

Meritve konstantnih količin/Statistika

Nekaj statistike smo delali že prej, zato je to bolj grob refresher. Posvetili bomo pozornost šumu. Privzemimo, da je ta porazdeljen po Gaussovi porazdelitvi:

$$r = (z - Hx) = \mathcal{N}(a, \sigma)$$

Ocenjujemo pravzaprav parametra a in σ . Zanima nas ali je porazdelitev omejena če ji "fittamo" Gaussovko, ko gre $n \rightarrow \infty$.

Imamo vzorec z_{i_n} . Vzorčni statistiki sta **povprečje**:

$$\bar{z} = \frac{1}{n} \sum_i z_i$$

in **varianca**:

$$s^2 = \frac{1}{n-1} \sum_i (z_i - \bar{z})^2$$

T-statistika

Definirajmo si novo statistiko takole:

$$T = \frac{\bar{z} - a}{\sqrt{s^2}} \sqrt{n}$$

Imenujemo jo **T-statistika**. Opazimo, da je **odvisna od izbire parametra a** . Poglejmo njeno verjetnostno gostoto:

$$\frac{dP}{dT} = \frac{1}{\sqrt{n-1} \text{B}\left(\frac{n-1}{2}, \frac{1}{2}\right)} \left(1 + \frac{T^2}{n-1}\right)^{-n/2} = S(n-1)$$


kjer je:

$$B(x, y) = \int_0^1 t^{x-1} (1-t)^{y-1} dt$$

Vidimo iz zadnjega člana, da nam da zvonasto obliko in da je normiran. Ker je ta porazdelitev tako pogosto uporabljena jo poimenujejo tudi **Studentova porazdelitev**. Studentov zakon je potem, da je verjetnostna gostota po T statistiki takole:

$$\frac{dP}{dT} = S(n-1)$$

Izgleda pa nekako takole:



Postopek uporabe

1. Acquire vzorec meritev z_{i_n}
2. Izberemo a glede na $\mathcal{N}(a, \sigma)$
3. Izračunamo \bar{z} in s^2

4. Izračunamo T-statistiko T

5. Iz tabeliranih vrednosti za vrednost n izberemo $t_{>}$ in postavimo stopnjo tveganja α

$$P(|t| > t_{>}) = \alpha$$

1. Če je $T > t_{>}$ potem rečemo, da “na stopnji α zavržemo parameter a ”. V nasprotnem primeru pa rečemo, da “na stopnji tveganja α parameter a ne moremo zavreči”.

Interval zaupanje

Interval zaupanje oz. angl. confidence interval definiramo takole:

$$\int_{t_{<}}^{t_{>}} \frac{dP}{dT} dT = (1 - \alpha)$$

Torej $T \in [t_{<}, t_{>}]$ na stopnji $(1 - \alpha)$. Bolj pravilno rečeno mogoče tako, da lahko **izven** tega intervala pričakujemo T z gotovostjo α

$a \in [a_{<}, a_{>}]$ na stopnji $(1 - \alpha)$ oz. a lahko izven tega intervala na stopnji tveganja α zavržemo. Pretvorba je slednja:

$$t_{<} = \frac{\bar{z} - a_{>}}{s} \sqrt{n} \quad t_{>} = \frac{\bar{z} - a_{<}}{s} \sqrt{n}$$

Porazdelitev χ^2

Imejmo tako kot prej vzorec z_{in} za katerega predpostavimo, da je porazdeljen po Gaussovi porazdelitvi $\mathcal{N}(a, \sigma)$.

