

SVEUČILIŠTE U ZAGREBU
AGRONOMSKI FAKULTET

MARKO KREKOVIĆ

Primjena redno-stupčanog dizajna u
implementirajući bilja

DIPLOMSKI RAD

Zagreb, 2016.

SVEUČILIŠTE U ZAGREBU
AGRONOMSKI FAKULTET
HORTIKULTURA - VOĆARSTVO

Marko Kreković

Primjena redno-stupčanog dizajna u
opravljivanju bilja

DIPLOMSKI RAD

Mentor: prof.dr.sc. Jerko Gunjača

Zagreb, 2016.

Ovaj diplomski rad je ocijenjen i obranjen dana _____
s ocjenom _____ pred Povjerenstvom u sastavu:

1. Prof.dr.sc. Jerko Gunjača _____

2. Prof.dr.sc. Hrvoje Šarčević _____

3. Prof.dr.sc. Marija Pecina _____

Ovaj diplomski rad izrađen je na Agronomskom fakultetu Sveučilišta u Zagrebu krajem 2016. godine.

Dugujem zahvalnost prof. dr. sc. Mariji Pecini, prof. dr. sc. Hrvoju Šarčeviću, te posebno mentoru prof. dr. sc. Jerku Gunjači. Zahvaljujem na njihovom strpljenju i razumijevanju kod pisanja diplomskog rada i što su mi pomogli da dovedem do kraja svoje obrazovanje na diplomskom smjeru Agronomskog fakulteta.

Marko Kreković

SAŽETAK

U Botincu je 2007. postavljen pokus s 20 sorata pšenice prema latiniziranom redno-stupčanom dizajnu u četiri repeticije na pokusnom polju Bc Instituta. U ovom diplomskom radu analizirani su podatci o sadržaju vlažnog lijepka primjenom osam različitih statističkih modela.

Cilj primjene različitih modela u statističkoj analizi bio je procjena učinkovitosti pojedinih strukturnih elemenata dizajna, radi odabira najpogodnijeg modela. Na temelju rezultata moguće je zaključiti da najpogodniji model treba sadržavati stupce kao jedini dodani strukturni element u odnosu na osnovni model slučajnog bloknog rasporeda.

Ključne riječi: redno-stupčani dizajn, vlažni ljepak, učinkovitost, strukturni elementi, slučajni blokni raspored

ABSTRACT

In Botinec in 2007. an experiment was set up with 20 varieties of wheat under latinized row-column design in 4 repetitions on the experimental field of the Bc Institute. The data on the wet gluten content were analyzed by using eight different statistical models.

The aim of the use of different models in statistical analysis was to estimate the efficiency of the different design structural elements, in order to select the most suitable model. According to the results, the most suitable model should contain columns as the sole added structural element to the base model of randomized complete block design.

Keywords: row-column design, wet gluten, efficiency, structural elements, randomized complete block design

SADRŽAJ

1. UVOD.....	1
1.1. Cilj istraživanja.....	3
2. PREGLED LITERATURE.....	4
2.1. Struktura alfa dizajna.....	5
2.2. Redno-stupčani dizajn i latinizacija.....	6
2.3. Specifični dizajni i modeli.....	6
3. MATERIJALI I METODE ISTRAŽIVANJA.....	8
3.1. Modeli	9
3.1.1. Slučajni blokni raspored (RCBD).....	9
3.1.2. Dizajn s nepotpunim blokovima	10
3.1.3. Redno-stupčani dizajn.....	10
3.1.4. Latinizirani dizajni	11
3.1.5. Pregled modela primijenjenih u istraživanju	12
3.2. Učinkovitost.....	13
3.3. Programska podrška.....	13
4. REZULTATI ISTRAŽIVANJA I RASPRAVA	14
4.1. Slučajni efekti nepotpunih blokova	14
4.2. Relativna učinkovitost	14
4.3. Test omjera vjerodostojnosti	15
5. ZAKLJUČAK	17
6. POPIS LITERATURE	18
7. ŽIVOTOPIS	20

1. UVOD

Velik se broj znanstvenih istraživanja na području agronomije zasniva na podacima prikupljenim u poljskim pokusima. Kako bi se prikupljeni podaci mogli analizirati na najučinkovitiji način, u smislu osiguravanja što nepristranijih rezultata, od presudne je važnosti izbor dizajna pokusa. Unatoč tome, u većini se istraživanja gotovo rutinski primjenjuje slučajni blokni raspored (RCBD - randomized complete block design), ili rjeđe, neki drugi dizajn iz skupine planova pokusa s potpunim blokovima. Takav postupak ipak ne mora nužno dovesti do povećanja pogreške pokusa, odnosno pristranosti rezultata, jer osnovni nedostatak dizajna s potpunim blokovima dolazi do izražaja tek kod pokusa s velikim brojem tretiranja. Naime, kako potpuni blokovi (repeticije) po definiciji moraju sadržavati sva tretiranja, u takvim je slučajevima zbog velikih dimenzija blokova povećana vjerojatnost narušavanja pretpostavke o njihovoj homogenosti (Gunjača i sur. 2005.).

