lokaciji Mersin (tablica 12.). U 2011. godini, u Turskoj, statistički vrlo značajan izvor variranja bili su samo hibridi – u Altinovi i Manisi.

Kada imamo slučaj da su nam ponavljanja glavni izvor variranja, obično je riječ o problemima sa suviškom ili manjkom oborina, lošom pripremom tla za sjetvu, manjkom biljaka po parcelici i slično. Tada kažemo da pokusi nisu dobri, da nisu postavljeni u optimalnim uvjetima. U slučajevima kada najbolje prinose ostvaruju hibridi koji se po randomizaciji nalaze na krajnje lijevoj ili krajnje desnoj strani pokusa (brojevi 1 i 2, ili 21 i 22) možemo posumnjati da se radi o tome da su tzv. zaštitni redovi koji se siju lijevo i desno od pokusa nedovoljno kvalitetno posijani (najčešće nemaju dobar sklop) i time dolazi do stvaranja boljih uvjeta za hibride koji su posijani odmah uz te rubne, zaštitne redove i stvaranja efekta rubnih redova, gdje takvi članovi pokusa zbog više vegetacijskog prostora imaju više prinose. To se obično izbjegne pravilnom randomizacijom unutar pokusa, ali kada se radi o pokusima sa samo dva ponavljanja, ovakvi se učinci rubnih članova pokusa ne mogu uvijek izbjeći. Ipak, u cjelini, zbog dosta podataka u cijelom ovom pokusu, poredak prinosa ostvarenih hibrida nije slučajan.

Ako analiziramo sve lokacije i godine vidimo da su nam statistički vrlo značajni izvori variranja i hibridi i okoline i njihova interakcija (tablica 20.).

Kod analize ostvarenih prinosa hibrida kroz obje godine i sve lokacije, (tablica 21.) ono što možemo uočiti je i da je ostvaren vrlo veliki raspon srednje vrijednosti prinosa

između okolina. U 1. sjetvi, tijekom 2010. godine, visinom srednje vrijednosti ostvarenog prinosa ističe se lokacija Manisa – 15,01 t/ha (tablica 11.). U 2011. godini ostvaren je najviši ostvareni prinos u cijelom istraživanju na lokaciji Altinova – 15,86 t/ha. Srednja vrijednost prinosa hibrida sa svih okolina bila je 11,22 t/ha (tablica 21.). Prinos u Osijeku bio je viši od prinosa u Karancu. Značajno viši prinosi od prosjeka ostvareni su u 1. sjetvi u Turskoj, kao i u Osijeku tijekom 2010. godine, te na lokaciji Adana,2. sjetva 2010. godine. Statistički značajno niži prinos od srednje vrijednosti ostvaren je na čak 7 od ukupno 17 okolina. To ukazuje da se ovdje radi, ne samo o prostorno diskontinuiranoj sjetvi (Turska i Hrvatska) već da je vrlo značajan izvor variranja prinosa i razlika ostvarenog prinosa između prve i druge sjetve u Turskoj.

Smanjenje srednje vrijednosti prinosa u 2. sjetvi u Turskoj, u odnosu na prvu sjetvu je prosječno 35 - 40 %. To znači, da kada tu razliku u prinosu prve sjetve (tablica 28.) i druge sjetve svedemo na srednju vrijednost, ona iznosi 3,69 t/ha ili možemo reći da je u drugoj sjetvi ostvareno 72,5 % prinosa iz prve sjetve.

Glavni razlog je svakako taj da kod sjetve hibrida u kasnijem terminu, dva mjeseca kasnije (svibanj – srpanj) isti hibridi, iste dužine vegetacije, imaju različite sume toplinskih jedinica u različito dugom vremenskom periodu. Dužina dana, kako kukuruz u drugoj sjetvi ide prema zriobi i nalijevanju zrna, se skraćuje, noći su hladnije. Isto tako, kao prateći faktor snižavanja prinosa u drugoj sjetvi je jači napad kukuruznog moljca, koji u jačem intenzitetu nego u 1. sjetvi nanosi i ekonomski značajne štete. Kao okolina, sa najvećom srednjom vrijednosti prinosa zrna i sa najmanjim oscilacijama između godina i rokova sjetve može se izdvojiti Manisa. Okolina koja se izdvaja kao daleko najlošija po prinosu zrna i ne uklapa se u shemu ostalih okolina je Mersin, 2010. godine, 2. sjetva, zbog niza problema – reducirani sklop, problemi sa korovima i navodnjavanjem.

Važno je istaknuti da tijekom obje godine istraživanja u Hrvatskoj (ukupno 4 okoline) niti jedan hibrid nije ostvario statistički značajno viši ili niži prinos od srednje vrijednosti pokusa. To je pokazatelj da je izbor hibrida (koji je napravljen na osnovi preliminarnih rezultata iz Osijeka 2009. godine) bio dobro napravljen, s obzirom na proizvodne uvjete u Hrvatskoj.

Isto tako, ne postoji niti jedan hibrid koji je tijekom prve sjetve u Turskoj, u obje godine ispitivanja, bio više puta na različitim lokacijama statistički značajno rodniji od drugih. Hibrid koji je 2 puta bio statistički značajno rodniji od srednje vrijednosti pokusa

bio je pod brojem 2 a hibrid pod brojem 21 – standardni hibrid Shemal, bio je statistički značajno rodniji čak u tri slučaja.

Hibridi koji su kod izračuna za sve okoline i godine imali statistički značajno viši prinos bili su pod brojevima 3, 21 i 22. Proizlazi da su to ili hibridi koji su standardi,(kao 21 i 22), ili su već registrirani u nekoj državi (kao OSSK 613 u Hrvatskoj).

Ilker i suradnici (2009.) radili su slično istraživanje za jednu od stranih oplemenjivačkih kuća koja je prije prijavljivanja vlastitih novih hibrida u postupak registracije u pokuse turskog ministarstva poljoprivrede željela ih provjeriti kroz vlastitu mrežu pokusa u Turskoj. Pokazalo se da kod pravilnog izbora standardnih hibrida, tzv. čekova (a to su ili službeni standardni hibridi u Komisijskim pokusima ministarstva ili najrasprostranjeniji i najpopularniji hibridi na tržištu u to vrijeme) je vrlo teško pronaći vlastititi hibrid koji će biti ravnopravan standardima ili bolji od njih. Ilker i sur. pronašli su jedan takav, u setu od 17 analiziranih hibrida. Kada primjenimo slične kriterije na ovo istraživanje, može se reći da postoji određena skupina hibrida Poljoprivrednog instituta Osijek koji imaju potencijal biti na listi hibrida za registraciju i proizvodnju u Turskoj. To su prije svega hibrid broj 3 = OSSK 613, 2 = Os 1965 x Os 622448, 13 = Os 7798/2 x Os 622448 = Toni, 15 = Os 7728/3 x Os 156BO i 16 = Os 7728/3 x Os 622448 = Leonid.

Hibridi pod brojevima 4, 6 i 7 ne mogu po pitanju prinosa biti ravnopravni ostalima u ispitivanju, jer su ostvarili statistički značajno niži urod (tablica 22.).

Hibrid koji je i u Hrvatskoj i u Turskoj 1. i 2. sjetvi ostvario statistički značajno bolje rezultate od svih ostalih ponovo je bio broj 21 - Shemal, a uz njega to su bili još brojevi 3 i 22.

Zanimljivo je da je hibrid Poljoprivrednog instituta Osijek, pod brojem 3 – OSSK 613 ostvario ovako dobar rezultat u proizvodnim uvjetim Turske. Rezultat je time značajniji što je to hibrid stvoren u Hrvatskoj, u sasvim drugačijim uvjetima selekcije i proizvodnje kukuruza. To znači da i hibridi stvoreni selekcijom bez navodnjavanja mogu imati vrlo visoki potencijal rodnosti koji uglavnom u našim uvjetima nikada u potpunosti ne dolazi do izražaja. Naravno, to zahtjeva i odgovarajuću, korektno provedenu mrežu ispitivanja takvih potencijalnih hibrida u uvjetima navodnjavanja, kao u Turskoj.

Dvofaktorijelnom i trofaktorijelnomANOVA–om (tablice 31. i 32.) utvrđeno je postojanje statistički značjnih izvora variranja kod hibrida, okolina, njihove interakcije, kao i kod godina, lokacija, hibrida i osobito kod interakcije lokacija i godina. Ovakav

rezultat je očekivan s obzirom na veliku heterogenost, prije svega lokacija koje su uključene u ispitivanje.

