

PRIMER REŠEVANJA STATISTIČNIH PROBLEMOV Z BOOTSTRAP PRISTOPOM

Katarina Košmelj, Michael Schemper*

Univerza v Ljubljani, Slovenija

*Univerza na Dunaju, Avstrija

Predstavljene so osnove bootstrap tehnike, ki je zelo uporabna pri reševanju statističnih problemov, kjer parametrični pristopi niso možni.

Prikazan je problem izračunavanja intervala zaupanja za optimum kvadratne odzivne krivulje. Interval zaupanja je izračunan na parametrični in na neparametrični način. Parametrični način je v tem primeru le aproksimativen in temelji na razvoju v Taylorjevo vrsto, neparametrični način pa uporablja bootstrap tehniko.

Podana je ilustracija tega problema na podatkih iz agronomije. Rezultati kažejo, da se rezultati obeh pristopov precej razlikujejo in zdi se, da so rezultati dobjeni z bootstrap tehniko za uporabljene podatke bolj ustrezní.

KLJUČNE BESEDE: bootstrap tehnika, interval zaupanja za optimum odzivne krivulje.

AN APPLICATION OF THE BOOTSTRAP TECHNIQUE: The ideas of the bootstrap technique are briefly presented. An application is given when the confidence interval for the extreme of a quadratic response curve is calculated using the bootstrap technique. An alternative approach based on the asymptotic parametric approach (Taylor series) is presented as well. Both approaches are illustrated on a data set from agriculture. It seems that the bootstrap technique gives more reliable results for our dataset.

KEYWORDS: bootstrap technique, confidence interval for the extreme of the response curve.

1. Uvod

Statistična inferenca je sklepanje o populaciji na osnovi vzorca. Da bi bil ta postopek korekten, moramo imeti reprezentativni vzorec, na osnovi katerega izračunamo oceno parametra, ki nas v populaciji zanimala.

Kvaliteto vzorčne ocene izraža njena standardna napaka. Ta meri načanost (angl. precision) vzorčne ocene in pove, kakšno napako naredimo, ko nameslo celotne populacije obravnavamo le njen del (vzorec). (Pojem načanosti se loči od pojma točnosti (angl. accuracy), ki upošteva poleg načanosti tudi pristranskost).

Natančnost vzorčne ocene, torej njena standardna napaka, je pri statističnih analizah ključnega pomena.

Obstajata dva načina izračevanja standardne napake ocene:

- parametrični pristop, ki je možen, če poznamo ali predpostavljamo porazdelitev celičke in znamo izračunati varianco ocene na osnovi te porazdelitve (klasični pristop statistične inference);
- neparametrični pristop, kadar porazdelitve ne poznamo in tako tudi variance ocene analitično ne moremo izračunati. Obstaja pa lahko asimptotično pravilna ocena.

2. Neparametrični pristop

Iz literature sta poznana dva neparametrična pristopa: bootstrap in jackknife pristop.

Opišimo na kraiko bootstrap pristop. Predpostavimo, da smo s klasičnim vzorčenjem dobili reprezentativni vzorec, ki ima N enot. Imenujmo ga osnovni vzorec. Iz tega vzorca tvorimo t. im. bootstrap vzorce takole: vsak bootstrap vzorec ima N enot, dobimo pa ga s slučajnim izborom z vracanjem iz osnovnega vzorca. Tvorimo K bootstrap vzorcev. Iz vsakega bootstrap vzorca izračunamo vzorčno oceno. Na osnovi vseh K bootstrap vzorcev izdelamo porazdelitev vzorčne ocene. Če je porazdelitev vzorčne ocene približno normalna, izračunamo bootstrap oceno za povprečje in za varianco vzorčne ocene (glej formule spodaj). Navadno porazdelitev ni normalna, zato predhodno uporabimo primerno transformacijo.

Jackknife tehnik je v razliko od bootstrap tehnik determistična. Posamezni jackknife vzorec dobimo tako, da spustimo po eno točko v osnovnem vzorcu. V vsakem jackknife vzorcu je $N-1$ točk, število jackknife vzorcev je torej enako N . To tehniko lahko interpretiramo kot aproksimacijo bootstrap tehnik.