Prilikom provođenja sortnih poljskih pokusa, bilo radi introdukcije novih genotipova ili u sklopu oplemenjivačkih programa, često dolazi do problema predimenzioniranosti pokusnog polja, osobito u slučaju većeg broja članova pokusa. U tom slučaju može biti narušen osnovni uvjet za korektno provođenje analize varijance, a to je pretpostavka o jednakosti standardne pogreške za provođenje usporedbi između bilo koja dva člana pokusa. To bi, drugim riječima, značilo da u slučaju tako predimenzioniranih repeticija ne možemo biti sigurni da je varijabilnost unutar pojedine repeticije ista. Ukratko, pokusi planirani i analizirani po slučajnom bloknom rasporedu s prevelikim brojem članova zauzimaju razmjerno veliku pokusnu površinu što umanjuje pouzdanost rezultata pokusa (Šindrak, 2001.).

Problem odabira učinkovitog dizajna u pokusima s velikim brojem tretiranja može se riješiti primjenom nekog dizajna iz skupine planova pokusa s nepotpunim blokovima. U ovim dizajnima blokovi ne moraju sadržavati sva tretiranja, što omogućava zadržavanje optimalne veličine blokova, koja osigurava njihovu kompaktnost, a time i homogenost. Tako se uvođenjem nepotpunih blokova osigurava mehanizam za bolju kontrolu varijabilnosti eksperimentalnog polja na kojem je smješten pokus. Ipak, iz toga ne proizlazi da ćemo postizati to bolje rezultate smanjujući blokove što je više moguće. Naime, što blokovi postaju manji, manje će i članova pokusa biti zastupljeno u bloku, a time ćemo dobivati i manje precizne usporedbe između članova u različitim blokovima (Williams i Matheson 1994.). Zato moramo znati izabrati najpogodniju veličinu nepotpunog bloka kako bismo osigurali što veću

preciznost u analizi eksperimentalnih podataka. Uslijed nepotpunosti blokova, u ovakovom se dizajnu međutim pojavljuje problem gubitka informacija, koji se može riješiti odabirom odgovarajućeg modela statističke analize.

Već dugi niz godina mnoge zemlje i međunarodne organizacije koriste se raznim tipovima dizajna s nepotpunim blokovima u oplemenjivačkim programima i postupcima ispitivanja kultivara. Jedan od njih je i redno-stupčani dizajn koji predviđa mogućnost postojanja heterogenosti pokusnog polja u oba smjera prostiranja, zbog čega se sve češće koristi za postavljanje poljskih pokusa.

1.1. Cilj istraživanja

Kako je iz brojnih znanstvenih radova i eksperimenata provedenih na raznim kulturama poznato da dizajni s nepotpunim blokovima omogućavaju precizniju analizu, pa time i donošenje pouzdanijih zaključaka u odnosu na slučajni blokni raspored, to se postavljanjem pokusa po redno-stupčanom dizajnu nastojalo provjeriti opravdanost njegove primjene i u našim uvjetima. Slijedeći ove pretpostavke ciljevi mojeg istraživanja su:

- Predstaviti najznačajnije karakteristike redno-stupčanog dizajna na jednom primjeru njegove primjene u oplemenjivanju bilja (studiji slučaja)
- Usporedbom različitih modela procijeniti učinkovitost pojedinih strukturalnih elemenata dizajna

2. PREGLED LITERATURE

Nepotpune blokove odnosno dizajne s nepotpunim blokovima uveo je u znanost Yates (1936.), kao dizajn sastavljen od blokova odnosno grupa koje su manje od cijelih repeticija, sa svrhom da se eliminira heterogenost eksperimentalne površine u većoj mjeri nego sto je to moguće primjenom slučajnog bloknog rasporeda. Takav raspored prvenstveno je trebao služiti za usporedbu velikog broja članova pokusa. Postojeći modeli pokazali su kako je njihova primjena ograničena brojem članova pokusa i povećanjem veličine osnovne parcele, jer u oba slučaja moramo koristiti veću površinu, čime smanjujemo homogenost, što automatski dovodi do povećanja pogreške pokusa. No, njegov raspored je bio ograničen činjenicom da je njime moguće obraditi samo određen broj članova pokusa jer se raspored sastoji od r repeticija sa s^2 parcela, što zahtjeva da broj članova pokusa g bude kvadrat cijelog broja s . Ukoliko nije tako, potrebno je uvoditi nove ili izbacivati postojeće članove pokusa.