I vrijednost Tukey testa (tablica 33.) pokazuje nam da su u prvom redu, okoline uzrok heterogenosti regresije. Yuksel i Akcura (2012.), Chapman i sur. (1997.) i Setimela (1997.) navode okoline kao dominantni izvor variranja. Riggs i suradnici (1986.) navode da kod pokusa na većem zemljopisnom području faktori lokacije dobivaju na značaju. Suprotno tome Karimizadeh (2012.) u svojem istraživanju nije imao kao statistički značajan izvor variranja okoline, već su to bile godine i interakcija genotipova i okolina.

Za procjenu stabilnosti hibrida i okolina korištena su dva parametra b_i i s^2_{di}.

Prema pristupu Eberharta i Russella (1966.) bilo bi potrebno hibride grupirati u 4 skupine, što je u ovom slučaju prilično otežano poglavito zbog visokih vrijednosti s^2_{di}. Rečeno je da idealan hibrid mora imati što veću srednju vrijednost prinosa, koeficijent regresije b_i=1,00 i varijancu odstupanja od regresije s^2_{di} = 0,00. Da bismo mogli donositi vjerodostojne zaključke prema vrijednostima s^2_{di} potreban je što veći broj okolina, dok se kod regresijskog koeficijenta zaključci mogu donositi i na manjem broju ali vrlo različitih okolina. U ovom istraživanju imamo relativno veliki broj okolina (17), ali su vrijednosti s^2_{di} uglavnom oko 1,00 ili više od toga. Stoga se ovaj parametar stabilnosti može ovdje koristiti u relativnom odnosu veličina manji-veći međusobno, odnosno prema tumačenju Eberharta i Russella vrijednosti s^2_{di} trebaju biti niske. U ovom slučaju one su niske ili visoke kod jednog hibrida prema vrijednosti s^2_{di} kod drugog hibrida ali su njihove apsolutne vrijednosti više od očekivanih.

Hibridi koji su svrstani u skupinu stabilnih i visoko prinosnih su čak njih 8, od ukupno 22 (tablica 37.).

Često puta dogodi se (Jambrović, 2001., Zdunić, 1998., Krizmanić i sur., 2003., Čupić i sur., 2003.) da najprinosniji hibrid nije i onaj koji ima najbolje i najujednačenije parametre stabilnosti. Tako i ovdje, hibrid Shemal, sa najboljim prinosom, ima dobru vrijednost b_i, ali mu je vrijednost s^2_{di} previsoka da bi ga mogli proglasiti jednim od najstabilnijih hibrida u pokusu.

Prilično jasno hibridi su se svrstali i u preostale dvije skupine – nestabilne i nisko prinosne (tablica 38.) i nestabilne i visoko prinosne (tablica 39.).

Osim ove tri skupine hibrida koje se dosta jasno mogu definirati, postoje i hibridi kod kojih je vrijednost parametara stabilnosti takva da ih ne možemo jasno svrstati niti u jednu skupinu (tablica 40.). Ovi hibridi, u pravilu imaju b_i>1,00 kao u skupini nestabilnih

ali visoko prinosnih hibrida, ali i vrlo visoku vrijednost s^2_{di} kao nestabilni i niskoprinosni hibridi (tablica 38.). Po visini srednje vrijednosti prinosa kroz godine i okoline, u ovu skupinu uglavnom dolaze hibridi koji imaju srednje vrijednosti prinosa gotovo iste kao što su i srednje vrijednosti prinosa svih hibrida u pokusu – 11.22 t/ha, ili neznatno viši ili neznatno niži prinos od njih. Među tim hibridima je i standardni hibrid OSSK 602 koji je godinama (uz stari hibrid OSSK 644) činio osnovnu ponudu koju je Poljoprivredni institut Osijek imao za tržište Turske. Pokazalo se da je moguće selekcijom i odgovarajućom mrežom dobro provedenih pokusa proizvesti hibride boljih proizvodnih karakteristika od ovog standardnog hibrida.

Isti problem kao kod hibrida, pojavio se i kod pokušaja svrstavanja okolina u odgovarajuće skupine stabilnosti ili nestabilnosti jer praktično nije moguće složiti više okolina zajedno poštujući kriterije koje postavljaju Eberhart i Russell. Najčešće se radi o nepovoljnoj kombinaciji parametara stabilnosti, gdje je jedan parametar, najčešće b_i, izrazito niži ili viši od 1,00 a u isto vrijeme vrijednosti s^2_{di} su u većini slučajeva više od očekivanih.

U stabilne i visoko prinosne okoline, po ovim parametrima dolazi samo lokacija Adana, 2. sjetva, u obje godine (tablica 42.). Tri okoline dolaze u 2. skupinu - nestabilnih i nisko prinosnih (tablica 43.), a 5 okolina nalazi se u skupini nestabilnih i visokoprinosnih okolina (tablica 44.).

Najveći broj okolina (7 od ukupno 17) možemo ubrojiti u skupinu tzv: „nesvrstanih„ (tablica 45.). Te okoline po pravilu, imaju neujednačene vrijednosti ova dva parametra stabilnosti. Prisutne su gotovo sve moguće kombinacije parametara, ali na način da to otežava svrstavanje okolina u jednu od prije navedenih skupina.

Tu se nalaze okoline sa najnižim prinosom – Mersin 2010./2. sjetva, ali i Manisa 2011./1. sjetva kao jedna od najprinosnijih okolina u istraživanju. Isto tako, moramo primjetiti da je Manisa, kao lokacija na kojoj su ostvarene najviše srednje vrijednosti prinosa i gdje nije bilo slučajeva u obje godine da bi pokus bio ugrožen bilo zbog biotskih ili abiotskih stresova, čak u tri od ukupno četiri slučaja svrstana u skupinu okolina sa neujednačenim parametrima stabilnosti okolina. To ukazuje još jednom na veliku heterogenost okolina koje su uključene u ovo istraživanje, kao i podaci iz tablice 46., gdje se nalazi pregled korelacijskih koeficijenata između srednje vrijednosti prinosa zrna sa pojedinih okolina, kao i između pojedinih okolina. Ono što se može odmah uočiti je da niti kod jedne okoline (u Turskoj se uspoređuju isti rokovi sjetve, na istoj lokaciji, u dvije

godine), nije zabilježena visoko značajna korelacija povezanosti prinosa, iz godine u godinu, na istoj lokaciji. To je u skladu sa tvrdnjom koju iznosi DeLacy (1994.) - da često megaokolinska klasifikacija ne može objasniti jasnu povezanost između lokacija.

Možemo uočiti također, da je ponovljivost parametara stabilnosti i kod hibrida i kod okolina, iz godine u godinu bila uglavnom niska. Sličnu situaciju imali su i brojni drugi autori (Becker i Leon, 1988.; Lin i sur., 1986.; Eberhart i Rusell, 1966.; Milas, 1983.; Sneller i sur., 1997.) Ovo otežava rangiranje genotipova iz višegodišnjih rezultata. Poželjno je imati što više podataka, a naravno i što više godina ispitivanja, jer iako je ponovljivost parametara mala, određene pravilnosti ipak se mogu uočiti.

Vidimo da je korelacija između koeficijenta regresije i varijance odstupanja od regresije nisko signifikantna za hibride i nesignifikantna za okoline, sa vrijednostima 0,175 i 0,414 (tablice 47. i 48.). To je u skladu sa iskustvima drugih autora (Zdunić, 1998.; Milas, 1983.; Becker i Leon, 1988.) koji navode da između ovih parametara stabilnosti nema značajnih korelacija i upućuje nas na potrebu korištenja oba ova parametra stabilnosti, jer svaki od njih na svoj način procjenjuje stabilnost hibrida i okolina.

Na slikama 13., 14. i 15. prikazano je grupiranje hibrida u skupine, primjenom Pattern analize, prema Wardovoj metodi. Osnovni kriterij bila je visina prinosa, tijekom 2010. godine, na ukupno 9 okolina u Hrvatskoj i Turskoj (slika 13.), a tijekom 2011. godine na ukupno 8 okolina (slika 14.), te skupno za 17 okolina na slici 15.

Sve hibride dijelimo na dvije osnovne skupine: visokoprinosne i niskoprinosne hibride. Ovi rezultati slični su rezultatima koje je dobio Zdunić, 2010. godine, kada su analizirani hibridi također bili grupirani u dvije veće skupine. Hibridi koji su svrstani u visoko prinosne u obje godine pojedinačno, te na kraju skupno, bili su hibridi pod brojevima 2, 3, 16, 21 i 22. Ova skupina hibrida ima dvije podskupine ili klastera sa međusobno vrlo sličnim reakcijama na pojedine okoline tijekom obje godine.

U skupinu nisko prinosnih hibrida svrstani su svi ostali hibridi u pokusu. Ovdje su prisutne tri podskupine hibrida koji su međusobno slično reagirali kroz okoline tijekom 2011. godine.

