

Nonparametric Analysis of Yield Stability of some Winter Wheat Varieties

Zrinka KNEZOVIĆ

Jerko GUNJAČA

SUMMARY

The important role in the creation of the new varieties has their stability in different environments. Due to genotype x environment interaction, their performance could be altered so much that their ranking order in different environments would be different, which makes the selection of the best varieties difficult. Therefore, it is important to identify the stable genotypes.

Nonparametric measures of stability are used less often than parametric measures. However, they have certain advantages. Their use does not depend on any assumption, because they are based on ranks. In this case study, the use of nonparametric methods in analysis of genotype x environment interaction and stability estimation is investigated in winter wheat variety trials yield data set. The presence of interaction is tested using four nonparametric methods, and interaction is detected in each and every year of investigation. Thereafter, the stability of genotypes is estimated using three nonparametric measures, and their values are compared with values of parametric measures estimated in an earlier study on the same data set. Comparison showed satisfactory resemblance between nonparametric and parametric measures of stability.

KEY WORDS

nonparametric measures, yield, stability, wheat

¹ University of Mostar, Faculty of Agriculture
Kralja Zvonimira 14, 88000 Mostar, B&H
E-mail: agronomski.fakultet@tel.net.ba

² University of Zagreb, Faculty of Agriculture
Svetošimunska 25, 10000 Zagreb, Croatia
E-mail: jgunjaca@agr.hr

Received: July 5, 2002

Neparametrijska mjerila stabilnosti prinosa nekih sorata ozime pšenice

Zrinka KNEZOVIĆ¹

Jerko GUNJAČA²

SAŽETAK

U procesu stvaranja novih sorata, vrlo je važna postojanost njihovih svojstava u različitim okolinama. Interakcijom genotipova s okolinama vrijednosti njihovih svojstava se mogu izmijeniti do te mjere da se i poredak genotipova u različitim okolinama mijenja, što znatno može otežati i izbor najboljih genotipova. Zbog toga je za izbor genotipova izuzetno važna stabilnost njihovih svojstava u različitim okolinama. Premda se koriste rjeđe od parametrijskih, neparametrijska mjerila stabilnosti imaju neke prednosti. Njihova primjena ne ovisi o ispunjavanju pretpostavki, jer se zasnivaju na rangovima.

U ovom je radu istražena mogućnost primjene neparametrijskih metoda u analizi interakcije genotip x okolina i procjeni stabilnosti na podacima o prinosu dobivenim iz sortnih pokusa s ozimom pšenicom. Testiranje interakcije provedeno je prema četiri neparametrijske metode, te je pomoću njih otkrivena interakcija u svim godinama istraživanja. Nakon toga je procijenjena stabilnost pomoću tri neparametrijska mjerila, te je usporedbom njihovih vrijednosti i vrijednosti parametrijskih mjerila (procijenjenih u ranijem istraživanju na istom materijalu) ustanovljena zadovoljavajuća podudarnost.

KLJUČNE RIJEČI

neparametrijska mjerila, prinos, stabilnost, pšenica

¹ Agronomski fakultet Sveučilišta u Mostaru
Kralja Zvonimira 14, 88000 Mostar, BIH
E-mail: agronomski.fakultet@tel.net.ba

² Agronomski fakultet Sveučilišta u Zagrebu
Svetošimunska 25, 10000 Zagreb, Hrvatska
E-mail: jgunjaca@agr.hr

Primljeno: 5. srpnja 2002.

UVOD

Procjena vrijednosti novostvorenih sorata temelji se na procjeni gospodarski važnih svojstava, a jedno od njih je i stabilnost, odnosno sposobnost genotipa da i u različitim okolinskim uvjetima zadrži slične vrijednosti prinosa i drugih važnih osobina. Što je interakcija nekog genotipa s okolinom manja, to je njegova stabilnost veća.