Šira je primjena dizajna ovog tipa bila ograničena postojanjem malog broja raspoloživih planova. Relativno poboljšanje ovakve situacije donose Cochran i Cox (1957.), koji predlažu niz kvadratnih i pravokutnih rešetkastih dizajna, koji su, međutim, također imali već navedene nedostatke. Pravo rješenje ovog problema otkrili su Patterson i Williams (1976.), koji razraduju modele uopćenog rešetkastog dizajna povećavajući njegovu primjenjivost i uvode klasu rješivih dizajna s nepotpunim blokovima među kojima se nalazi i alfa dizajn. Taj dizajn je primjenjiv u praktično svim mogućim slučajevima, za bilo koji broj članova, parcela i blokova, odnosno prikladan za većinu slučajeva koji se pojavljuju u praksi. Patterson i sur. (1978.) predstavljaju seriju rješivih dizajna s nepotpunim blokovima prikladnih za sortne pokuse s bilo kojim brojem članova u rasponu od 20 do 100. Takvi dizajni uspješno zamjenjuju postojeće kvadratne i pravokutne rešetkaste dizajne. U radu detaljno opisuju konstrukciju i randomizaciju alfa-dizajna primjenjivih za sortne pokuse.

Sažimajući sadržaj nabrojenih publikacija, o alfa dizajnu se može reći kako ga karakterizira primjena nepotpunih blokova što otklanja probleme vezane za broj članova pokusa i broj blokova. U odnosu na RCBD prednost alfa dizajna je u tome što dodavanjem nove kategorije - bloka, omogućujemo precizniju kontrolu varijabilnosti eksperimentalnog polja, čime dobivamo veću vjerojatnost da će alfa dizajn biti učinkovitiji kod provođenja istog eksperimenta na istoj površini. U najgorem slučaju bit će jednako učinkovit kao i RCBD. Također, za jednaku preciznost rezultata eksperimenta alfa dizajna i RCBD-a, alfa

dizajn zahtjeva manji broj repeticija pri postavljanju pokusa bez gubljenja preciznosti, čime se štedi novac i pokušna površina (Renka, 2005).

2.1. Struktura alfa dizajna

Kod postavljanja alfa dizajna u praksi potrebno je voditi računa da blokovi unutar svakoga ponavljanja čine fizičke jedinice kojima se kontrolira varijabilnost polja. Elementi alfa dizajna su broj repeticija ili potpunih blokova (r), broj nepotpunih blokova (s), veličina bloka odnosno broj članova pokusa u bloku (k) i broj tretiranja ($t=sk$). Broj pokušnih jedinica u nepotpunim blokovima manji je od broja tretiranja. Nepotpuni blokovi mogu se grupirati tako da svaka grupa nepotpunih blokova tvori potpuni blok ili repeticiju. Repeticijama je moguće kontrolirati široku skalu varijabilnosti, a blokovi unutar njih omogućavaju daljnju (precizniju) kontrolu varijabilnosti eksperimentalne površine repeticije. Njegova ciklička struktura olakšava dizajniranje, gdje se raspored elemenata dizajna generira ciklički po razinama, a nakon toga slijedi randomizacija (Kuehl, 2000).

U alfa-dizajnu postoje tri razine strukture elemenata, a to su repeticija, repeticija/blok i repeticija/blok/parcija, koji onda određuju i smjer randomiziranja. Prvo se randomizira redak repeticija, pa nakon toga poredak blokova unutar repeticija, te slijedi randomizacija poretku parcalica unutar svakog bloka. Na kraju se raspoređuju članovi pokusa nasumično od broja $1-t$, gdje je t ukupna broj tretiranja (Šindrak, 2001). Cilj randomizacije je optimizirati raspored članova pokusa radi postizanja najveće moguće učinkovitosti pri provedbi statističke analize podataka pokusa. Usporedbe između članova pouzdanije su za one parove članova koji se nalaze unutar istog bloka, što nužno ima posljedicu daljnje povećavanje pouzdanosti usporedbe za one parove članova koji se zajedno nalaze unutar većeg broja blokova. Nasuprot tome, analiza podataka za one parove članova koji se nalaze zajedno unutar manjeg broja blokova ili se uopće ne nalaze zajedno niti u jednom bloku gubi na pouzdanosti. Tako dobivamo regulirajući mehanizam unutar kojega možemo povećati pouzdanost analize određenih tretiranja za koje smo zainteresirani svrstavajući ih zajedno unutar većeg broja blokova. Ako svi članovi pokusa imaju isti status, nastojimo rasporediti članove pokusa na način da dobijemo izbalansirani dizajn sa što većim brojem različitih parova. Međutim, iako je maksimalno izbalansirani dizajn s najvećim mogućim brojem različitih parova općenito

najučinkovitiji, nije i apsolutno najučinkovitiji, naročito u slučajevima postojanja određenih tretmana većeg stupnja prioriteta (Renka, 2005).