Ova podjela na manje skupine hibrida sa međusobno sličnim reakcijama analiziranog svojstva (u ovom slučaju to je prinos), omogućena je tehnikom ordinacije (Ward, 1963.; Kroonenberg i sur., 1995.). Na ovaj način oplemenjivači dobivaju dodatne informacije o ispitivanim genotipovima i često puta već na osnovu ovakvih podjela mogu uočiti pojedine skupine hibrida (ili čak i skupine inbred linija, ako se radi o istraživanju sa

roditeljskim komponentama hibrida) koji su međusobno sličniji i genetski bliži (Kroonenberg i sur., 1995.).

Zanimljiva je usporedba svrstavanja hibrida u skupine Pattern analizom i procjena njihove stabilnosti prema odgovarajućim parametrima (Sabaghnia i sur., 2012.). Korištenjem različitih tehnika grupiranja i procjene stabilnosti hibrida dobivene su skupine hibrida sa različitim brojem članova (kod stabilnosti), ili su se hibridi grupirali u više ili manje skupina, kod cluster analize. Ponovljivost dobivenih rezultata korištenjem različitih tehnika klasifikacije analiziranih hibrida bila je niska. U ovom istraživanju parametri stabilnosti kod hibrida nisu nam omogućili jasno grupiranje hibrida u skupine prema kriterijima Eberharta i Russella, u prvom redu zbog visokih vrijednosti s^2_{di} (kao posljedica velike heterogenosti korištenih okolina). Ipak, kod klasifikacije stabilnih i visoko prinosnih hibrida čak 5 hibrida (pod brojevima 2, 13, 17, 21 i 22) su i prema Pattern analizi bili uvršteni u skupinu visoko prinosnih hibrida, sa međusobno vrlo sličnim reakcijama po pitanju prinosa, kroz godine i okoline. Stoga možemo reći da su korištenjem parametara stabilnosti i Pattern analize pronađeni praktično isti hibridi, bilo da su se oni zvali stabilnima ili bili u skupini hibrida sa visokim prinosom.

Kod grupiranja nestabilnih i nisko prinosnih hibrida, prema parametrima stabilnosti, tu bi pripadali hibridi pod brojevima 5, 8 i 14. Kod klasteriranja brojevi 8 i 14 bili su u sva 3 analizirana slučaja u skupini nisko prinosnih hibrida, ali nikada u istoj podskupini, sa međusobno bliskim reakcijama kroz okoline i godine. Hibrid broj 5 čak je u zbirnom dendrogramu (slika 4.) za obje godine svrstan u skupinu visoko prinosnih hibrida. I kod samog grupiranja nisko prinosnih hibrida uočeno je slabije jasno grupiranje međusobno sličnih hibrida po prinosu nego što je to bio slučaj kod visoko prinosnih hibrida. Stoga možemo zaključiti da je korištenjem parametara stabilnosti i Pattern analize, grupiranje nestabilnih i niskoprinosnih hibrida dalo rezultate koji se međusobno dosta razlikuju i mogu se različito interpretirati.

Kada se radi o okolinama i njihovom grupiranju, Shabana i suradnici (1974.) koriste dva osnovna kriterija kod izbora najboljih okolina za selekciju, ali i za testiranje i izbor najboljih genotipova:

1. Izbor u optimalnim uvjetima, gdje je pouzdanost podataka iz godine u godinu vrlo visoka,
2. Izbor u stresnim uvjetima, jer se najveći dio biljne proizvodnje i odvija pod takvim uvjetima. Gauch (1997.) navodi da upravo okoline kod kojih je jako izražen neki

stres tijekom vegetacije (u ovom slučaju to su vrlo visoke temperature zraka, uz nužno navodnjavanje), i gdje je interakcija GxE velika, čine tzv. marginalne okoline u kojima živi veliki broj ljudi koji trebaju u proizvodnji genotipove prilagođene na te specifične uvjete.

Često se u oplemenjivačkim programima selekcija odvija unutar nekog ciljanog područja koje je samo po sebi dosta varijabilno, odnosno sadrži varijabilne okoline. U ovom istraživanju bilo je postavljano pitanje od suradnika iz Turske zašto se inzistira na visokoj preciznosti izvođenja pokusa (visoki postotak ostvarenog sklopa, preciznost u količini dodanog gnojiva u prihrani između parcelica, u nastojanju da se što uspješnije izvrši zaštita od korova), kada se to u širokoj proizvodnji uglavnom ne događa u toj mjeri, odnosno nije li kod samog testiranja novih hibrida bolje oponašati uvjete iz široke proizvodnje, koji su više ili manje prosječni, nego stvoriti vrhunske, praktično optimalne uvjete za uzgoj. Činjenica je da su hibridi, koji su testirani i izabrani u najboljim okolinama, u pravilu manje oscilirali u prinosima na prosječnim okolinama, ali u ovom istraživanju imali smo prilično veliki raspon oscilacija u faktorima koji jednu lokaciju čine optimalnom, prosječnom ili lošom, prema Federeru i Sculliyu (1993.).

Lin i Thompson (1975.), Lin (1982.) i Lin i Butler (1990.), prema Karimizadeh (2012.) predložili su posebnu cluster analizu za analiziranje dvosmjerne GxE interakcije. Cluster analiza može prepoznati razlike između genotipova, što je važno za oplemenjivače, preko klasifikacije genotipova.

Okoline u Hrvatskoj u 2010. godini, (Osijek i Karanac) pokazale su se kao izdvojena cjelina (slika 16.) u odnosu na okoline u Turskoj, nevezano za rok sjetve u Turskoj. U Turskoj se te godine formiralo praktično, tri podskupine ili klastera. Jednu podskupinu okolina čine Manisa, Mersin i Adana – sve u drugoj sjetvi. To je pokazatelj da je te godine rok sjetve mogao poslužiti kao kriterij međusobne sličnosti lokacija u Turskoj. Ovaj podatak govori nam da smo te 2010. godine mogli imati manje lokacija u drugoj sjetvi jer dolazi do preklapanja podataka sa više lokacija i podaci postaju redundantni

Na slici 17. nalazi se pregled grupiranja okolina prema visini prinosa, tijekom 2011. godine, u obje zemlje. Ovaj puta radilo se o 8 okolina. Ponovo je vidljiva podjela na dvije cjeline, odnosno dvije međusobno odvojene megaokoline – Hrvatsku i Tursku. Okoline u Hrvatskoj (Osijek i Karanac) bile su grupirane odvojeno od okolina u Turskoj. U Turskoj se te godine formiralo tri podskupine ili klastera.

Tijekom 2011. godine, okoline je moguće grupirati i u Turskoj, ali ovaj puta to nije bio slučaj prema roku sjetve, kao u 2010. godini, već same lokacije po sebi predstavljaju zasebne, odvojene cjeline, neovisno o roku sjetve. U prvu skupinu okolina ulazi Altinova, sa oba roka sjetve. Drugu skupinu okolina čini Manisa, sa oba roka sjetve. Proizlazi da smo te godine, mogli imati samo podatke o prinosima analiziranih hibrida, iz prvog roka sjetve, sa te dvije lokacije, i nije bilo potrebno raditi drugu sjetvu, jer se podaci praktično preklapaju i nisu bili nužno potrebni da bi mogli donositi ispravne zaključke sa tih lokacija.

Međutim, Wedderburn (1993.) te Babić i sur. (2011.), navode da na osnovi ovakvih podataka ne možemo izvoditi dalekosežne zaključke, jer se radi o jakim interakcijama genotipova i okoline, pa bi izdvajanje neke od okoline kao superiorne ili loše, na osnovi samo jedne ili dvije godine istraživanja bio preambicizno postavljeni cilj i da bi za točnije i preciznije identificiranje megaokolina bilo nužno ispitivanje provoditi kroz više godina. Neki autori koristili su podatke o prinosima (kod više različitih kultura) iz pokusa koji su bili provođeni kroz minimalno dvije godine (Ilker i sur. 2009.), ali bilo je i onih koji su analizirali pokuse kroz 10 ili više godina – De Lacy i suradnici (1994.) za period od čak 26 godina, a Barrero Farfan i suradnici (2013.) za 11-godišnji period.

Ipak, ovakvi rezultati ukazuju na adaptabilnost određene germplazme kukuruza na određene, manje regije, što je od velike koristi oplemenjivačima i oplemenjivačkim programima da mogu pozicionirati okoline koje trebaju biti ishodišta buduće selekcije roditeljskih inbred linija i za stvaranje uvjeta za nastanak novih hibrida baš na tom području. Pokazalo se da je to nužno i zahvaljujući ovakvim rezultatima. Oni pokazuju da oplemenjivanjem kukuruza u Hrvatskoj, stvaramo u prvom redu hibride koji su prilagođeni uvjetima suhog ratarenja i dužine vegetacije od travnja do sredine listopada, kada dolaze prvi mrazevi. Pretpostavka je bila da kod navodnjavanja i kod vegetacijskog perioda od travnja pa praktično do sredine prosinca, nije moguće imati hibride stvorene u Osijeku koji će po prinosu moći konkurirati hibridima u Turskoj.

