

VII. STATISTIČKI TESTOVI

1. VRSTE POGREŠAKA. JAKOST TESTA

Označimo sa $f(x, \theta)$ funkciju vjerojatnosti slučajne varijable x . Distribucija varijable x u potpunosti je određena ako je zadana funkcija f i vrijednost parametra θ . Pretpostavimo sada da za neku varijablu x poznajemo oblik funkcije f , ali da ne znamo vrijednost parametra θ . Za vrijednost tog parametra θ postavimo nul-hipotezu:

$$H_0 : \theta = \theta_0$$

i alternativnu hipotezu:

$$H_1 : \theta = \theta_1$$

Odluka koju od hipoteza treba prihvatiti kao istinitu donosi se na osnovi izvjesnog broja vrijednosti varijable x , drugim riječima, na temelju *uzorka*. Pokazat će se da postoji mogućnost prihvatanja pogrešne hipoteze i da tome odgovara stanovita vjerojatnost; to je ujedno i najkarakterističnije obilježje statističkih odluka u teoriji testiranja. Pri svakom statističkom testiranju moguće su iste vrste pogrešaka, ali oblik funkcije vjerojatnosti tih pogrešaka varira od testa do testa.

Pretpostavimo da je:

$$x_1, x_2, \dots, x_n$$

slučajni uzorak. Svakom takvom uzorku pridružimo točku $T(x_1, \dots, x_n)$ n -dimenzionalnog prostora. Čitav prostor podijelimo zatim na dva disjunktna dijela A i B . Testiranje hipoteze H_0 prema alternativnoj hipotezi H_1 provedimo na slijedeći način: ako uzorak dade točku T iz dijela prostora A (kraće ćemo to označiti sa $T \in A$), prihvatimo hipotezu H_0 kao istinitu; na protiv, ako se desi $T \in B$, tj. točka T padne u dio prostora B , odbacimo hipotezu H_0 i prihvatimo H_1 . Dio prostora A zovemo područjem prihvatanja hipoteze H_0 , a dio prostora B kritičnom domenom ili područjem signifikantnosti (sl. 61).

U mnogo slučajeva moguće je naći takvu slučajnu jednodimenzionalnu varijablu $t = t(x_1, x_2, \dots, x_n)$ pomoću koje se izvodi testiranje hipoteze H_0 . Prednost je toga da područje prihvatanja, a stoga i područje signifikantnosti, postaju dijelovi pravca, a ne dijelovi n -dimenzionalnog prostora.


Pri opisanom načinu testiranja postoji mogućnost *dviju* vrsta pogrešaka. Pogreška *prve vrste* sastoji se od prihvatanja hipoteze H_1 kada je stvarno istinita hipoteza H_0 ; vjerojatnost α takve pogreške jeste:

$$\alpha = P\{T \in B/H_0\} \quad (1)$$

jer nastaje kad točka T padne u dio B prostora, ali pri istinitosti hipoteze H_0 . Kosa crtica i H_0 iza nje u vitičastoj zagradi izraza (1) ima ulogu da naglasi da je riječ o vjerojatnosti ako je istina hipoteza H_0 . Mogli bismo također reći da pogreška prve vrste nastaje pri odbacivanju hipoteze H_0 kada je ona stvarno ispravna (pogrešno odbacivanje H_0).

Pogreška druge vrste nastaje prihvatanjem hipoteze H_0 kada je stvarno istinita hipoteza H_1 (pogrešno prihvatanje H_0). Vjerojatnost β takve pogreške pri opisanom načinu testiranja jeste:

$$\beta = P\{T \in A/H_1\} \quad (2)$$



Slika 61

Sve mogućnosti u pogledu istinitosti hipoteze H_0 i pravilnosti zaključivanja prikazane su u slijedećoj tablici:

Hipoteza H_0	Istinita	Neistinita
Odbacuje se	Pogreška 1. vrste	Pravilan zaključak
Prihvata se	Pravilan zaključak	Pogreška 2. vrste

Osim vjerojatnosti α i β mogućih pogrešaka pri donošenju odluka, uvodi se još i pojam *jakosti* ili *moći* testa. Pod jakosti testa razumijeva se vjerojatnost odbacivanja hipoteze H_0 kada je ona zaista neispravna (vjerojatnost pravilnog odbacivanja H_0), dakle vjerojatnost:

$$p = P\{T \in B/H_1\} \quad (3)$$

Budući da je vjerojatnost da točka T padne u dio prostora A ili B jednaka 1, to je zbog (2) i (3):

$$\beta + p = 1 \quad (4)$$

odnosno:

$$p = 1 - \beta$$

Razabiremo odatle da je jakost testa p to veća, što je vjerojatnost pogreške druge vrste manja.