2.2. Redno-stupčani dizajn i latinizacija

Dizajni s nepotpunim blokovima se koriste kada se postojanje heterogenosti u pokusnom polju predviđa u samo jednom smjeru, dok se kod redno-stupčanih dizajna heterogenost predviđa u dva smjera, gdje dolazi do grupiranja redova i stupaca. Svrha grupiranja redova i stupaca je da se iz pogreške eliminiraju sve usporedbe unutar redova, te isto tako unutar stupaca. Unutar tih okolnosti, pokusni materijal mora biti posložen i pokus proveden tako da sve usporedbe unutar redova i stupaca predstavljaju veliki izvor varijacije koji je poznat ili predviđen (Seema, 2009).

Kod latiniziranih redno-stupčanih dizajna pojavljuju se tzv. „dugi“ blokovi. Ti „dugi“ blokovi, kao dodatni strukturni element, protežu se kroz više repeticija i dobivaju se latinizacijom. To je način randomizacija koji se provodi tako da se u “dugim” blokovima tretiranja ne ponavljaju, te je broj pokusnih jedinica blizak ili jednak broju tretiranja, pa se efekt “dugih” blokova u modelu gleda kao fiksni učinak. Kod redno-stupčanih dizajna bitno je naglasiti da se grupiranje pokusnih jedinica u nepotpune blokove može provoditi u dvije dimenzije. Kao osnovni dizajn može se koristiti alfa dizajn, čija ciklička struktura olakšava dizajniranje. Oni su dostupni za ograničen broj tretiranja, jer je broj tretiranja jednak produktu brojeva redova i stupaca. Tako optimizacijom nastoji se povećati broj usporedbi parova tretiranja unutar redova i unutar stupaca, a ona se može provoditi istovremeno ili u dvije faze (optimiziranje stupaca nakon optimiziranja redova) (Kuehl, 2000).

2.3. Specifični dizajni i modeli

John (1987.), te John i Williams (1995.) publiciraju monografije u kojima iznose teoretske osnove za konstrukciju različitih vrsta dizajna. Uglavnom se radi o dizajnima s nepotpunim blokovima, za jedno ili višefaktorijalne pokuse, čije su metode konstrukcije u

svojoj biti ciklične; npr. alfa-dizajn dobiva se permutiranjem članova (ciklične substitucije članova) unutar blokova u rješivom dizajnu s nepotpunim blokovima dimenzija zadanih brojem članova v , brojem repeticija r i veličinom bloka k , pomoću tzv. algoritma razmjene (interchange algorithm). Pomoću algoritma razmjene moguće je kreirati veliki broj 'dobrih' dizajna određenih parametara, tj. takvih dizajna koji unatoč različitom rasporedu članova imaju najbolji mogući prosječni faktor efikasnosti.

U knjizi namijenjenoj poglavito eksperimentiranju u šumarstvu i voćarstvu Williams i Matheson (1994), između ostalog, daju detaljni prikaz dizajna s nepotpunim blokovima prikladnim za znanstvenike i stručnjake iz tih područja obrađuju problematiku dizajna s nepotpunim blokovima od objašnjenja i primjene, konstrukcije i randomizacije, pa sve do analiza prema mješovitom modelu.

Williams (2000.) u preglednom članku na jednostavan način sumira dosadašnja iskustva u primjeni raznih tipova dizajna s nepotpunim blokovima (redno-stupčani dizajni, alfa-dizajni, latinizirani dizajni), te navodi da iskustveni rezultati pokazuju da korištenje dizajna s nepotpunim blokovima štedi otprilike jednu repeticiju na svakih četiri u usporedbi sa slučajnjm bloknim rasporedom za isti stupanj preciznosti.

3. MATERIJALI I METODE ISTRAŽIVANJA

Predmet mog istraživanja je pokus sa 20 sorata pšenice postavljen prema latiniziranom redno-stupčanom dizajnu u 4 repeticije u na pokusnom polju Bc Instituta u Botincu 2007. godine (Slika 1.).

	11	6	2	7
Rep 1	18	15	1	14
	5	17	3	8
	4	13	10	16
	20	9	19	12
Rep 2	19	18	6	17
	2	8	13	20
	12	16	11	1
	9	4	7	3
	15	10	14	5
Rep 3	8	1	9	11
	14	2	17	4
	6	5	16	19
	10	7	20	15
	3	12	18	13
Rep 4	17	11	12	10
	16	3	15	2
	13	14	5	9
	7	19	8	18
	1	20	4	6

Slika 1. Dizajn pokusa

Svojstvo koje će se analizirati je sadržaj vlažnog ljepka. Ljepak je nabubriva, rastezljiva, plastična, bjelančevinasta masa, koja se dobiva iz tijesta tako da se ispere škrob i omotač zrna. Čine ga alkoholna i bazna frakcija bjelančevina, odnosno gliadin i glutenin. Za ljepak dobre kvalitete taj odnos između glijadina i glutenina treba biti 2,5 : 1,0 do 3,0 : 1,0. Vlažni ljepak se određuje ispiranjem i mjeri se masa prije i poslije ispiranja, a izražava u postotcima

(<14% - vrlo mali sadržaj, 14-20% - mali, 21-24% - zadovoljavajući, 24-27% - dobar, >27% - vrlo dobar) (Mlinar i Ikić, 2009).