Hibrid stvoren u Osijeku, pod brojem 3 = OSSK 613, imao je najviši ostvareni prinos, tijekom zbirnog obračuna, za prvi rok sjetve, u obje godine. To je bilo prilično neočekivano, jer u prvoj sjetvi dolazi do izražaja maksimalni kapacitet rodnosti nekog hibrida, ali pokazalo se da nije nemoguće. To otvara novi zahtjev – za što obuhvatnijom mrežom lokacija za testiranje hibrida u Turskoj, iz koje bi onda podaci bili dovoljno pouzdani i ne bi ostavljali dvojbe, po pitanju vjerodostojnosti.

Na slici 18. nalazi se pregled grupiranja okolina prema visini prinosa, skupno, za 2010. i 2011. godinu, u Hrvatskoj i u Turskoj, sa ukupno 17 okolina.

Ponovo je vidljiva podjela na dvije cjeline, odnosno dvije međusobno odvojene megaokoline – Hrvatsku i Tursku, ali ne tako jasno kao kada se radi o rezultatima pojedinačnih godina. Lokacije u Hrvatskoj (Osijek i Karanac) pokazale su se kao izdvojena cjelina u odnosu na lokacije u Turskoj, ali samo za 2011. godinu. Ostatak okolina podijelio se u dvije zasebne, po godinama djelomično bliske ali međusobno ipak heterogene podskupine okolina.

Na slici 19. nalazi se pregled grupiranja okolina prema visini prinosa, skupno, za 2010. i 2011. godinu, i u Hrvatskoj i u Turskoj, ali sa ukupno 16 okolina. Iz izračuna je izdvojena okolina Mersin 2010. godine, 2. sjetva. Osnovni razlog bio je potreba balansiranja podataka, kao kod trofaktorijelne ANOVA-e. Ova okolina nije imala balans, tj. nije postojala okolina Mersin 2011. godine, 2. sjetva, što bi činilo tu okolinu jednom cjelinom. Okolina Mersin 2010. godine, 2. sjetva, bila je u mnogome kontradiktorna svim ostalim okolinama tijekom ovog dvogodišnjeg istraživanja. Ostvareni prinos bio je vrlo nizak, znatno niži u odnosu na sve ostale okoline i godine, ali poredak genotipova unutar pokusa pokazao se kao smislen i zbog toga ova okolina nije izbačena iz izračuna svih ostalih parametara. Da je odluka da se ova okolina ostavi kao vjerodostojna za ovo istraživanje ispravna, pokazala je tablica 46., gdje je vidljivo da je između malog broja statistički značajnih ili vrlo značajnih korelacija ostvarenih prinosa između analiziranih okolina, najveći broj bio upravo sa okolinom Mersin 2010., 2. sjetva. Sve ostale okoline bile su u parovima. Prisjetimo se da u izračun nije ušla okolina Adana, ali u paru, tj. nije bilo rezultata iz sjetve Adana 2010. godine 1. sjetva i Adana 2011. godine, također 1. sjetva, što nije poremetilo balansiranje podataka.

Sad je interpretacija rezultata malo drugačija. Podjela na dvije cjeline, odnosno dvije međusobno odvojene megaokoline – Hrvatsku i Tursku ostala je i dalje. Okoline u Hrvatskoj (Osijek i Karanac) ostale su izdvojena cjelina u odnosu na okoline u Turskoj, ali samo za 2011. godinu. To je praktično jedna megaokolina, za sebe. Ostatak okolina zadržao je podjelu na dvije zasebne, po godinama djelomično bliske podskupine okolina. Značaj što većeg broja godina u provođenju pokusa poznat je (Hallauer, 1981.; Talbot, 1997.; Leon i Becker, 1988.). U ovom slučaju, 2010. godina dala je drugačije rezultate nego 2011., osnovni razlog (previše vode – 2010., premalo vode – 2011. godine) naveden je ranije.

Glavna razlika u odnosu na sliku 18., sa okolinom Mersin 2010. godina, 2. sjetva, je ponovno spajanje okolina u Hrvatskoj u 2010. godini, što je i u pojedinačnim godinama bio slučaj.

Ono što nije vidljivo iz ovog završnog grupiranja okolina, vidljivo je iz pojedinačnih godina, (slike 16. i 17.). Naime, kada gledamo grupiranje okolina iz slika 18. i 19., možemo pomisliti da i okoline iz Hrvatske 2010. godine ulaze u skupinu turskih okolina i da nije moguća podjela na megaokoline, odnosno da se sve okoline mogu svrstati samo u jednu megaokolinu. Na slikama 16. i 17. jasno se vidi da to nije tako, odnosno da se okoline u Hrvatskoj jasno odvajaju od onih u Turskoj, neovisno od godine.

Što se tiče grupiranja okolina u Turskoj, možemo uočiti da se u obje godine, uglavnom, preklapaju rezultati sa pojedinih okolina iz prve i druge sjetve. To je vrlo važan i koristan podatak jer u tom slučaju nije uvijek nužno provoditi i drugu sjetvu sa istim hibridima, u istoj godini, na istoj okolini. To može doprinijeti smanjivanju troškova provođenja pokusa, bez da se izgubi vjerodostojnost dobivenih podataka (Jambrović, (2001.); Ilker i sur., (2006.); Šimić, (2003.)).

Isto tako, to otvara mogućnost, da se u okviru istih financijskih troškova, postavi 2 ili više pokusa na novim lokacijama u 1. sjetvi, koje su reprezentativne u Turskoj, a gdje pokusi do sada nisu bili postavljani. Ono što nije dobro provedeno, je sjetva u jugoistočnim lokacijama u Turskoj (Adana i Mersin) koje zauzimaju značajne površine u proizvodnji kukuruza u Turskoj. U okviru ovog istraživanja, često puta podaci sa tih lokacija nisu mogli biti korišteni, jer pokus nije bio korektno postavljen i proveden. Moguće je da je osnovni problem bilo vrijeme sjetve, jer uobičajeno vrijeme sjetve za te dvije regije je početak travnja (20-tak dana ranije nego u Altinovi i Manisi), a to nije bilo ispoštovano tijekom ovog istraživanja, pa je sjetva kasnila i rezultati su izostali, ili nisu bili u toj mjeri dobri kako smo to očekivali.

5. ZAKLJUČCI

Prema dobivenim rezultatima istraživanja sa 22 hibrida kukuruza, na 17 okolina, u 2010. i 2011. godini, u Hrvatskoj i Turskoj, a prema unaprijed postavljenim ciljevima, možemo zaključiti:

1. Univarijatnom ANOVA-om utvrđeno je statistički vrlo značajno variranje prinosa hibrida kukuruza, za gotovo sve okoline i obje godine, u Hrvatskoj i Turskoj. Izuzetak je situacija u Hrvatskoj, u dvogodišnjoj analizi, kada hibridi nisu bili izvor variranja, nego samo okoline. Dvofaktorijelnom ANOV-om, kao statistički značajan izvor variranja, potvrđeni su i okoline i hibridi, uz $P<0,01$, a ista je situacija potvrđena i trofaktorijelnom analizom varijance.

2. Interakcija GxE bila je statistički vrlo značajna u većini analiziranih pokusa, izuzev u Turskoj u 1. sjetvi, gdje nije bilo statistički značajne interakcije. Dvofaktorijelna analiza varijance pokazuje statistički vrlo značajnu interakciju GxE, uz $P<0,01$, kao i skupna trofaktorijelna analiza varijance, napravljena nakon balansiranja podataka. Isti je slučaj i kod interakcije okolina x godina (LxY). Kod interakcija hibrid x okolina (GxL) i hibrid x godina (GxY) nije ostvarena statistička značajnost interakcija, dok je interakcija hibrida, godina i okolina (GxLxY) bila statistički značajna uz $P<0,05$.