Obe tehniki sta metodi ponovnega vzorčenja (angl. resampling) in predpostavljata, da je porazdelitvena funkcija F za oceno parametra, dovolj dobro ocenjena z empirično porazdelitveno funkcijo, ki jo dobimo na osnovi bootstrap vzorcev.

Naj bodo x_1, x_2, \dots, x_N podatki. Pogejmo, kako izračunamo bootstrap oceno za povprečje in za varianco vzorčne ocene. Naj bo T celička našega parametra. Iz tega bootstrap vzorca izračunamo $T_B^i = T(x_1^{(i)}, x_2^{(i)}, \dots, x_N^{(i)})$. Iz vseh K bootstrap vzorcev ocenimo vzorčno porazdelitev za T . Če je ta porazdelitev približno normalna, je ocena za povprečje $E_B(T)$ in za varianco $\text{Var}_B(T)$ po bootstrap tehniki

$$E_B(T) = \sum T_B^i / K$$

$$\text{Var}_B(T) = E_B(T^2) - E_B(T)^2$$

po jackknife tehniki pa

$$E_J(T) = \sum T_j \cdot \frac{1}{N}$$

$$Var_J(T) = (N-1)^{-1} (E_J(T^2) - E_J(T)^2)$$

pri čemer je N število enot v osnovnem vzorcu, K pa število bootstrap vzorcev. Kot smo že omenili, v primeru, da porazdelitev ni 'dovolj normalna', uporabimo predhodno primerno transformacijo.

Empirično je bilo ugotovljeno, da naj bi bilo število bootstrap vzorcev K v primeru, ko želimo oceniti varianco vzorčne ocene, od 50 do 70. Bootstrap pristop se bolj obnese za majhne osnovne vzorce kot pa jackknife pristop. Za vrstilne karakteristike (npr. kvartili) je potrebno več ponovitev ($K > 200$), jackknife tehniku se izkaže v tem primeru zelo slabo.

Bootstrap in jackknife pristop sta izvedljiva le z ustreznim računalniško opremo. Sla algoritmično enostavna, vendar z vidika računalniškega časa zahtevna. Slednje pa postaja ob razvoju računalniške opreme vse manj pomembno.

3. Opis problema

Problem, ki ga predstavljamo, je izračun intervala zaupanja za optimump kvadratne odzivne krivulje. Zvezo med odvisno spremenljivko Y in pojastjevalno spremenljivko X zapisemo

$$E(Y) = \beta_0 + \beta_1 X + \beta_2 X^2$$

Na osnovi vzorca, v katerem je N točk, ocenimo parametre in izračunamo napovedi za odvisno spremenljivko

$$\hat{Y} = b_0 + b_1 X + b_2 X^2$$

Z odvajanjem dobimo oceno za lokacijo ekstrema

$$x_{opt} = -b_1/2b_2$$

Radi bi izračunali interval zaupanja za x_{opt} , za kar potrebujemo njegovo varianco

$$Var(x_{opt}) = Var(-b_1/2b_2)$$

Oceno za varianco $b = (b_0, b_1, b_2)$ dobimo iz variančno-kovariančne matrike

$$Var(b) = (X'X)^{-1}\sigma^2$$

Varianco za razmerje $-b_1/2b_2$ pa ne poznamo. Tako klasični parametrični pristop v tem primeru odpade.

3.1 Parametrični pristop

Razmerje razvijemo v Taylorjevo vrsto okoli točke \hat{x}_{opt} in poiščemo aproksimativno oceno za varianco. Upoštevamo le prve odvode (glej npr. Mead str. 532)

$$\text{Var}(x_{\text{opt}}) \approx (1/4b_2^4)(b_2^2 \text{Var}(b_1) + b_1^2 \text{Var}(b_2) - 2b_1b_2 \text{Cov}(b_1, b_2))$$

Opomrimo naj, da ne znamo ovrednotiti kvalitete te aproksimativne ocene.