3.1. Modeli

U ovom pokusu koristit će se različiti modeli, koji će uključivati pojedine strukturne elemente dizajna, kako bi se s međusobnim usporedbama procijenila njihova učinkovitost. Koristit će se slučajni blokni raspored (RCBD), tri varijante dizajna s nepotpunim blokovima, i te četiri varijante latiniziranog dizajna s „dugim“ stupcima. U nastavku su ukratko opisani svi korišteni modeli, a njihove su oznake navedene u Tablici 1.

3.1.1. Slučajni blokni raspored (RCBD)

Analiza modela RCBD-a jednostavna je zbog ortogonalnosti faktora članova pokusa i repeticije. To znači da se u repeticiji nalaze svi članovi pokusa zastupljeni samo jedanput i na jednakim veličinama osnovne parcele, što članovima u analizi osigurava mogućnost usporedbe svakog sa svakim. Dakle, svi članovi su zastupljeni u svakoj repeticiji, a svaka repeticija sadržava svaki član zastupljen samo jedanput što dizajn čini ortogonalnim (Kuehl, 2000.).

Linerani model slučajnog bloknog rasporeda može se prikazati kao:

$$\text{opažaj} = \text{ukupni prosjek} + \text{učinak tretiranja} + \text{učinak repeticije} + \text{ostatak}$$

ili simbolički:

$$Y_{ij} = \mu + \tau_i + \rho_j + e_{ij}$$

gdje je Y_{ij} ($i = 1, 2, \dots, r$; $j = 1, 2, \dots, t$) opažaj u j -toj repeticiji u r -toj parcelici; μ je prosjek pokusa (overall mean); τ_i je fiksni učinak tretiranja i ρ_j je fiksni učinak repeticija, te e_{ij} je slučajna pogreška u modelu.

3.1.2. Dizajn s nepotpunim blokovima

Dizajn s nepotpunim blokovima od RCBD-a se razlikuje u tome što se svaka repeticija dijeli na s blokova (nepotpuni blokovi), tako da je moguće uspoređivati članove pokusa unutar i između blokova. Nepotpuni blokovi omogućuju precizniju kontrolu varijabilnosti unutar repeticije, kada se u model za analizu uvedu kao učinci blokova unutar repeticija:

$$\begin{aligned} \text{opažaj} = & \text{ukupni prosjek} + \text{učinak tretiranja} + \text{učinak repeticije} + \\ & + \text{učinak nepotpunog bloka} + \text{ostatak} \end{aligned}$$

ili simbolički:

$$Y_{ijk} = \mu + \tau_i + \rho_j + b_{jk} + e_{ijk}$$

gdje je Y_{ijk} ($i = 1, 2, \dots, r$; $j = 1, 2, \dots, t$; $k = 1, 2, \dots, s$) opažaj za r -ti član pokusa u s -tom nepotpunom bloku u j -toj parcelici; μ je prosjek pokusa (overall mean); τ_i je fiksni učinak tretiranja i ρ_j je fiksni učinak repeticija, b_{jk} je slučajni učinak nepotpunih blokova, te e_{ijk} je slučajna pogreška u modelu.

3.1.3. Redno-stupčani dizajn

Redno-stupčani dizajn je dizajn s nepotpunim blokovima, kod kojeg se blokovi unutar repeticija pružaju u dva smjera. Na taj način se ranije opisani model za analizu pokusa

postavljenog prema dizajnu s nepotpunim blokovima proširuje dodatkom učinka još jednog tipa nepotpunih blokova:

opažaj = ukupni prosjek + učinak tretiranja + učinak repeticije +

+ učinak reda unutar repeticije + učinak stupca unutar repeticije + ostatak

ili simbolički:

$$Y_{ijk} = \mu + \tau_g + \rho_i + r_j + c_k + e_{ijk}$$

gdje je Y_{ijk} ($i = 1, 2, \dots, r$; $j = 1, 2, \dots, t$; $k = 1, 2, \dots, s$) opažaj za član pokusa u j -tom redu i s -tom stupcu r -te repeticije; μ je prosjek pokusa (overall mean); τ_g je fiksni učinak tretiranja i ρ_i je fiksni učinak repeticija, r_j i c_k su slučajni učinci redova, odnosno stupaca kao nepotpunih blokova, a e_{ijk} je slučajna pogreška u modelu.