3. Procjenjena su 2 parametra stabilnosti, (b_i i s^2_{di}) za hibride i za okoline. U skupinu stabilnih hibrida, koristeći oba ova parametra stabilnosti, uvršteni su hibridi pod brojevima 10, 13, 17, 9, 6, 2, 21 i 22. Hibrid sa najvećom srednjom vrijednosti prinosa (broj 21) nije i najstabilniji. Tri su hibrida svrstana u nestabilne i preporučene za uzgoj u niskoprinosnim okolinama (brojevi 5, 8 i 14). Nestabilni hibridi adaptirani na visokoprinosne okoline su pod brojevima 1, 3, 4 i 7. Sedam hibrida imalo je neujednačene vrijednosti ovih parametara stabilnosti i nije ih bilo moguće jasno svrstati niti u jednu od do sada navedenih skupina. Koristeći iste parametre stabilnosti, stabilnim okolinama možemo nazvati samo okolinu Adana, 2. sjetva u 2010. i 2011. godini. U nestabilne i niskoprinosne okoline možemo ubrojiti 3 potpuno međusobno nevezane okoline, kako zemljopisno, tako i prema godinama i rokovima sjetve. To su Karanac 2010., Altinova 2010., 1. sjetva i Manisa 2011., 2. sjetva. Nestabilne, a visokoprinosne okoline su isto vrlo raznorodne okoline, ali sa dominacijom 2011. godine (4 od 5 tih okolina su u istoj godini). U ovoj skupini je i okolina Altinova 2011., 1. sjetva, koja je imala najviši ostvareni prinos od svih u pokusu. Najveći broj okolina (7 od ukupno 17) ne možemo svrstati u neku od do sada navedenih skupina. Te okoline, po pravilu, imaju neujednačene vrijednosti ova dva

parametra stabilnosti. Tu se nalaze okoline sa najnižim prinosom – Mersin 2010., 2. sjetva, ali i Manisa 2011., 1. sjetva kao jedna od najprinosnijih okolina u istraživanju.

4. Primjenom Pattern analize napravljeno je grupiranje hibrida i okolina. Ovo grupiranje hibrida rezultiralo je svrstavanjem hibrida u dvije osnovne skupine = nisko i visoko prinosne hibride. U skupinu visoko prinosnih hibrida, kroz sve tri analize (2010., 2011. i skupno za obje godine) svrstani su hibridi pod brojevima 2, 3, 16, 21 i 22. Po istim kriterijima, u skupinu nisko prinosnih hibrida svrstani su hibridi po brojevima 1, 6, 7, 8, 10, 18 i 19. Čak 5 hibrida (pod brojevima 2, 13, 17, 21 i 22) koji su svrstani u skupinu stabilnih putem procjene parametara stabilnosti i u skupinu visoko prinosnih i putem Pattern analize bili su uvršteni u skupinu visoko prinosnih hibrida, sa međusobno vrlo sličnim reakcijama po pitanju prinosa, kroz godine i okoline. Stoga možemo reći da su korištenjem parametara stabilnosti i Pattern analize pronađeni praktično isti hibridi. Kod grupiranja nestabilnih i nisko prinosnih hibrida, prema parametrima stabilnosti, tu bi pripadali hibridi pod brojevima 5, 8 i 14. Kod klasteriranja brojevi 8 i 14 bili su u sva 3 analizirana slučaja u skupini nisko prinosnih hibrida, ali nikada u istoj podskupini, sa međusobno bliskim reakcijama kroz okoline i godine. Grupiranje okolina dalo nam je odgovor o postojanju dvije megaokoline. To su megaokolina u Hrvatskoj i megaokolina u Turskoj, bez obzira na rok sjetve. Značaj većeg broja godina provođenja pokusa vidljiv je kod skupnog izračuna za 2010. i 2011. godinu, posebno u Hrvatskoj, kad je zbog specifičnih klimatskih prilika, svrstavanje okolina u megaokoline i podskupine okolina bilo manje jasno, nego kod pojedinačnih godina. Postoji podudarnost dobivenih podataka sa pojedinih okolina u Turskoj, po pitanju 1. i 2. sjetve, što navodi na mogućnost uvođenja dodatnih okolina za testiranje, bez povećanja financijskih troškova samog provođenja postupka.

5. Značaj i primjenjivost ovakvih rezultata u praktičnom oplemenjivanju u prvom redu je u tome da smo dobili brojne informacije i možemo bolje tumačiti dobivene rezultate. Korištenje megaokolinskih pokusa esencijalno je u oplemenjivanju, kako za otkrivanje uže adaptabilnosti za manje, zemljopisno bliže regije, tako i za veće, međusobno udaljene i prostorno diskontinuirane regije, kao što su Hrvatska i Turska.

6. LITERATURA

1. Abou-El-Fittouh, H.A.; Rawlings, J.O.; Miler, P.A. (1969.): Classification of environments to control by environment interaction with an application to cotton. Crop science, 9: 135-140.
2. Adeyemo, M.O.; Fakorede, M.A.B. (1990.): Stability and environmental responses of top cross hybrids, varietal hybrids and Open-polinating cultivars of maize. Turrialba, 40: 299-303.
3. Allard, R.W.; Bradshaww, A.D. (1964.): Implication of genotype – environmental interractiona in applied plant breeding. Crop science, 4: 503-508.
4. Algarswamy, G.; Chandra, S. (1998.): Pattern analysis of international sorghum multienvironment trials for grain-yield adaptation. Theoretical and Applied genetics, 96: 397-405.
5. Annicchiarico, P. (2002.): Genotype x environment interactions – Challenges and opportunities for plant breeding and cultivar recommendations. FAO Plant Production and Protection Paper, No 174, FAO Rome.
6. Atlin, G.N.; Baker, R.J.; Mc Rae, K.B.; Lu. X. (2000.): Selection response in subdivided target regions. Crop science, 40: 7-135.
7. Azad, M.A.K.; Biswas, B.K.; Alam, N.; Alam, Sk.S. (2012.): Genetic diversity in maize (*Zea mays L.*) inbred lines. The Agriculturalist, A scientific journal of Krishi Foundation, 10 (1): 64-70.
8. Babić, M.; Anđelković, V.; Vojka Babić (2008.): Genotype by environmental interaction in maize breeding. Genetika, Vol.40, No 3: 303-312.
9. Babić Vojka; Babić, M.; Ivanović, M.; Filipović, M. (2011.): Pattern interaction in the maize yield trial. Journal of agricultural sciences, Vol.56, No 2: 101-110.
10. Barrero Farfan, I.D.; Murray, S.C.; Labar, S.; Pietsch, D. (2013.): A multi-environment trial analysis shows slight grain yield improvement in Texas commercial maize. Field crops research, 1¸49: 167-176.
11. Basford, K.E.; McLachlan, G.J. (1985.): The mixture method of clustering applied to three-way data. Journal of Calssification, 2: 109-125.
12. Balestre, M.; Von Pinho, R.G.; Souza, J.C.; Oliveira, R.L. (2009.): Genotypic stability and adaptability in tropical maize based on AMMI and GGE biplot analysis. Genet. Mol. Res. 884, 1311-1322.

13. Becker, H.C. (1981.): Corelation among some statistical measures of phenotypic stability, Euphytica, 30: 835-840.
14. Becker, H.C.; Leon, J. (1988.): Stability analysis in plant breeding. Plant breeding 101: 1-23.
15. Bindraban, P.; Louwaars, N.; Loffler, H.; Van Hintum, T.; Rabinge, R. (2006.): Breeding strategy for mixed production system in sub – Saharan Africa. Tailoring Biotechnologies, Vol.2: pp57-76.
16. Braun H.J.; Rajaram S.; Ginkel M. (1996.): CIMMYT‟s approach to breeding for wide adaptation. Euphytica 92: 175-183.
17. Braun, H.J.; Atlin, G.; Payne, T. (2010.): Multi location testing as a tool to identify plant response to global climate change, ed. M.P. Reynolds, 115.
18. Brkić, I.; Jambrović, A.; Zdunić, Z.; Šimić, D. (1998.): Kvantitativno- genetički pristup optimiranju procjene genotipske vrijednosti eksperimentalnih hibrida kukuruza. XXXIV Znanstveni skup hrvatskih agronoma, Zbornik sažetaka Opatija.
19. Byth, D.E.; Eisemann, R.L.; DeLacy, I.H. (1976): Two-way pattern analysis of a large data set to evaluate genotypic adaptation. Heredity 37: 215-230.
20. Chapman, S.C.; Crossa, J.; Edmeades, G.O. (1997.): Genotype by environment effects and selection for drought tolerance in tropical maize. I. Two mode pattern analysis of yield. Euphytica, 95: 1-9.
21. CIMMYT (2009): The drought tolerant maize for Africa initiative – DTMA project. http://dtma.cimmyt.org/project-definitions.
22. Cooper, M.; Delacy, I.H. (1994.): Relationships among analytical methods used to study genotipic variation and genotype – by environment interaction in plant breeding multi – environment experiments. Theoretical applied genetics, 88: 561-572.
23. Crossa, J. (1990.): Statistical analysis of multilocation trials. Advances in agronomy 44, 55-86.
24. Ćupić, T.; Popović, S.; Tucak, M.; Stjepanović, M.; Sonja Grljušić (2003.): Procjena stabilnosti prinosa zrna graška (*Pisum sativum L.*). Poljoprivreda, 9: 37-41.
25. Delacy, I.H.; Fox, P.N.; Corbet, J.D.; Crossa, J.; Rajaram, R.A.; Fischer and Van Ginkel (1994.): Long-term associations of locations for testing spring bread wheat. Euphytica, 72: 95-106.