Većina korištenih metoda analize interakcije genotip \times okolina može se svrstati u skupinu parametrijskih metoda. Neparometrijske metode znatno su manje zastupljene, premda imaju niz prednosti nad parametrijskim metodama. Iako se rijetko koriste, neparometrijske su metode u analizi interakcije genotip \times okolina prvi put primijenjene još davne 1946. godine (Haldane, 1946).

Pojava interakcije može, ali ne mora prouzročiti izmjenu poretka genotipova u različitim okolinama. Zbog toga razlikujemo dva tipa interakcije – kvantitativni i kvalitativni. Za oplemenjivački je rad znatno važniji kvalitativni tip, kod kojeg dolazi do promjene poretka genotipova, jer je uslijed toga otežan izbor najboljih genotipova (Baker, 1990). Zato bi nakon što se utvrdi postojanje interakcije bilo važno razlučiti radi li se o kvantitativnom ili kvalitativnom tipu interakcije. Kako se neparometrijske metode zasnivaju na rangovima, one upravo i omogućavaju detektiranje tipa interakcije.

Hühn (1996) u pregledu neparometrijskih metoda testiranja interakcije genotip \times okolina navodi četiri metode, nazvane prema njihovim autorima – Bredenkampu, Hildebrandu, Kubingeru, te van der Laan i de Kroonu. Prve tri metode temeljene su na rangiranju podataka o prinosu sa svih lokacija unutar jedne godine istraživanja, dok se kod posljednje rangiranje provodi za svaku lokaciju zasebno. Bredenkampova metoda je najmanje pouzdana i najčešće ne pokazuje postojanje interakcije, a rangiranje se temelji na podacima o prinosu. Kod Hildebrandove i Kubingerove metode rangiranje genotipova se zasniva samo na interakcijskim efektima, te su znatno pouzdanije, ali ne mogu razlučiti o kojem se tipu interakcije radi. Primjenom van der Laanove – de Kroonove metode (de Kroon i van der Laan, 1981) rangiranje se provodi na temelju sume genotipskih i interakcijskih efekata, a detektira se isključivo kvalitativni tip interakcije. Kod svih se metoda za testiranje interakcije primjenjuje χ^2 test, a za odnos vrijednosti χ^2 vrijedi pravilo (Hühn, 1996):

Hildebrand \approx Kubinger $>$ van der Laan i de Kroon $>$ Bredenkamp.

Neparometrijska mjerila stabilnosti zasnivaju se na rangiranju genotipova prema ostvarenim prinosima u nekoj okolini. Rangovi odražavaju poredak genotipova prema ostvarenim prinosima, ali ne i

njihove apsolutne razlike. Uz taj mogući nedostatak, ovako transformirani podaci imaju i niz prednosti, jer nije potrebno ispunjavanje bilo kakvih pretpostavki, kao kod parametrijskih metoda (Nassar i Hühn, 1987). Dodavanje ili izostavljanje jednog ili više genotipova neće uzrokovati velike izmjene u procjenama.

Dva najčešće korištena mjerila stabilnosti su (prema Hühnu, 1990): prosječna razlika rangova u različitim okolinama ($S_i^{(1)}$) i varijanca rangova ($S_i^{(2)}$). Ova su mjerila primijenjivana u mnogim istraživanjima (Hühn, 1979; Thomson i Cunnigham, 1979; Kleinschmit, 1983; Skrøppa, 1984). Mogućnosti testiranja ovih mjerila istraživali su Nassar i Hühn (1987), te Hühn i Nassar (1989, 1991).

Kako dva navedena mjerila stabilnosti uzimaju u obzir apsolutnu vrijednost prinosa genotipova Hühn (1979) predlaže treće mjerilo – $S_i^{(3)}$, koje predstavlja relativno odstupanje u odnosu na prosječni rang. Različite varijante ovog mjerila su u svojim istraživanjima koristili Kang (1990), te Kang i Pham (1991), dok su mogućnosti njegovog testiranja istraživali Nassar i sur. (1994).