3.1.4. Latinizirani dizajni

Latinizirani dizajn je model dizajna s više strukturnih elemenata u odnosu na dizajn s nepotpunim blokovima, odnosno redno-stupčani dizajn, jer se u latiniziranim dizajnjima pojavljuju tzv. „dugi“ blokovi. Oni nastaju grupiranjem redova ili stupaca iz različitih repertacija. Model za latinizirani redno-stupčani dizajn izgleda ovako:

opažaj = ukupni prosjek + učinak tretiranja + učinak repeticije + učinak „dugog“ bloka +

+ učinak reda unutar repeticije + učinak stupca unutar repeticije + ostatak

ili simbolički

$$Y_{ijk} = \mu + \tau_i + \rho_j + \beta_k + r_{jk} + c_{jk} + e_{ijk}$$

gdje je Y_{ijk} ($i = 1, 2, \dots, r$; $j = 1, 2, \dots, t$; $k = 1, 2, \dots, s$) opažaj za r -ti član pokusa u s -tom „dugom“ bloku u j -toj parcelici; μ je prosjek pokusa (overall mean); τ_i je fiksni učinak tretiranja i ρ_j je fiksni učinak repeticija, β_k je fiksni učinak „dugih“ blokova, r_{jk} i c_{jk} su slučajni učinci redova i stupaca unutar repeticije, te e_{ijk} je slučajna pogreška u modelu.

3.1.5. Pregled modela primijenjenih u istraživanju

U Tablici 1. nalaze se svi modeli koji su korišteni u statističkoj analizi. Prikazane su njihove oznake i nazivi, te objašnjeno je koji su se sve učinci promatrati u pojedinom modelu, točnije koji su strukturni elementi pojedinog modela.

Tablica 1. Oznake modela u analizi i njihova objašnjenja

Oznaka	Objašnjenje
RCBD	Slučajni blokni raspored (tretiranje + repeticija)
RCBDr	Slučajni blokni raspored s redovima (tretiranje + repeticija + (1 red:repeticija))
RCBDc	Slučajni blokni raspored sa stupcima (tretiranje + repeticija + (1 stupac:repeticija))
RCBDrc	Slučajni blokni raspored sa stupcima i redovima (tretiranje + repeticija + (1 stupac:repeticija) + (1 red:repeticija))
lcRCBD	Latinizirani redno-stupčani bez redova i stupaca (tretiranje + repeticija + "dugi stupac")
lcRCBDr	Latinizirani redno-stupčani bez stupaca (tretiranje + repeticija + "dugi stupac" + (1 red:repeticija))
lcRCBDc	Latinizirani redno-stupčani bez redova (tretiranje + repeticija + "dugi stupac" + (1 stupac:repeticija))
lcRCBDrc	Latinizirani redno-stupčani (tretiranje + repeticija + "dugi stupac" + (1 stupac:repeticija) + (1 red:repeticija))

3.2. Učinkovitost

Kao mjerilo učinkovitosti analize može se koristiti veličina pogreške koju radimo pri usporedbama članova pokusa. Relativna učinkovitost je jednostavna metoda za procjenu učinkovitosti jednog dizajna naspram drugog, gdje se izračunava omjer njihovih varijanci pogrešaka. Stoga relativnu učinkovitost možemo jednostavno izračunati pomoću omjera standardnih pogrešaka razlike dvaju korištenih dizajna putem formule:

$$E_R = \left(\frac{s.e.d. \text{ reducirani}}{s.e.d. \text{ puni}} \right)^2$$

gdje je E_R relativna učinkovitost analize dvaju modela, a s.e.d. je standardna pogreška razlike (standard error of difference). Prvo ćemo usporediti dva osnovna modela bez nepotpunih blokova, tj. RCBD sa i bez latiniziranih stupaca, nakon toga će se učinkovitij model usporediti s modelom kod kojeg su dodani stupci, odnosno redovi i na kraju onaj model koji je pokazao veću učinkovitost uspoređuje se s punim modelom (redovi i stupci zajedno). Takav slijed usporedbi dovest će nas do zaključka o najučinkovitijem modelu. Također, opravdanost dodavanja struktura može se ispitati i testom omjera vjerodostojnosti (likelihood ratio test). Modele ćemo uspoređivati na sličan način kao i kod analize relativne učinkovitosti.

3.3. Programska podrška

Sve statističke analize provedene su primjenom funkcija iz osnovnog paketa R okruženja (R Core Team, 2015). Uz osnovni, za analize prema mješovitim modelima korišten je i paket „lme4“ (Bates i sur. 2015), a za procjenu pogreške usporedbi pri usporedbi učinkovitosti paket „multcomp“ (Hothorn i sur. 2008).

4. REZULTATI ISTRAŽIVANJA I RASPRAVA

4.1. Slučajni efekti nepotpunih blokova

U Tablici 2. usporedno su prikazane komponente varijance slučajnih efekata dvaju modela koji uključuju učinke redova i stupaca, RCBDrc i lcRCBDrc. Jedinu razliku između ova dva modela predstavlja dodatni efekt „dugih“ blokova koji se pojavljuje u drugom modelu.