26. DeLacy, I.H.; Basford, K.E.; Cooper, M.; Bull, J.K.; C.G. McLaren (1996.a): Analysis of multi-environment trials - an historical perspective. Plant Adaptation and Crop Improvement, M. Cooper and G.L. Hammer (Eds.). CAB International. Oxford.
27. DeLacy, I.H.; Basford,K.E.; Fox, P.N. (1996.b): Retrospective analysis of historical data sets from multi environment trials – case studies. Plant adaptation and Crop improvement, pp269-290.
28. Dolatabad, S.S.; Choukan, R.; Hervan, E.M.; Dehghani, H. (2010.): Biplot analysis for multi-environmental trials of maize (*Zea mays L*.) hybrids in Iran. Crop and pasture science, 61, 700-707.
29. Eberhart, S.A.; Rusell, W.A. (1966.): Stability parameters for comparing varietes. Crop Science 6: 36-40.
30. Falconer, D.S.; Mackay, T.F.C. (1996.): Quantitative genetics. Fourth edition, Longman group Ltd.
31. Federer, W.T.; Scully, B.T. (1993.): A parsimonious statistical design and breeding procedure for evaluating and selecting desirable characteristics over environments. Theoretical and applied genetics, 86: 612-620.
32. Finlay, K.W.; Wilkinson, G.N. (1963.): The analysis of adaptation in a plant-breeding programme, Australian lournal Agric. Res. 14, 742-754.
33. Flores, F.; Moreno, M.T.; Cubero, J.I. (1998.): A comparison of univariate and multivariate methods to analyze GxE interaction. Field crops research, Vol 6: 271-286.
34. Fox, P.N.; Crossa, J.; Romagosa, I. (1997.): Multi-environmental testing and genotype x environment interaction. Statistical methods for plant variety evaluation. Edited by R.A. Kempton and P.N. Fox, published in 1997 by Chapman and Hall, London.
35. Fox P.N.; A.A. Rosielle (1982.): Reducing the influence of environmental mean effects on pattern analysis of plant breeding environments. Euphytica 21: 645-656.
36. Francis, T.R.; Kannenberg, L.W. (1978.): Yield stability studies in short-season maize. I.A descriptive method for grouping genotypes. Ca. J. Plant Sci., 58: 1029-1034.
37. Gauch, H.G.; Zobel, R.W. (1988.): Predictive and postdictive success of statistical analyses of yield trials. Theor. Appl. Genet, 76: 1-10.

38. Gauch, H.G.; Zobel, J.R.; Richard, W. (1997.): Identifying mega environments and targeting genotypes. Crop science, 1997.
39. Guberac, V.; Sonja Marić; Tolušić, Z. (2001.): Ekonomski učinak primjene kalibriranja u doradi sjemenskog kukuruza. Sjemenarstvo, broj 1-2: 19-29.
40. Gunjača, J.; Knezović, Z.; Pecina, M. (2007.): Genotype by environment interaction in variety trials. Cereal Research Communicatoins, 35 (Part 1): 425-428.
41. Gunjača, J. (1997.): Procjena stabilnosti prinosa iz nebalansiranih setova podataka. Magistarski rad. Agromomski fakultet Sveučilišta u Zagrebu.
42. Halauer, A.R. et al. (1981.): Quantitative genetics in maize breeding. First edition, Iowa state University press.
43. Hallauer, A.R.; Russell, W.A.; Lamkey, K.R. (1988.): Corn breeding, In corn and corn improvement, 3rd edition. (Edit. Sprague, G.F.; Dudley, J.W.) 463-564, Madison, USA.
44. Hill, J.; Becker, H.C.; Tigerstedt, P.M.A. (1988.): Quantitative and ecological aspects of plant breeding, Chapman and Hall.
45. Haussmann, B.I.G.; Hess, D.E.; Reddy, B.V.S.; Mukuru, S.Z.; Kayentao, M.; Welz, H.G.; Geiger, H.H. (2001.): Pattern analysis of genotype x environment interaction for striga resistance and grain yield in African sorghum trials. Euphytica, 122: 297-308.
46. Ilker, E.; Fatma Aykut Tonk; Caylak, O.; Tosun, M.; Ozmen, I. (2009.): Assesment of genotype x environment interactions for grain yield in maize hybrids using AMMI and GGE biplot analyses. Turkish J. Of field crops 14 82: 123-135.
47. Jambrović, A. (1998.): Nasljednost gospodarski važnih svojstava kod inbred linija kukuruza domaćeg i stranog podrijetla. Magistarski rad. Agronomski fakultet u Zagrebu.
48. Jambrović, A. (2001.): Različitost i broj lokacija za testiranje hibrida kukuruza. Disertacija. Agronomski fakultet Sveučilišta u Zagrebu.
49. Kang, M.S.; Miller, J.D. (1984.): Genotype x environment interactions for cane and sugar yield and their implications in sugarcane, Crop Sci. Vol 24, No 3, 435-440.
50. Kamutando, C.N.; Muungani, D.; Masvodza, D.R.; Gasura, E. (2013.): Exploiting genotype x environmental interaction in maize breeding in Zimbabwe. African Journal of Agricultural Research, Vol.8.

51. Karimizadeh, R.; Mohammadi, M.; Sabaghnia, N.; Hosseinpour,T.; Shafazadeh, M.K. (2012.): Analysis of genotype x environment interaction in durum wheat in warm rainfed areas of Iran. Crop breeding journal, 2: 71-76.
52. Kaya Y.; Akcura M.; Taner S. (2006.): GGE-biplot analysis of multi-environment yield trials in bread wheat. Turk J. Agric. 30: 325-337.
53. Khavari Khorasani S.; Mostafavi, Kh.; Zandipour, E.; Heidarian, A. (2011.): Multivariate analysis of agronomic traits of new corn hybrids (*Zea mays L.*). International Journal of AgriScience Vol.1 (6): 314-322.
54. Knezović, Z.; Gunjača, J. (2002.): Neparametrijska mjerila stabilnosti i prinosa nekih sorata ozime pšenice. Agriculturae Conspectus Scientificus 3: 143-148.
55. Krizmanić, G. (2009.): Interakcija genotip x okolina i stabilnost kvantitativnih svojstava hibrida suncokreta. Disertacija. Poljoprivredni fakultet Osijek.
56. Kroonenberg, P.M.; Basford, K.E. (1989.): An envistigation of multi - atribute genotyp response across environments using three – mode principal component analysis. Euphytica, 44: 109–123.
57. Kroonenberg, P.M.; Basford, K.E.; Ebskamp, A.G.M. (1995.): Three-way cluster and component analysis of maize variety trials. Euphytica, 84: 31-42.
58. Lin, C.S.; Butler, G. (1988.): A data-based approach for selecting locations for regional trials. Canadian journal Plant Sciences 68: 651-659.
59. Lin, C.S.; Binns, M.R.; Lefkovitch, L.P. (1986.): Stability analysis: Where we do stand? Crop science, vol. 26, no. 5: 894-900.
60. Liović, I.; Kristek, A. (2000.): Stability of agronomic traits in sugar beet hybrids. Rostlinna vyroba, 46: 189-175.
61. Linda M. Pollak; Corbett, J. (1992.): Using GIS datasets to classify maize growing regionsin Mexico and Central America. Agronomy Juornal, Vol. 85 (6), 1133-1139.
62. Marić Sonja; Ćupić, T.; Julić, G.; Varnica, I.; Dunković, D. (2007.): Selection of testing of environments for winter wheat breeding. Cereal research communication, 35 (2), Part 2: 749-752.
63. Milas, S. (1983.): Metode procjene parametara stabilnosti nekih hibrida kukuruza i sorata pšenice. Magistarski rad. Fakultet poljoprivrednih znanosti u Zagrebu.
64. Milas, S. (1989.): Odnosi parametara stabilnosti, koeficijenata stabilnosti i koeficijenata veze za prirod i komponente priroda kod nekih genotipova kukuruza i

pšenice. Doktorska disertacija. Fakultet poljoprivrednih znanoati Sveučilišta u Zagrebu.