Prednost neparometrijskih metoda u odnosu na parametrijske je njihova neovisnost o prethodnim pretpostavkama, kao i relativno jednostavno detektiranje tipa interakcije. Potrebno je, međutim, ispitati njihovu primjenjivost u analizi specifičnih setova podataka dobivenih iz sortnih pokusa. Nastavljajući ranije istraživanje mogućnosti analize interakcije genotip \times okolina i procjene stabilnosti u setovima podataka dobivenim u sortnim pokusima u kojem su korištene parametrijske metode (Gunjača, 1997), u ovom smo radu odlučili istražiti mogućnosti primjene neparometrijskih metoda.

MATERIJAL I METODE

U ovom istraživanju korišteni su podaci o prinosu iz pokusa Povjerenstva za ispitivanje novostvorenih sorata ratarskog bilja, povrća i cvijeća iz razdoblja 1992-1998. godine za sorte ozime pšenice. Pokusi su izvedeni prema slučajnom bloknom rasporedu u četiri ili pet repeticija (ovisno o godini). Pregled lokacija istraživanja i broja ispitivanih genotipova po godinama istraživanja prikazan je u Tablici 1. Obzirom na to da ispitivanje genotipova u pravilu traje tri godine, ukupan broj genotipova uključenih u ovo istraživanje iznosio je 238.

Postojanje interakcije genotip \times okolina testirali smo prema četiri neparometrijske metode: Bredenkampovoj, Hildebrandovoj, Kubingerovoj i van der Laan – de Kroonovoj (Hühn, 1996). Ukoliko se prema metodi van der Laana – de Kroona utvrdi postojanje interakcije, procijenit će se stabilnost genotipova. Skupine genotipova izdvojenih zbog izrazite stabilnosti ili nestabilnosti usporedili smo s listom priznatih sorata.

Tablica 1. Pregled lokacija i broja genotipova po godinama istraživanja

Table 1. Year-by-year overview of sites and number of genotypes

Godina-Year	Sorte-Varieties	Lokacije-Sites	Ponavljanja-Replicates
1992	43	Botinec, Koprivnica, Šašinovečki Lug i Velika Gorica	5
1993	60	Botinec, Koprivnica, Osijek, Šašinovečki Lug i Velika Gorica	5
1994	88	Botinec, Kutjevo, Osijek i Poreč	5
1995	92	Botinec, Đakovo, Kutjevo, Osijek i Poreč	5
1996	88	Botinec, Đakovo, Kutjevo, Osijek i Poreč	5
1997	68	Botinec, Đakovo, Kutjevo i Osijek	4
1998	77	Botinec, Đakovo, Kutjevo i Osijek	4

Stabilnost genotipova procijenili smo pomoću tri neparametrijska mjerila stabilnosti (Hühn, 1990):

1. prosječna razlika rangova u različitim okolinama – $S_i^{(1)}$
2. varijanca rangova – $S_i^{(2)}$
3. relativno odstupanje u odnosu na prosječni rang – $S_i^{(3)}$

Pri procjeni prosječne razlike rangova u različitim okolinama (1) rangiranje se provodi za svaku okolinu zasebno, a zatim se prosječna razlika procjenjuje prema izrazu:

$$S_i^{(1)} = \frac{\sum_{j < j'} |r_{ij} - r_{ij'}|}{\binom{m}{2}} = \frac{2}{m(m-1)} \sum_{j=1}^{m-1} \sum_{j'=j+1}^m |r_{ij} - r_{ij'}|$$

gdje su r_{ij} i $r_{ij'}$ rangovi i-tog genotipa u j-toj i j'-toj okolini, a m broj okolina.