Sestavimo si statistiko χ^2 :

$$\chi^2 = (n - 1) \frac{s^2}{\sigma^2}$$


Opazimo, da je odvisna od σ . K sreči ko pogledamo njeno gostoto verjetnosti ni več odvisnosti od σ in je $\frac{dP}{d\chi^2}$ univerzalna funkcija in je tabelirana. Zakon pravi pa takole:

$$\chi^2(n - 1) = \frac{dP}{d\chi^2} = \frac{1}{2^{\frac{n-1}{2}} \Gamma(\frac{n-1}{2})} (\chi^2)^{\frac{n-3}{2}} e^{-\frac{\chi^2}{2}}$$

kjer se spomnimo, da je Gamma funkcija:

$$\Gamma(z) = \int_0^{\infty} x^{z-1} e^{-x} dx$$

Narišimo jo na hitro:



Tudi ta porazdelitev je normirana, kar pomeni, da tako kot prej lahko postavimo meje in stopnjo tveganja. Torej z verjetnostjo $(1 - \alpha)$ pričakujemo, da bo $\chi^2 \in [\chi^2_{<}, \chi^2_{>}]$. V nasprotnem če $\chi^2 \notin [\chi^2_{<}, \chi^2_{>}]$ lahko parameter σ na stopnji tveganja α zanemarimo.

Izrek za vsoto kvadratov..

Izrek neznanega imena ali avtorja pravi takole:

Vsota kvadratov n neodvisnih standardizirano normalno naključno porazdeljenih spremenljivk je porazdeljena po zakonu χ^2 z n prostostnimi stopnjami.

Dokaz:

Iz dokaza bomo videli, da je to ekvivalentno naši prejšnji definiciji. Torej imamo x porazdeljen po $\mathcal{N}(0, 1)$. Veljata vzorčni statistiki:

$$\sum x^2 = \chi^2 \quad s^2 = \frac{1}{n-1} \sum (z_i - \bar{z})^2$$

Če imamo nek vzorec z_{i_n} porazdeljen po $\mathcal{N}(\bar{z}, \sigma)$ potem moramo prvo vzorec normalizirati. To storimo takole:

$$\frac{z_i - \bar{z}}{\sigma}$$

To bo porazdeljeno po $\mathcal{N}(0, 1)$. Torej če združimo znanje vemo, da bo:

$$\sum_i \frac{(z_i - \bar{z})^2}{\sigma^2}$$

porazdeljen po $\chi^2(n-1)$. Iz tega pa po hitrem obračanju sledi

$$\chi^2 = (n-1) \frac{s^2}{\sigma^2}$$

Izrek za mešanje porazdelitev..

Parafraziram ampak izrek pravi nekako takole:

Naj bo X porazdeljena po $\mathcal{N}(0, 1)$ in Y porazdeljena po $\chi^2(n)$. Iz nju lahko tvorimo T -statistiko, ki bo porazdeljena po $S(n)$ po predpisu:

$$T = \frac{X}{\sqrt{\frac{Y}{n}}}$$

Dokaz:

Dokažimo kar direktno:

$$T = \frac{\bar{z} - a}{s} \sqrt{n} = \frac{(\bar{z} - a)\sqrt{n}}{\sigma \sqrt{\frac{s^2}{\sigma^2}}} = \frac{\bar{z} - a}{\frac{\sigma}{\sqrt{n}}} \frac{\sqrt{n-1}}{\sqrt{\frac{s^2}{\sigma^2}(n-1)}}$$


V spodnjem korenu prepoznamo definicijo statistike χ^2 . To je (nekako, nisem čisto 100%) porazdeljeno po $S(n-1)$.


Oblikovni testi

Pearsonov χ^2 test

Namen Pearsonovega χ^2 testa je, da ugotovimo kako dobro se neka določena verjetnostna gostota $\frac{dP}{d\xi}$ ujema z našimi podatki.