Tablica 2. *Slučajni efekti u modelima sa i bez latiniziranih blokova*

Učinak	Model	
	RCBDrc	lcRCBDrc
redova	0,1635	0,1691
stupaca	3,5449	0,3518
pogreška	1,0851	1,0791

Uspoređujući komponente varijance prikazane u Tablici 2., vidljivo je da je najveća razlika između modela RCBDrc i lcRCBDrc u učinku stupaca, čija je varijanca kod drugog modela deset puta manja u odnosu na prvi. Na temelju toga je moguće zaključiti da se uvođenjem „dugih“ latiniziranih blokova relativna varijanca stupaca, kao nepotpunih blokova, vidno umanjila, jer je veći dio te varijabilnosti već obuhvaćen fiksnim učinkom „dugih“ blokova.

4.2. Relativna učinkovitost

Učinkovitost dodavanja različitih strukturalnih elemenata dizajna prikazana je u Tablici 3., kao relativna učinkovost modela koji sadrži određeni strukturalni element u odnosu na model bez njega.

Tablica 3. Relativne učinkovitosti primijenjenih modela

Osnovni model	Dodani strukturni element			
	-*	r	c	r+c**
RCBD	1,00	3,09	1,06	
IcRCBD	3,30	1,01	1,03	1,05

* usporedba dvaju osnovnih modela

** u odnosu na učinkovitiji od modela iz dva prethodna stupca

U prvom koraku smo napravili usporedbu dva osnovna modela, bez i s latiniziranim „dugim“ blokovima, i analiza je pokazala da se uvođenjem tih blokova učinkovitost povećala za 330% u odnosu na osnovni slučajni blokni raspored, što govori da bi bez tih blokova slučajni blokni raspored istu učinkovitost postigao tek s 13,2 repeticije. U sljedećem koraku usporedili smo oba osnovna modela s modelima kad se uvrste redovi, pa stupci kao nepotpuni blokovi i vidljivo je da je u oba slučaja dobivena veća učinkovitost uvođenjem stupaca. U završnom koraku smo učinkovitiji model iz drugog koraka usporedili s punim modelom, koji u sebi sadrži redove i stupce kao strukturne elemente, i u oba slučaja je puni model pokazao veću učinkovitost. Osim opisanog znatnog povećanja učinkovitosti ostvarenog u prvom koraku, slično je ostvareno jedino još kod dodavanja stupaca kao nepotpunih blokova u slučajni blokni raspored, dok je učinak svih ostalih relativno malen. Dakle, sustavnim dodavanjem strukturalnih elemenata u osnovni model dolazi do smanjenja standardne pogreške razlika i povećanja relativne učinkovitosti u svim usporedbama, osim usporedbe osnovnog RCBD i RCBDr modela, gdje su standardna pogreška razlike i relativna učinkovitost ostale iste.

4.3. Test omjera vjerodostojnosti

Opravdanost dodavanja strukturalnih elemenata ispitana je testom omjera vjerodostojnosti, rezultati kojeg su prikazani u Tablici 4.

Tablica 4. Test omjera vjerodostojnosti (P vrijednosti)

Osnovni model	Dodani strukturni element			
	-*	r	c	r+c**
RCBD		1,000	<0,001	0,166
lcRCBD	<0,001	0,778	1,000	0,709

* usporedba dvaju osnovnih modela

** u odnosu na učinkovitiji od modela iz dva prethodna stupca

Samo su dvije P vrijednosti u Tablici 4. manje od granične vrijednosti ($P=0,01$), i to one za dodavanje latiniziranih „dugih“ stupaca, odnosno stupaca kao nepotpunih blokova u slučajni blokni raspored. P vrijednosti ostalih testova ne ukazuju na postojanje značajne razlike između uspoređivanih modela.

Rezultati testa omjera vjerodostojnosti konačno sužavaju izbor najpogodnijeg modela na samo dva preostala kandidata – modele RCBDc i lcRCBD. Pri konačnom odabiru jednog od ova dva modela, u maloj prednosti je možda model s „dugim“ stupcima, jer se njegovom primjenom ostvaruje nešto malo veće relativno povećanje učinkovitosti u odnosu na slučajni blokni raspored (Tablica 3.).

5. ZAKLJUČAK

Rezultati statističkih analiza provedenih primjenom osam različitih modela na podatcima iz istog pokusa otkrivaju da uvođenje dodatnih struktturnih elemenata u načelu povećava relativnu učinkovitost, a smanjuje eksperimentalnu pogrešku i standardnu pogrešku razlike. Od dva tipa nepotpunih blokova znatno je izraženiji učinak stupaca, čak i kada su u model uvršteni „dugi“ stupci. Najveće povećanje učinkovitosti dogodilo se kod uvođenja latiniziranih „dugih“ blokova u osnovni RCBD model i kod uvođenja stupaca kao nepotpunih blokova u osnovni RCBD, te se učinkovitost povećala za 330%, odnosno 309%. To su ujedno i jedini slučajevi u kojima je povećanje učinkovitosti opravdano, prema rezultatima testa omjera vjerodostojnosti. Na temelju toga je moguće izvesti zaključak da bi najpogodniji model u odnosu na najjednostavniji model slučajnog bloknog rasporeda trebao sadržavati samo još i stupce kao jedini dodani struktturni element.