Varijanca rangova (2) temelji se na odstupanjima od prosječnog ranga:

$$S_i^{(2)} = \frac{1}{m-1} \sum_{j=1}^m (r_{ij} - \bar{r}_i)^2$$

gdje je prosječni rang i-tog genotipa:

$$\bar{r}_i = \frac{1}{m} \sum_{j=1}^m r_{ij}$$

Stabilni genotipovi imaju niske vrijednosti ovih mjerila, a maksimalna se stabilnost postiže kada je neki genotip jednako rangiran u svim okolinama, pa je $S_i^{(1)} = S_i^{(2)} = 0$. Značajnost oba mjerila stabilnosti moguće je testirati kako je zadano izrazom, prema Hühnu i Nassaru (1989, 1991):

$$Z_i^{(n)} = \frac{[S_i^{(n)} - E\{S_i^{(n)}\}]^2}{\text{var}\{S_i^{(n)}\}}$$

gdje je $n = 1, 2$, a $Z_i^{(n)}$ ima približnu χ^2 distribuciju sa 1 stupnjem slobode. Da bi mogli provesti test potrebno je odrediti srednju vrijednost $E\{S_i^{(m)}\}$ i varijancu

$\text{var}\{S_i^{(m)}\}$. Prema Nassaru i Hühnu (1987) i Hühnu i Nassaru (1989):

$$E\{S_i^{(1)}\} = \frac{l^2 - 1}{3l}$$

$$\text{var}\{S_i^{(1)}\} = \frac{(l^2 - 1)[(l^2 - 4)(m + 3) + 30]}{45l^2m(m - 1)}$$

$$E\{S_i^{(2)}\} = \frac{l^2 - 1}{12}$$

$$\text{var}\{S_i^{(2)}\} = \frac{(l^2 - 1)}{36m} \left[\frac{l^2 - 4}{5} + \frac{l^2 - 1}{2(m - 1)} \right]$$

gdje je l broj genotipova.

Za stabilan genotip $S_i^{(m)} < E\{S_i^{(m)}\}$, a nestabilan $S_i^{(m)} > E\{S_i^{(m)}\}$.

Treće mjerilo stabilnosti je relativno odstupanje u odnosu na prosječan rang (3). Mjerilo $S_i^{(3)}$ je predložio Hühn (1979), a ono se može izračunati prema izrazu:

$$S_i^{(3)} = \sum_{j=1}^m \frac{|r_{ij} - \bar{r}_i|}{\bar{r}_i}$$

Ovo mjerilo izražava stabilnost u jedinicama prinosa. Ono predstavlja sumu apsolutnih odstupanja rangova r_{ij} od prosječnog ranga \bar{r}_i , gdje su odstupanja izražena u jedinicama \bar{r}_i .

Brojnik mjeri stabilnost (varijabilnost rangova), dok nazivnik odražava razinu prinosa (prosječna vrijednost rangova r_{ij}). U ovoj skupini mjerila postoje i druge varijante, ali je mjerilo $S_i^{(3)}$ najjednostavnije i najčešće korišteno.

REZULTATI I RASPRAVA

Rezultati testiranja interakcije genotip x okolina nakon primjene metoda Bredenkampa, Hildebranda, Kubingera i van der Laana – de Kroona za ozimu pšenicu u razdoblju od 1992 do 1998 godine prikazani su u Tablici 2. Utvrđeno je postojanje

Tablica 2. Neparometrijski testovi interakcije genotip x okolina – χ^2 vrijednosti za četiri primijenjene metode po godinama istraživanja

Tablica 2. Nonparametric tests of genotype x environment interaction – χ^2 values of four applied methods over years of investigation

Godina-Year	Bredenkamp	Hildebrand	Kubinger	van der Laan-de Kroon
1992	209,94 **	355,08 **	344,06 **	207,55 **
1993	213,32 n.s.	725,99 **	740,88 **	444,41 **
1994	175,15 n.s.	940,92 **	999,2 **	750,24 **
1995	331,26 n.s.	1.113,70 **	1.178,14 **	971,94 **
1996	300,44 n.s.	903,83 **	950,44 **	649,28 **
1997	114,40 n.s.	309,21 **	317,97 **	215,39 n.s.
1998	171,34 n.s.	598,47 **	626,17 **	296,64 **