65. Mitrović, B.; Stanisavljević, D.; Treskić, S.; Stojaković, M.; Ivanović, M.; Bekavac, G.; Rajković, M. (2012.): Evaluation of experimental maize hybrids tested in multi location trials using AMMI and GGE Biplot analyses. Turkish journal of fields crops, 17 (1): 35-40.
66. Mungomery, V.E.R.; Shorter & D.E. Byth (1974.): Genotype x environment interactions and environmental adaptation. I. Pattern analysis - application to soya bean populations. Aust. J. Agric. Res., 25: 59-72.
67. Pecina, M. (1998.): Multivarijatna analiza i primjena u oplemenjivanju bilja. Doktorska disertacija. Agronomski fakultet Sveučilišta u Zagrebu.
68. Perkins, J.M.; Jinks, J.R. (1960): Environmental and genotype-environmental components of variability. III. Multiple lines and crosses. Heredity, 23, 339-356.
69. Piepho, H.P. (1995.): The use of multilocation trials to select cultivars that are better than a control. Plant breeding, Vol 114 (4), 337-340.
70. Rajaram, S.; Borlaug, N.E.; Van Ginkel, M. (1998.): CIMMYT international wheat breeding – Concept of mega – environments. http://www.fao.org/docrep/oo6/y4011e/y4011e09.htm
71. Reynolds, P.M. (2010.): Climate change and crop production. Chapter 7: Braun, H.J.; Atlin, G.N.; Payne, T.: Multi-location testing as a tool to identify plant response to global climate change. CIMMYT, Mexico, pp 115.
72. Rozman, L.; Vasilj, Đ.; Kozuplik, V. (1997.): Yield stability in long – term released maize hybrids FAO 100 and 200. Journal of Agronomy and crop science, 179, (4): 193-199.
73. Sabaghnia, N.; Mohammadi, M.; Karimizadeh, R. (2012.): Interpretation of genotype x environment interaction in multi environment trials of bread wheat using cluster analysis. Natura Montenegrina, 11 (3): 511-523.
74. Shabana, R. (1974.): Genetic variability of sunflower varieties and inbred lines. Proceedings of 6th Int sunflower Conference, Bucharest, Romania; pp263-269.
75. Shukla, G.K. (1972.): Some statistical aspects of partioning genotype – envieonmental components.
76. Setimela, P.S. (1997.): Evaluation of maize hybrids for yield and stability in Botsvana. Literature update on maize, May-June, 1998, vol. 4, no. 3.

77. Setimela, P.S.; Badu-Apraku, B.; Mwangi.W. (2009.): Variety testing and release approaches in DTMA project in sub-saharian Africa. Harare, Zimbabwe, CIMMYT: 1-39.
78. Snedecor, G.W.; Cochran, W. G. (1989.): Statistical methods. Eighth edition. Iowa state University Press.
79. Sikora, I. (1973.): Procjena stabilnosti jednostrukih hibrida kukuruza OSSK 295 i OSSK 619. Zbornik radova Poljoprivrednog instituta Osijek, sv. 1, 29-36.
80. Sneller, C.H.; Kilgore – Norquest, L.; Dombek, D. (1997.): Repeatability of yield stability statistics in soybean. Crop science, 37: 383-390.
81. Steel, R.G.D.; Torrie, J.H. (1980.): Principles and procedures of statistics a biometrical approach. Second edition, Mc Graw-Hill Book company.
82. Subramanian, A.; Subbraman, N. (2010.): Hierarchical cluster analysis of genetic diversity in maize germplasm. Electronic Journal of Plant breeding, 1 (4): 431-436.
83. Sudarić Aleksandra; Šimić, D.; Marija Vratarić (2006.): Characterization of genotype by environment interactions in soya bean breeding programmes of southeast Europe. Plant breeding, 125: 191-194.
84. Šimić, D.; Jambrović, A.; Tatjana Ledenčan; Brkić, I.; Zdunić, Z.; Kozumplik, V. (2003.): Pattern analiza interakcije genotip x okolina za prinos zrna u oplemenjivačkim pokusima kod kukuruza. 38. Znanstveni skup hrvatskih agronoma s međunarodnim sudjelovanjem, Opatija, 143-148.
85. Šimić, D.; Zdunić, Z.; Jambrović, A. (2000.a): Optimiziranje izbora lokacije za testiranje prinosa u oplemenjivačkim programima kukuruza i razdioba interakcije genotip x okolina i parametri stabilnosti. Poljoprivreda, časopis Poljoprivrednog fakultet Osijek.
86. Šimić, D.; Jambrović, A.; Brkić, I.; Kozumplik, V. (2000.b): Različitost i optimalan broj lokacija za poljske pokuse kukuruza u Hrvatskoj. Workshop, povodom proslave 80-godišnjice Odjela za oplemenjivanje i genetiku Agronomskog fakulteta u Zagrebu.
87. Tadesse, W.; Manes, Y.; Singh, R.P.; Payne, T.; Braun, H.J. (2010.): Adaptation and performance of CIMMYT spring wheat genotypes targeted to high rainfall areas of the World. Crop science, Vol. 50 (6), 2240-2248.

88. Talbot, M. (1997.): Resource allocation for selection systems. Statstical methods for plant variety evaluation. Edited by R.A. Kempton and P.N. Fox, Published in 1997 by Chapman and Hall, London.
89. Tukey, J.W. (1949.): One degree of freedom for non – aditivity. Biometrics 5: 232–242.
90. Utz, H.F. (1995.): PLABSTAT Version M. Ein Computerprogramm zur statistischen Analyse von pflanzenzuchttenschen Experimenten. Universitat Hohenheim, Stuttgart.
91. Vasilj, Đ.; Milas, S. (1984.): Relationship between stability partameters estimated with different methods for some maize and wheat genotypes. Vortr, Pflanzenzuch. 7, 266-279.
92. Yuksel, S.; Akcura, M. (2012): Pattern analysis of multi – environment yield trials in barley (*Hordeum vulgare L.*). Turk Journal Agriculture For, 36: 285-295.
93. Ward, J.H. (1963): Hierarchical grouping to optimize an objective function. J Am Stat Assoc 58: 236-244.
94. Watson, S.L.; DeLacy, I.H.; Podlich, D.W.; Basford, K.E. (1996.): GEBEI. An analysis package using agglomerative hierarchical classificatory and SVD ordination procedures for genotype x environment data.
95. Wedderburn, R.N. (1993.): International testing: Evaluating and distributing maize germplasm products. CIMMYT, Mexico, 15-22.
96. Windhausen, V.S.; Wagener, S.; Magorokosho, C.; Makumbi, D.; Bindiganavile, V.; Piepho, H.P.; Melchinger, A.E.; Atlin, G.N. (2012.): Strategies to subdivide a target population of environments; Results from the CIMMYT-Led maize hybrid testing programs in Africa. Crop Science,52 (5): 2143-2152.
97. Wishart, D. (1969): An algorithm for hierarchical classifications. Biometrics 25: 165-170.
98. Wricke, G. (1962.): Uber eine Methode zur Erfassung der Oekologischen Streubreite in Feldversuchen. Z. Pflanzenzuchtung, 47: 92-96.
99. Zavala–Garcia, F.; Bramel–Cox, P.J.; Eastin, J.D.; Witt, M.D.; Andrews, D.J. (1992.): Increasing the efficiency of crop selection for unpredictable environments. Crop science, vol. 32: 51-57.
100. Zdunić, Z.; Brkić, I.; Jambrović, A.; Brkić, A.; Brkić, J.; Tatjana Ledenčan; Abdulkadir Cetin; Šimić, D. (2010.): Struktura interakcije genotip x okolina za

prinos zrna OS hibrida kukuruza u megaokolinama Hrvatske i Turske. 45. hrvatski i 5. međunarodni simpozij agronoma, Genetika, oplemenjivanje bilja i sjemenarstvo, Opatija.

101. Zdunić, Z. (1998.): Stabilnost i adaptabilnost prinosa novih Os hibrida kukuruza. Magistarski rad, Agronomski fakultet Sveučilišta u Zagrebu.

7. SAŽETAK

Tijekom 2010. i 2011. godine testirana su 22 hibrida kukuruza na 2 lokacije u Hrvatskoj i na 4 lokacije (sa 2 roka sjetve) u Turskoj. Pokusi su bili posijani u 2 ponavljanja, po slučajnom bloknom rasporedu.

Analizom varijance ustanovljeni su izvori variranja. Dvofaktorijelnom i trofaktorijelnom ANOV-om kao statistički značajan izvor variranja potvrđeni su i okoline i hibridi. Interakcija hibrida i okoline (GxE), bila je statistički vrlo značajna, osim u jednom slučaju. Statistički vrlo značajna interakcija bila je i između okolina i godina (ExY). Kod interakcija hibrida i okolina (GxL), kao i kod interakcije hibrid x godina (GxY) nije ostvarena statistička značajnost, dok je interakcija hibrida, okolina i godina (GxLxY) bila statistički značajna uz $P<0,05$.