6. POPIS LITERATURE

1. Cochran W. G., Cox G. M. (1957). Experimental designs, John Wiley & Sons, New York, 1957
2. Bates D., Maechler M., Bolker B., Walker S. (2015). Fitting Linear Mixed-Effects Models Using lme4. Journal of Statistical Software 67: 1-48
3. Gunjača J., Renka H., Jambrešić I., Šindrak Z., Safner T., Liović I., Pecina M. (2005). Efficiency of Alpha designs in Croatian variety trials. Proceedings of the 27th International Conference on Information Technology Interfaces. Lužar-Stiffler V, Hljuz Dobrić V (ur.). Cavtat, Hrvatska. str. 207-21
4. Hothorn T., Bretz F., Westfall P. (2008). Simultaneous Inference in General Parametric Models. Biometrical Journal 50: 346-363
5. John J.A. (1987). Cyclic designs, Chapman&Hall, London, 1987.
6. John J.A., Williams ER (1995). Cyclic and Computer Generated Designs, Chapman&Hall, London, 1995.
7. Kuehl R.O. (2000). Design of Experiments: Statistical Principles of Research Design and Analysis, 2nd Edition, University of Arizona, Emeritus, 2000.
8. Mlinar R., Ikić I. (2009). Bc Renata – Nova sorta ozime pšenice, Sjemenarstvo 26: 3-4
9. Patterson H. D., Williams E.R. (1976). A new class of resolvable incomplete block designs, Biometrika 63: 83-92
10. Patterson H.D., Williams E.R., Hunter E.A. (1978). Block designs for variety trials, J. Agri. Sci. Cambridge 90: 395-400.
11. R Core Team (2015). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.
12. Renka H. (2005). Povećanje učinkovitosti pokusa primjenom alfa dizajna, Studentski rad, Agronomski fakultet u Zagrebu
13. Seema J. (2009). Row-Column Designs, I.A.S.R.I., Libray Avenue, New Delhi, 12; 178-182.

14. Šindrak Z. (2001). Struktura blokova i učinkovitost plana i analize poljskih pokusa, Magistarski rad, Agronomski fakultet u Zagrebu
15. Williams E.R. (2000). Selecting appropriate designs for field trials – Statistical efficiency and practical considerations, Aspects of applied biology, 61: 1-6.
16. Williams E.R., Matheson A.C. (1994). Experimental design and analysis for use in tree improvement, CSIRO, Melburne, Australia, 1994.
17. Yates F. (1936). A new method of arranging variety trials involving a large number od varieties, J. Agr. Sci. Cambridge 26: 424-255.

7. ŽIVOTOPIS

Marko Kreković rođen je 18.06.1985. godine u Zagrebu. 2004. godine završava V. Gimnaziju, matematički smjer, i upisuje Stomatološki fakultet Sveučilišta u Zagrebu. Nakon tri godine upisuje Agronomski fakultet u Zagrebu, preddiplomski studij (smjer hortikultura). U rujnu 2011. godine završava preddiplomski studij obranom završnog rada pod naslovom „Pomološke značajke plodova šljiva cijepljenih na podlozi Wa x Wa“ pod mentorstvom Jelene Gadže, dipl. ing. Na istom fakultetu 2011. upisuje diplomski studij (smjer hortikultura – voćarstvo).

Sudjelovao je na 8. Zanstveno-stručnom savjetovanju hrvatskih voćara s međunarodnim sudjelovanjem pod nazivom „Mjere za razvoj hrvatskog voćarstva“. Izložio je svoj rad pod naslovom „Tretmani voća poslije berbe zračenjem“ koji je napravljen u suradnji s prof. dr. sc. Tomislavom Jemrićem.

U 2008. godini kreće u projekt podizanja nasada šljive u Ličko-senjskoj županiji zajedno sa svojim ocem, Ivanom Krekovićem, pod vodstvom prof. dr. sc. Ive Miljkovića. U projektu sudjeluje do 2013. godine. U međuvremenu se bavi i proizvodnjom autohtone ličke šljivovice i ekološkog ličkog češnjaka.

Diplomski studij na Agronomskom fakultetu Sveučilišta u Zagrebu završava krajem 2016. godine obranom diplomskog rada pod naslovom „Primjena redno-stupčanog dizajna u oplemenjivanju bilja“, pod mentorstvom prof. dr. sc. Jerka Gunjače.