Tablica 3. Genotipovi za značajnom razlikom rangova u različitim okolinama

Table 3. Genotypes with significant rank difference in different sites

	1993	1995	1996	1998
Genotipovi	TDW2415	ZG 320092	AG4394	Palio
Genotypes	ZG408791		AG51291	Soprano
	ZG587791		Amello	
			OSK66382	
			OSK8096	
			ZG65692	

interakcije genotip x okolina prema svim metodama s izuzetkom Bredenkampove. Time su potvrđene spoznaje o relativnoj nesigurnosti ove metode (Hühn i Leon, 1995). Također, odnos χ^2 vrijednosti dobivenih ovim metodama slijedi ranije navedeno pravilo (Hühn, 1996), s izuzetkom 1992 godine. Jedino je te godine vrijednost za Bredenkampovu metodu veća od vrijednosti za metodu van der Laana – der Kroona, a također je, jedino te godine Bredenkampovom metodom utvrđeno postojanje interakcije. Kvalitativni tip interakcije detektiran je (metodom van der Laana – de Kroona) u svim godinama osim 1997.

U istraživanje je bio uključen vrlo veliki broj genotipova pšenice, a dobivene vrijednosti mjerila stabilnosti pojedinih genotipova bile su raznolike. Stoga nije moguće prikazati vrijednosti mjerila stabilnosti svih genotipova, no koliko se njihova stabilnost razlikovala, moguće je vidjeti iz raspona vrijednosti mjerila. Naime, vrijednosti prosječne razlike rangova ($S_i^{(1)}$) kreću se od 1,17 do 52,83, vrijednosti varijance rangova ($S_i^{(2)}$) od 0,92 do 1888,92, a vrijednosti relativnih odstupanja u odnosu na prosječan rang ($S_i^{(3)}$) od 0,04 do 6,78.

Testiranjem je ustanovljena značajnost mjerila za manji broj genotipova. Genotipovi za koje je ustanovljena značajnost prosječnih razlika rangova u različitim okolinama su prikazani u Tablici 3. Značajna varijanca rangova ustanovljena je u 1994.

godini za genotip OSK41632, a u 1995. za genotip AG41632. Usporedbom rezultata ovih istraživanja s rezultatima dobivenim parametrijskim metodama (Gunjača, 1997) ustanovljena je zadovoljavajuća podudarnost. Navodimo nekoliko karakterističnih primjera.

Sorta pod šifrom C1616 (priznata kao Zlatni Dukat) u ovom istraživanju bila je nestabilna samo u jednoj godini, a parametrijskom analizom je razlog te nestabilnosti bilo moguće još točnije pripisati podbačaju u samo jednoj lokaciji u toj godini. Prema rezultatima temeljenim na parametrijskim i neparometrijskim vrijednostima izrazito stabilnim genotipovima mogu se smatrati: VM-12-36 i ZG 211490.

ZAKLJUČAK

Primjenom neparometrijskih metoda za otkrivanje interakcije genotip x okolina, utvrdili smo postojanje interakcije.

Vrijednosti koje ukazuju na postojanje interakcije genotip x okolina dobivene ovim metodama, njihova signifikantnost i odnosi među metodama, podudaraju se s rezultatima drugih autora.

Vrijednosti prosječne razlike rangova ($S_i^{(1)}$) i varijance rangova ($S_i^{(2)}$) za isti genotip razlikovale su se od godine do godine (najveći broj genotipova ima naime

niske vrijednosti za jednu, a visoke za druge dvije godine ili obrnuto), a istovremeno se i set ispitivanih genotipova razlikovao od godine do godine. Stoga se čini da se na ova dva mjerila stabilnosti možemo osloniti s manjom sigurnošću nego na vrijednosti relativnog odstupanja u odnosu na prosječni rang ($S_i^{(3)}$).