3.2 Neparametrični pristop

Alternativni pristop k reševanju takih problemov so tehniko ponovnega vzorčenja.

4. Primer

4.1 Opis problema

Na Katedri za poljedelstvo Biotehniške fakultete v Ljubljani so v letih 1989 in 1990 izvedli poljski poskus, s katerim so poskušali ugotoviti, pri kateri gostoti setve je pridelek koruze optimalen.

S tremi tipi setev so dosegli razmeroma široko območje gostote setve, kar je omogočilo dobro identifikacijo ekstrema odzivne krivulje. Poskus je bil zastavljen kot bločni poskus s 3 bloki, v vsakem bloku je bilo 15 različnih gostot. Skupaj imamo torej 45 meritov.

Grafični prikaz podatkov je na Sliki 1. V obeh primerih se je izkazalo, da se kvadratna krivulja dovolj dobro prilagaja podatkom, kar se je ujemalo s pričakovanji agronomov. Pri večjih gostotah (> 120) so se posebno v 1989 pokazale 'nestabilne' razmere, v obeh letih so se točke z največjo gostoto izkazale kot vplivne točke (angl. inference points). V Tabeli 1 so predstavljeni rezultati statistične analize.

Tabela 1: Predstavitev rezultatov prilaganja kvadratne funkcije: ocene parametrov in njihove standardne napake, koeficient determinacije R^2 , s, Durbin-Watsonova statistika DW, za posamezni leti.

	1989		1990	
	ocena	st. napaka	ocena	st. napaka
b_0	2077.73	559.69	249.19	321.88
b_1	133.202	14.504	103.588	8.34109
b_2	-0.4667	0.0802	-0.3854	0.04613
R^2	70%		88%	
s	1173.69		1088.43	
DW	2.44		1.95	

Izračunali smo oceni za maksimum pridelka iz odvoda. V pojedeljstvu točkovna ocena ne pove dosti, zato je izračun intervala zaupanja za maksimum s stališča stroke začelen. Rezultati so v tabeli 2.

Tabela 2: Ocena za maksimum, za standardno napako (izračunicno po aproksimativni analitični formuli) in 95% interval zaupanja za maksimum.

	1989	1990
x_{opt}	121.3	134.4
$s(x_{opt})$	7.30	6.48
95% IZ	(106.7, 135.9)	(127.3, 140.9)

Intervala zaupanja se prekriva na sorazmerno ozkem območju od 128 do 136.

Do ocene za standardno napako smo poskušali priči tudi z metodami ponovnega vzorčenja. Ker je bilo v osnovnem vzorcu 45 točk, smo se odločili za bootstrap pristop. Izdelali smo tri variente glede na število bootstrap vzorcev: $K = 50$, $K = 100$, $K = 200$.

Za vsak K ($K = 50, 100$ oz. 200) smo izvedli naslednji postopek: iz vsakega posameznega bootstrap vzorca izračunali optimum z odvajanjem, iz vseh K bootstrap vzorcev pa izdelali porazdelitev optimumov. Če je bila porazdelitev optimumov (vsej) simetrična, smo izračunali povprečje in standardno napako za optimum. Če je bila porazdelitev asimetrična (to se je pogosto zgodilo za leto 1989), se s transformacijami nismo ukvartili, ampak smo rezultate zavrgli in ponovili postopek vzorčenja.

Izdelali smo po 5 ponovitev za vsak K in za vsako leto. (Torej je bilo pri $K = 200$ za vsako leto 1000 ponovnih vzorčenj). Izračuni so bili izvedeni na zmogljivem velikem IBM računalniku in zarje smo pri $K = 200$ za vsako ponovitev porabili okoli 10 minut, pri $K = 100$ pa za vsako ponovitev okoli 5 minut. Rezultati so v Tabeli 3 in 4.

Tabela 3: povprečje in standardna napaka za optimum za 1989 glede na različno število bootstrap vzorcev K. Izdelanih je bilo po 5 ponovitev.