Imejmo spet vzorec z_{i_n} , ki je porazdeljen po **poljubnem porazdelitvenem zakonu** $\frac{dP}{d\xi}$. Sedaj pa naredimo **razrede**. Grafično si to predstavljamo kot histogram samo da ni treba, da so bin-i ekvidistančni. Takole:





Za njih mora veljati slednje:


1. Morajo biti brez prekrivanja in brez "lukenj". Sestavimo jih ρ
2. N_k izmerkov pade v k -ti razred
3. Verjetnost, da pade v en interval:

$$N_{P_k} = N \int_{\xi_k}^{\xi_{k+1}} \frac{dP}{d\xi} d\xi$$

1. Če smo si dobro izbrali ($\frac{dP}{d\xi}$) bo $(N_k - N_{P_k})$ le statističen šum. Tako lahko štejemo dogodke \bar{N} in dobimo **Poissonovo** porazdelitev $\frac{dP}{dN}$:

$$w_v = \frac{dP}{dN} = \frac{\bar{N}^v e^{-\bar{N}}}{v!}$$

Pri dovolj velikem \bar{N} se ta porazdelitev bliža $\mathcal{N}(\bar{N}, \sqrt{\bar{N}})$. Visual aid:



in tako pridemo do zaključka, da je:

$$\chi^2 = \sum_{k=1}^{\rho} \frac{N_k - N_{P_k}}{N_{P_k}}$$

porazdeljena po $\chi^2(\rho - 1)$

[Zgled: Radioaktiven razpad]

Opazujemo pojav radioaktivnega razpada. Beležimo čas med sosednjima sunkoma t_k . Recimo da imamo vzorec meritev t_{k100} , torej $N = 100$ in da nikoli ni čas med sunkoma daljši od 1.6s. Ali lahko na stopnjo tveganja $\alpha = 5\%$ ovrzemo hipotezo $\tau = 1s$?

Tu preizkušamo če je eksponentna porazdelitev dobra. Torej, ali velja:

$$dP = \frac{1}{\tau} e^{-t/\tau} dt$$

Ustvarimo zdaj dva razreda. Prvi razred sega do $t = 1.6s$, kar pomeni, da bomo v njega zajeli vseh $N_0 = 100$ meritev, ostalo do neskončnosti pa je drugi razred, kamor pade $N_1 = 0$ meritev. Kakšne so verjetnosti za razreda?

$$N_{P_0} = N \int_0^{1.6} \frac{1}{\tau} e^{-t/\tau} dt = 100 \cdot 1 - e^{-1.6} = 80$$

$$N_{P_1} = N \int_{1.6}^{\infty} \frac{1}{\tau} e^{-t/\tau} dt = -100 \cdot e^{-1.6} = 20$$

Tvorimo zdaj χ^2 :

$$\chi^2 = \frac{(100 - 80)^2}{80} + \frac{(0 - 20)^2}{20} = 5 + 20 = 25$$

Pogledamo tabelirano vrednost za $\rho = 2$ in $\alpha = 5\%$, ki znaša:

$$\chi_{>}^2(2 - 1)^{5\%} = 5.99$$

To pa je manjše od dobljenega χ^2 . Grafično prikazano:



Torej: lahko zavržemo hipotezo $\tau = 1s$ na stopnjo tveganja 5% .

Fischerjev test in funkcija zanesljivosti

Želimo testirati porazdelitveni zakon pri čemer želimo parametre določiti optimalno

$$\frac{dP}{dz}(q_1, q_2, \dots, q_m)$$

Torej imamo m izmerkov, ki jih razdelimo v ρ razredov $[z_{k-1}, z_k]$. Sestavimo **funkcijo zanesljivosti**:

$$L^* = \prod_k^{\rho} [P_k(q_i)]^{N_k}$$

kjer je verjetnost za k -ti razred:

$$P_k = \int_{z_{k-1}}^{z_k} \frac{dP}{dz} dz = P_k(q_i; i = 1, \dots, m)$$

Funkcija zanesljivosti nam podaja verjetnost, da dobimo točno tak histogram, kot smo ga izmerili oz. da velja privzeta porazdelitev. Iz

$$\frac{\partial(mL^*)}{\partial q_i} = 0$$

dobimo ocene za parametre q_1^*, \dots, q_m^* in potem sestavimo χ^2 :

$$\chi^2 = \sum_{k=1}^{\rho} \frac{(N_k - N_{P_k}^*)^2}{N_{P_k}^*}$$

ki pa je porazdeljena po zakonu $\chi^2(\rho - 1 - m)$.