Premda su za većinu genotipova te vrijednosti oscilirale, ipak se mogu izdvojiti skupine genotipova izrazito stabilnog, odnosno nestabilnog prinosa.

Usporedbom mjerila stabilnosti dobivenih parametrijskim i neparametrijskim metodama ustanovili smo zadovoljavajuću podudarnost, uz neke izuzetke.

Broj genotipova se mijenjao iz godine u godinu, a isto tako i na lokacijama nije bio uvijek istovjetan materijal. Zbog toga, kao i zbog premalog broja okolina, nije bilo moguće klasificirati okoline.

LITERATURA

- Baker R. J. (1990). Crossover genotype-environmental interaction in spring wheat. In: *Genotype-by-environmental interactions and plant breeding*. (M. S. Kang, ed), Louisiana State University, Agricultural Center, Baton Rouge, 42-51
- Gunjača J. (1997). Procjena stabilnosti prinosa iz nebalansiranih setova podataka. Agronomski fakultet Sveučilišta u Zagrebu (magistarski rad)
- Haldane J. B. S. (1946). The interaction of nature and nature. *Ann. Eugenics* 13: 197-205
- Hühn M. (1979). Beiträge zur Erfassung der phänotypischen Stabilität. I. Vorschlag einiger auf Ranginformationen beruhenden Stabilitätsparameter. *EDV in Medizin und Biologie* 10: 112-117
- Hühn M. (1990). Nonparametric measures of phenotypic stability. Part 1: Theory. *Euphytica* 47: 189-194
- Hühn M. (1990). Nonparametric measures of phenotypic stability. Part 2: Applications. *Euphytica* 47: 195-201
- Hühn M. (1996). Nonparametric analysis of genotype x environment interactions by ranks. In: *Genotype by environment interaction* (M. S. Kang, H. G. Gauch, Jr., eds), CRC Press, Boca Raton, 235-271
- Hühn M., Léon J. (1995). Nonparametric analysis of cultivar performance trials: Experimental results and comparison of different procedures based on ranks. *Agron. J.* 87: 627-632
- Hühn M., Nassar R. (1989). On tests of significance for nonparametric measures of phenotypic stability. *Biometrics* 45: 997-1000
- Hühn M., Nassar R. (1991). Phenotypic stability of genotypes over environments: On tests of significance for two nonparametric measures. *Biometrics* 47: 1196-1197
- Kang M. S. (1990). Understanding and utilization of genotype-by-environment interaction in plant breeding. In: *Genotype-by-environment interaction and plant breeding* (M. S. Kang, ed) Louisiana State University, Agricultural Center, Baton Rouge, 52-668
- Kang M. S., Pham H. N. (1991). Simultaneous selection for high yielding and stable crop genotypes. *Agron. Journal* 83: 161-165
- Kleinschmit J. (1983). Concepts and experiences in clonal plantations of conifers. *Proc. 19th Meeting Can tree Impr Assoc Part 2: Symp on Clonal Forestry: Its impact on tree improvement and our future forests* (Zsuffa, Rauter, and Yeatman eds.). Toronto (Ontario): 26-56
- Kroon J. P. M. de, van der Laan P. (1981). Distribution-free test procedures in two-way layouts; a concept of rank-interaction. *Statistica Neerlandica* 35: 189-213
- Nassar R., Hühn M. (1987). Studies on estimation of phenotypic stability: Test of significance for nonparametric measures of phenotypic stability. *Bimetrics* 43: 45-53.
- Nassar R., Léon J., Hühn M. (1994). Tests of significance for combined measures of plant stability and performance. *Biometrical Journal* 36: 109-123.
- Skrøppa T. (1984). A critical evaluation of methods available to estimate the genotype x environment interaction. *Studia Forestalia Suecica* 166: 3-14
- Thompson N. J., Cunningham R. B. (1979). Genotype x environment interactions and evaluation of cotton cultivars. *Australian Journal of Agricultural Research* 30: 105 – 112

acs67_16