1989					
K = 200		K = 100		K = 50	
povprečje	st. napaka	povprečje	st. napaka	povprečje	st. napaka
122.64	14.53	121.92	12.36	120.89	12.67
120.69	11.69	124.28	13.11	121.72	11.61
121.32	11.40	118.45	11.97	119.49	9.55
121.13	11.59	121.67	12.17	122.82	11.08
119.94	11.81	122.83	9.07	122.11	11.22

Tabela 4: povprečje in standarnda napaka za optimum za leto 1990 glede na različno število bootstrap vzorcev K. Izdelanih je bilo po 5 ponovitev.

1990					
K = 200		K = 100		K = 50	
povprečje	st. napaka	povprečje	st. napaka	povprečje	st. napaka
134.20	5.40	134.55	5.41	133.93	3.87
134.28	4.92	133.82	4.77	133.36	6.20
133.93	4.96	134.24	5.07	133.19	4.13
134.91	4.83	133.58	4.06	133.97	4.59
134.49	4.73	133.88	5.30	135.37	4.62

Iz tabele 3 razberemo, da je za leto 1989 optimum približno 121, njegova standardna napaka pa približno 11. Za leto 1990 pa tabela 4 pokaže, da je optimum okoli 134, standardna napaka pa približno 5.

Primerjava: povprečji sta po obeh pristopih skoraj enaki (manj kot 1% različni), različni pa sta standardni napaki: za 1989 daje aproksimativna ocena precej nižjo vrednost, za 1990 pa višjo vrednost. Zdi se, da so rezultati dobjeni po bootstrap metodi bolj kvalitetni, saj z večjo mero upoštevajo informacijo v podatkih.

Literatura:

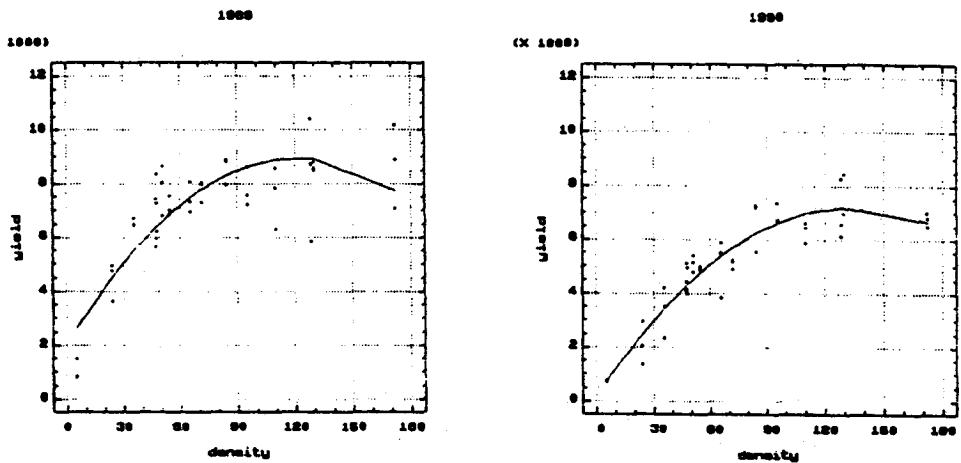
Bissel A.F.: The Jackknife - Toy, Tool or Two-edged Weapon?, *The Statistician*, Vol. 24, No. 2, 1975, p. 79-100

Efron B.: Nonparametric standard errors and confidence intervals, *The Canadian Journal of Statistics*, Vol. 9, No. 2, 1981, p. 139-172

Mead R.: *The Design of Experiments. Statistical principles for practical applications*, Cambridge University Press, 1988

Schemper M.: Some Applications of Bootstrap Techniques to Nonparametrics, neobjavljen

Weishs Claus: Canonical Discriminant Analysis: Comparison of Simulation Methods, Seminar 91 der Region Oesterreich-Schweiz der Internationalen Biometrischen Gesellschaft, Biel, 1991



Slika 1: Grafični prikaz podatkov in odzivne krivulje za leto 1989 in 1990: gostota v 1000 rastlin/ha, pridelek v tonah