Vjerojatnost pogreške prve vrste α obično se unaprijed zadaje, u primjenama redovito se uzima 0,05 ili 0,01, a cijeli prostor nastoji se podijeliti na dijelove A i B tako da vjerojatnost β pogreške druge vrste bude po mogućnosti što manja.

Pretpostavimo da smo n -dimenzionalni prostor točaka T podijelili na dva načina: prvo na A i B i pri tom da vrijedi $P\{T \in B/H_0\} = \alpha$, a zatim na A_1 i B_1 i pri tom da je opet $P\{T \in B_1/H_0\} = \alpha$. Test koji se zasniva na prvoj podjeli ima istu vjerojatnost α pogreške prve vrste kao i test zasnovan na drugoj podjeli. Ako se desi da prvom testu odgovara manja vjerojatnost β pogreške druge vrste za svaku dopustivu vrijednost parametra θ , kažemo da je test s domenama A i B *uniformno* jači od testa s domenama A_1 i B_1 . U stvari to znači da ćemo pri upotrebi testa s domenama A i B činiti rjeđe pogrešku druge vrste negoli pri upotrebi testa s domenama A_1 i B_1 . Ako je test s domenama A i B uniformno jači i od svakog drugog testa, kaže se da je on *uniformno najjači*. Na žalost, uniformno najjači testovi uvijek ne postoje, naime obično su neki od testova jači nad jednim područjem vrijednosti parametra θ , a drugi opet nad drugim.

Primjer 1. Novčić X pokazuje grb uz vjerojatnost $p = \frac{1}{2}$. Novčić Y nije uravnotežen,

pa pokazuje grb uz vjerojatnost $p = \frac{2}{3}$. Uzmimo jedan novčić i bacimo ga tri puta. Broj grbova u ta tri bacanja neka je slučajna varijabla t pomoću koje treba odlučiti da li je bacan novčić X ili novčić Y . Drugim riječima, t je slučajna varijabla kojom treba testirati hipotezu $H_0: p = \frac{1}{2}$ prema alternativnoj hipotezi $H_1: p = \frac{2}{3}$.

Naša varijabla t kojom obavljam testiranje može poprimiti vrijednosti 0, 1, 2, 3, a distribuirana je po zakonu binomne razdiobe $B\{n=3, p\}$. Stoga je:

$$P(t) = \binom{3}{t} p^t q^{3-t}$$

Ako je istinita hipoteza H_0 distribucija varijable t prikazana je ovom tablicom:

t	0	1	2	3
$P(t)$	$\frac{1}{8}$	$\frac{3}{8}$	$\frac{3}{8}$	$\frac{1}{8}$

Pretpostavimo sada da je istinita hipoteza H_1 . U tom slučaju distribuciju varijable t prikazuje tablica:

t	0	1	2	3
$P(t)$	$\frac{1}{27}$	$\frac{6}{27}$	$\frac{12}{27}$	$\frac{8}{27}$

U oba slučaja vjerojatnosti $P(t)$ računane su po istoj formuli, jedino što je prvi puta uzeto $p = \frac{1}{2}$ a drugi puta opet $p = \frac{2}{3}$.

Razmotrimo testiranje hipoteze H_0 ako za područje B odbacivanja ove hipoteze uzmemo jednu jedinu vrijednost varijable t , i to $t = 0$. U tom slučaju područje A prihvatanja hipoteze H_0 sastoji se od vrijednosti $t = 1, 2, 3$. Ukratko, ako u tri bacanja novčića bar jednom padne grb odlučimo se za izjavu da je bacan novčić X . Izračunajmo vjerojatnost pogrešaka prve i druge vrste pri ovakvom izboru domena A i B .

Po definiciji pogreške prve vrste slijedi da je njena vjerojatnost:

$$\alpha = P\{t \in B/H_0\} = P\{t = 0/H_0\} = \frac{1}{8} = 0,125$$

što zapravo znači da bismo u 12,5 % slučajeva izjavili da je bacan novčić Y kada je stvarno bacan novčić X (pogrešno bismo odbacili H_0). Vjerojatnost pogreške druge vrste jeste prema (2):

$$\begin{aligned}\beta &= P\{t \in A/H_1\} = P\{t = 1, 2, 3/H_1\} \\ &= \frac{6}{27} + \frac{12}{27} + \frac{8}{27} = \frac{26}{27} = 0,96\end{aligned}$$

Dakle, prema našem testu izjavili bismo u 96 % slučajeva da je bacan novčić X , kada je stvarno bacan novčić Y (pogrešno bismo prihvatili hipotezu H_0).