Procjenjena su 2 parametra stabilnosti – koeficijent regresije i varijanca odstupanja od regresije, za hibride i okoline. Isto tako, Pattern analizom napravljeno je grupiranje hibrida i okolina. Pet hibrida (pod brojevima 2, 3, 17, 21 i 22) primjenom obje metode svrstani su u skupinu visoko prinosnih hibrida, sa međusobno vrlo sličnim reakcijama po pitanju prinosa, kroz godine i okoline. Stoga možemo reći da su korištenjem parametara stabilnosti i Pattern analizom, kod grupiranja hibrida, dobiveni praktično vrlo slični rezultati. Prema parametrima stabilnosti jedina stabilna okolina koju možemo izdvojiti je Adana, u 2. sjetvi, u obje godine. Najveći broj okolina ne možemo jednostavno svrstati u neku od skupina, zbog neujednačenih vrijednosti ova dva parametra.

Grupiranje okolina pokazuje nam postojanje 2 megaokoline. To su Hrvatska i Turska – generalno, bez obzira na rok sjetve. Kada bi interpretirali rezultate godinu po godinu, za pojedine podregije (posebno za Hrvatsku zbog dvije klimatski potpuno različite godine u istraživanju), ovo svrstavanje u megaokoline ne bi bilo tako jasno. To nam govori da kod proučavanja i identificiranja megaokolina trebamo podatke iz što većeg broja godina.

Zbog podudarnosti i ponovljivosti dobijenih rezultata sa pojedinih lokacija u Turskoj (iz 1. i 2. sjetve), moguće je na pojedinim lokacijama ne sijati ponovo hibride u 2. sjetvi već u testiranje uvesti i dodatne lokacije, bez povećanja financijskih troškova.

Ovi rezultati sa stanovišta praktičnog oplemenjivanje značajni su nam jer nam otkrivaju kako adaptabilnost hibrida kukuruza za zemljopisno bliže regije, tako i za regije koje su međusobno vrlo udaljene i prostorno diskontinuirane, kao što su Hrvatska i Turska.

8. SUMMARY

Adaptibility Corn Hybrids in Different Mega-environments

Total of 22 maize hybrids were tested in 2010 and 2011 at two locations in Croatia and four locations (with two different planting times) in Turkey. Trials were set in two replications with randomized complete block design.

Sources of variation were determined with analysis of variance. Combined (two-way and three way factorial) ANOVA showed environments and genotypes as statistically significant sources of variation. Genotype and environment interaction (G×E) was statistically very significant, except at one occasion.

Combination of locations and years (L×Y) showed statistically very significant interaction, interactions between genotypes and locations (G×L) and between genotypes and years (G×Y) were not statistically significant, while interaction between genotypes, locations and years (G×L×Y) showed statistical significance at $P<0.05$ probability level.

Two stability parameters (regression coefficient and regression deviation variance) were estimated for hybrids and locations. Also, Pattern analysis was used for grouping hybrids and environments. Using both stability and Pattern analysis five hybrids (denominated as 2, 3, 17, 21, 22) were grouped in high yielding hybrids, with very similar yield performance across years and locations. Therefore, in order to group hybrids very similar results were obtained by using stability parameters and Pattern analysis. Stability parameters point out only one stable location – Adana, second planting, in both years. Largest number of locations cannot be simply put into groups due to uneven values of stability parameters.

Grouping of environments showed two mega-environments (Croatia and Turkey in general, regardless of the planting time). Grouping in mega-environments would not be so transparent (especially for Croatia with two completely different research years in terms of weather conditions), if the results were interpreted year by year for certain sub-regions. That information emphasizes the need for multiple year data in research and identification of mega-environments.

Due to compatible and repeatable data from certain locations in Turkey (from first and second planting), it is possible to avoid second planting of the same hybrids at some locations and instead test more locations without cost increase.

From practical breeding perspective results from this thesis are important for adaptability assessment of maize hybrids, especially for geographically distant regions, such as Croatia and Turkey.

ŽIVOTOPIS

Rođen sam 10. studenog 1959. godine u Osijeku, kao drugo od troje djece, Franje Radan i Marice Radan (rođene Radoš). Sa roditeljima odrastam i živim u Dardi odakle se i školujem. Oženjen sam i otac sam dvoje djece, dva sina. Sa obitelji živim u Osijeku.

Osnovnu školu pohađao sam i završio u Osnovnoj školi u Dardi 1974. godine. Maturirao sam na Poljoprivredno strojarsko tehničkoj školi u Belom Manastiru 1978. godine. Iste godine upisujem se na Poljoprivredni fakultet u Osijeku smjer ratarstvo gdje sam i diplomirao 1982. godine.

Pripravnički staž odradio sam na PIK Belje tadašnji Pogon poljoprivrede Brestovac (6.200 ha) od 09. travnja 1984. godine u trajanju od godinu dana. Nakon toga na istom pogonu radim kao tehnolog ratarstva a od 1989. godine i kao glavni tahnolog ratarstva sve do progonstva 1991. godine.

Odazvao sam se kao dragovoljac domovinskog rata u obrani Hrvatske od studenog 1991. do lipnja 1992. godine.

Po skidanju iz vojske jednu i pol školsku godinu radio sam kao profesor u Srednjoj poljoprivrednoj školi u Valpovu. Nakon toga preko dvije godine radio sam u privatnoj tvrtci Agromed iz Osijeka (zastupstvo Bayer-a za Hrvatsku te proizvodnja, dorada i izvoz ljekovitog bilja). Vodio sam poslove ugovaranja, proizvodnje i dorade ljekovitog bilja a na koncu i predstavljanja tvrtke. Tvrtka je svu proizvodnju izvozila na tržišta Njemačke i Italije tako da sam vrlo intenzivno i često komunicirao sa inozemstvom te putovao u te zemlje i Tursku te vrlo dobro savladao engleski jezik. Od svibnja 1995. do rujna 1997. bavim se plasteničkom proizvodnjom cvijeća i prijesadnica povrća kao obiteljskim poslom. Mirnom reintegracijom i povratkom u Baranju, 1997. godine, ponovo se vraćam u Belje d.d. Pogon poljoprivrede Brestovac gdje radim kao tehnički direktor (sada 5.200 ha). Nakon toga 1999. godine preuzimam mjesto izvršnog direktora ratarstva Belje d.d.-a. Potom od 2001. pa do 2005. godine radim kao direktor najvećeg od pet pogona poljoprivrede Belje d.d.-a, Pogon poljoprivreda Mirkovac. Privatizacijom Belje d.d.-a 2005. godine preuzimam ponovno mjesto prvog čovjeka ratarske proizvodnje kao direktor PC Ratarstvo slijedeće tri godine, te sam na čelu tima koji je uspješno restrukturirao i modernizirao ratarstvo ne samo Belja d.d. nego cijelog koncerna Agrokor. Kao direktor PC Povrtlarstvo u sklopu Belje d.d. radim 2009. godinu. Kada je Agrokor kupio VUPIK d.d. prelazim u VUPIK i na poziciji direktora PC Ratarstvo radim slijedeće dvije godine točnije do 30. rujna 2011. godine. U tom periodu sproveo sam uspješno restrukturiranje,

reorganizaciju i modernizaciju ratarstva VUPIK d.d.-a. Od 01. listopada 2011. prešao sam u tvrtku Fermopromet d.o.o. gdje sam radio do konca 2015. godine na mjestu člana uprave zaduženog za proizvodnju u cijeloj grupi (Srbija i Hrvatska - preko 7.500 ha oraničnih površina od čega 1.000 ha navodnjavanja, tov junadi preko 2.000 grla u turnusu).

Osim toga društveno sam angažiran u humanitarnom djelovanju kroz Lions club "Drava" iz Osijeka od 2007. godine čiji sam jedan od osnivača kao i jedan od bivših predsjednika. Fokus aktivnosti kluba je na pomoći djeci i roditeljima u potrebi.

Član sam Hrvatskog društva agronoma Osijek a od 2004 sam i u Upravnom odboru društva. Vrlo aktivno podupirem aktivnosti društva dugi niz godina.

Aktivan sam i kao športski djelatnik gdje sam 2004. godine kao predsjednik košarkaškog kluba "Darda" iz Darde ponovno pokrenuo djelovanje kluba nakon 13-godišnje pauze. Okupivši oko kluba bivše igrače i osnivače toga kluba, ne samo da je klub oformio škole košarke u Dardi, Bilju i Kn. Vinogradima, nego je i prva ekipa ušla u A-1 hrvatsku ligu 2009. godine, za moga mandata, u kojoj se i danas natječe. Danas sam na poziciji dopredsjednika kluba. Od 2006. do 2010. godine obnašao sam funkciju predsjednika košarkaškog saveza Osječko – baranjske županije.

Osim toga član sam i igrač Preferans kluba "Mortkontra" iz Osijeka koji je višestruki ekipni prvak Hrvatske, te je to i klub iz kojeg dolaze i pojedinačni prvaci Hrvatske posljednjih desetak godina.