Lahko pa tudi ne delimo izmerkov na razrede ko računamo funkcijo zanesljivosti in dobimo tako **poenostavljeno funkcijo zanesljivosti**:

$$L = \prod_{k=1}^N \frac{dP}{dz}(z_k, q_1, \dots, q_m)$$

To izračunamo v vrednostih meritev z_k . Potem isto zahtevamo:

$$\frac{\partial(mL)}{\partial q_i} = 0 \Rightarrow \hat{q}_1, \dots, \hat{q}_m$$

in z njimi tvorimo statistiko:

$$\chi^2 = \sum_{k=1}^{\rho} \frac{(N_k - N_{\hat{P}_k})^2}{N_{\hat{P}_k}}$$

kjer je verjetnost za k -ti razred definirana kot prej. Pri velikem N je dobljeni χ^2 porazdeljen nekje med $\chi^2(\rho - 1 - m)$ in $\chi^2(\rho - 1)$.

[Zgled: Radioaktivni razpad]

Opazujemo spet radioaktivni razpad za katerega smo določili porazdelitev:

$$\frac{dP}{dt} = \frac{1}{\tau} e^{-t/\tau}$$

Radi bi zdaj našli optimalen τ . Tvorimo poenostavljeno funkcijo zanesljivosti:

$$L = \prod_{k=1}^N \frac{1}{\tau} e^{-t_k/\tau} = \frac{1}{\tau^N} \exp \left[- \sum_k \frac{t_k}{\tau} \right]$$

To logaritmirajmo in odvajajmo po parametru, da zahtevamo ekstremalen problem:

$$\ln L = -N \ln \left(\frac{1}{\tau} \right) - \sum_k \frac{t_k}{\tau}$$

$$\frac{\partial \ln L}{\partial \tau} = -\frac{N}{\tau} + \frac{1}{\tau^2} \sum_k t_k = 0 \Rightarrow \frac{1}{\tau} \sum_k t_k = N$$

$$\hat{t} = \frac{1}{N} \sum_k t_k$$


Vidimo, da smo v temu primeru dobili na koncu kar **povprečevanje**, da bo parameter $\hat{\tau}$ optimalen.

Test Kolmogorova oz. Kumulativni test

Imejmo spet vzorec z_{iN} in privzet porazdelitveni zakon $\frac{dP}{d\xi}$. Sestavimo **kumulativno porazdelitveno funkcijo**:

$$F(z) = \int_{-\infty}^z \frac{dP}{d\xi} d\xi$$

Zelo grob grafičen prikaz:



Sestavimo **eksperimentalno kumulativno funkcijo**:

$$f(z) = \frac{k(z)}{N}$$


kjer je $k(z)$ funkcija, ki nam pove število vseh izmerkov, manjših od z . Testiramo maksimalni odmik:

$$D = \sup_{-\infty < z < \infty} |F(z) - f(z)|$$

Če $\frac{dP}{d\xi}$ dobro opiše meritve, je D le izjemoma zelo velik. Kolmogorov je napisal takole:

$$\lim_{N \rightarrow \infty} P(D\sqrt{N} < d) = \sum_{k=-\infty}^{\infty} (-1)^k e^{-2k^2 d^2}$$

Zadeva zglada nekako tako:



Izberemo tak mejni $d_{<}$, da je $P(D\sqrt{N} < d) = 1 - \alpha$.

Če je $D\sqrt{N} > d_{<}$, lahko s tveganjem α zavrnemo hipotezo, da $F(z)$ ustreza izmerkom.