Područje B odbacivanja hipoteze H_0 proizvoljno smo odabrali, pa ne možemo biti sigurni da je taj test ujedno i najbolji. Da bismo pokazali da postoji i bolji test, uzmimo da domen B' odbacivanja hipoteze H_0 predstavlja vrijednost $t = 3$; domena A' prihvatanja hipoteze H_0 sastoji se sada od vrijednosti $t = 0, 1, 2$. Za test s ovim domenama odbacivanja i prihvatanja hipoteze H_0 vjerojatnosti su pogrešaka prve i druge vrste:

$$\begin{aligned}\alpha' &= P\{t \in B'/H_0\} = P\{t = 3/H_0\} = \frac{1}{8} = 0,125 \\ \beta' &= P\{t \in A'/H_1\} = P\{t = 0, 1, 2/H_1\} \\ &= \frac{1}{27} + \frac{6}{27} + \frac{12}{27} = \frac{19}{27} = 0,70\end{aligned}$$

Budući da je $\alpha = \alpha'$ i $\beta > \beta'$, bolji je test s domenom B' odbacivanja hipoteze H_0 nego li test s domenom B . Ukratko, manja je vjerojatnost pogreške druge vrste ako izjavimo da je bacan novčić Y ako je $t = 3$, negoli ako to izjavimo kada je $t = 0$.

Primjer 2. Varijabla t predstavlja proteklo vrijeme između uzastopnih reagiranja Geigerova brojača u izučavanju kozmičke radijacije. Poznato je da funkcija vjerojatnosti varijable t ima oblik:

$$f(t, c) = c e^{-ct}, \quad 0 < t < +\infty$$

gdje je c parametar koji zavisi o uvjetima pod kojima se vrši ispitivanje radijacije. Pretpostavimo da na temelju jednog jedinog mjerenja vremena koje je proteklo između dvaju uzastopnih reagiranja brojača treba testirati hipotezu $H_0: c = 2$ prema alternativnoj hipotezi $H_1: c = 1$. Koliko su vjerojatnosti pogrešaka prve i druge vrste ako je područje A prihvatanja hipoteze H_0 interval $(0; 1)$?

Funkcija vjerojatnosti slučajne varijable t glasi:

$$f_c(t, 2) = 2e^{-2t}$$

ako je istinita hipoteza H_0 , odnosno:

$$f_1(t, 1) = e^{-t}$$

ako je istinita hipoteza H_1 . Budući da je područje B odbacivanja hipoteze H_0 interval $[1; +\infty)$, to je vjerojatnost pogreške prve vrste:

$$\begin{aligned}\alpha &= P\{t \in B/H_0\} = P\{1 \leq t < \infty/H_0\} \\ &= \int_1^{\infty} f_0(t, 2) dt = 2 \int_1^{\infty} e^{-2t} dt = 0,135\end{aligned}$$

odnosno vjerojatnost pogreške druge vrste:

$$\begin{aligned}\beta &= P\{t \in A/H_1\} = P\{0 < t < 1/H_1\} \\ &= \int_0^1 f_1(t, 1) dt = \int_0^1 e^{-t} dt = 0,632\end{aligned}$$

2. NEYMAN-PEARSONOVA LEMA

Prije no što se upustimo u proučavanje pojedinih testova, moramo postaviti još jedno pitanje. Neka je zadana vjerojatnost α pogreške prve vrste; kako odrediti najbolju kritičnu domen B (time bi ujedno bila određena i domena A prihvatanja hipoteze H_0) u smislu da toj domeni pripada *najmanja* vjerojatnost β pogreške druge vrste?

Po pretpostavci su

$$x_1, x_2, \dots, x_n$$

nezavisne slučajne varijable s istom funkcijom vjerojatnosti $f(x, \theta)$. Stoga je funkcija vjerojatnosti njihove združene distribucije:

$$L(T) = f(x_1, \theta) \cdot f(x_2, \theta) \dots f(x_n, \theta)$$

Uvedemo li znak II kao oznaku za produkt, možemo kraće pisati:

$$L(T) = \prod_{i=1}^n f(x_i, \theta)$$

Za $\theta = \theta_0$ imamo:

$$L_0(T) = \prod_{i=1}^n f(x_i, \theta_0)$$

Ako je $\theta = \theta_1$, onda je:

$$L_1(T) = \prod_{i=1}^n f(x_i, \theta_1)$$

Stoga je vjerojatnost α pogreške prve vrste:

$$\alpha = P\{T \in B/H_0\} = \int_B L_0(T) dx \quad (1)$$