

Statistika z elementi informatike

Osnove verjetnostnega računa in statistike


9.4.1999

1. Naloga: Izpeljana porazdelitev

Obravnavamo ravninski primer sevanja radioaktivnega telesa, ki seva na vse strani enako. To pomeni, da je slučajna spremenljivka Θ , ki predstavlja kot posameznega žarka, enakomerno porazdeljena. Zaradi svinčene zaščite seva le navzdol (glej sliko). Tako lahko gostoto verjetnosti zapišemo takole:

$$f_\Theta(\vartheta) = 1/\pi \quad \dots \quad -\pi/2 \leq \vartheta \leq \pi/2.$$

Določi gostoto verjetnosti slučajne spremenljivke X , da posamezen žarek pade na raven ekran neskončnih razsežnosti x od točke A . Skiciraj gostoto verjetnosti te porazdelitve, ki je poznana kot *Cauchyjeva porazdelitev*. Razdalja radioaktivnega telesa do ekrana $a =$ dan vašega rojstva [cm].



SLIKA 1: Radioaktivno sevanje v ravnini

Rešitev: Iz slike 1a lahko določimo zvezo med kotom ϑ in vodoravno razdaljo x :

$$\frac{x}{a} = \operatorname{tg} \vartheta \quad \rightarrow \quad x = g(\vartheta) = a \operatorname{tg} \vartheta.$$


Iz slik 1a in 2a lahko sklepamo, da območju $-\pi/2 \leq \vartheta \leq \pi/2$ ustreza neskončno območje $-\infty \leq x \leq \infty$. Ker je na območju od $-\pi/2 \leq \vartheta \leq \pi/2$ funkcija monotona (glej sliko 2a), lahko zapišemo obratno zvezo

$$\vartheta = \operatorname{arctg} \frac{x}{a} = g^{-1}(x)$$

in izpeljemo gostoto verjetnosti po enačbi:

$$f_X(x) = f_\Theta(g^{-1}(x)) \cdot \frac{dg^{-1}(x)}{dx} = \frac{1}{\pi} \cdot \frac{a}{a^2 + x^2} \quad \dots \quad -\infty \leq x \leq \infty.$$

Na sliki 2b prikazujemo graf gostote verjetnosti slučajne spremenljivke X za nekaj vrednosti parametra a .



SLIKA 2: Zveza med ϑ in x ter gostota verjetnosti $f_X(x)$

2. Naloga: diskretna slučajna spremenljivka

Nek stroj lahko dnevno proizvede 1, 2, 3 ali 4 izdelke. Verjetnostna funkcija števila proizvedenih izdelkov N je:

$$p_N(n) = \begin{cases} 0.1 & \dots \quad n = 1 \\ 0.2 & \dots \quad n = 2 \\ 0.5 & \dots \quad n = 3 \\ 0.2 & \dots \quad n = 4 \end{cases}$$

Določite verjetnostno funkcijo skupnega števila M proizvedenih izdelkov, ki jih proizvedeta dva neodvisno delujoča stroja z enakimi lastnostmi. Narišite verjetnostno funkcijo in določite srednjo vrednost $E[M]$ in varianco $VAR[M]$ slučajne spremenljivke M .

Rešitev: Ker dva stroja, ki delujeta neodvisno, lahko izdelata po 1 do 4 izdelkov, je skupno število izdelkov lahko 2, 3, 4, 5, 6, 7 ali 8 izdelkov. Verjetnostno funkcijo $p_M(m)$ določimo z naslednjo preglednico:

1. stroj N_1	2. stroj N_2	Skupaj M	Verjetnost
1	1	2	$0.1 \cdot 0.1 = 0.01$
1	2	3	$0.1 \cdot 0.2 = 0.02$
1	3	4	$0.1 \cdot 0.5 = 0.05$
1	4	5	$0.1 \cdot 0.2 = 0.02$
2	1	3	$0.2 \cdot 0.1 = 0.02$
2	2	4	$0.2 \cdot 0.2 = 0.04$
2	3	5	$0.2 \cdot 0.5 = 0.10$
2	4	6	$0.2 \cdot 0.2 = 0.04$
3	1	4	$0.5 \cdot 0.1 = 0.05$
3	2	5	$0.5 \cdot 0.2 = 0.10$
3	3	6	$0.5 \cdot 0.5 = 0.25$
3	4	7	$0.5 \cdot 0.2 = 0.10$
4	1	5	$0.2 \cdot 0.1 = 0.02$
4	2	6	$0.2 \cdot 0.2 = 0.04$
4	3	7	$0.2 \cdot 0.5 = 0.10$
4	4	8	$0.2 \cdot 0.2 = 0.04$

Iz te preglednice lahko povzamemo verjetnostno funkcijo $p_M(m)$

$$p_M(m) = \begin{cases} 0.01 & \dots \quad m = 2 \\ 0.04 & \dots \quad m = 3 \\ 0.14 & \dots \quad m = 4 \\ 0.24 & \dots \quad m = 5 \\ 0.33 & \dots \quad m = 6 \\ 0.20 & \dots \quad m = 7 \\ 0.04 & \dots \quad m = 8 \end{cases},$$

ki jo narišemo na sliki 3. Srednjo vrednost in varianco slučajne spremenljivke M lahko izračunamo po enačbah

$$\mathbb{E}[M] = \sum_{m=2}^8 m \cdot p_M(m) = 5.60,$$

$$\mathbb{E}[M^2] = \sum_{m=2}^8 m^2 \cdot p_M(m) = 32.88,$$

$$\text{VAR}[M] = \mathbb{E}[M^2] - \mathbb{E}[M]^2 = 1.52.$$


Enako izračunamo tudi, če po podobnih enačbah izračunamo najprej srednjo vrednost in varianco slučajne spremenljivke N :

$$\begin{aligned} \mathbb{E}[N] &= \sum_{n=1}^4 n \cdot p_N(n) = 2.8, \\ \mathbb{E}[N^2] &= \sum_{n=1}^4 n^2 \cdot p_N(n) = 8.6 \\ \text{VAR}[N] &= \mathbb{E}[N^2] - \mathbb{E}[N]^2 = 0.76. \end{aligned} \tag{1}$$

ter upoštevamo zveze za momente vsote več neodvisnih slučajnih spremenljivk:

$$\mathbb{E}[M] = \mathbb{E}[N + N] = \mathbb{E}[N] + \mathbb{E}[N] = 2.8 + 2.8 = 5.60,$$

$$\text{VAR}[M] = \text{VAR}[N + N] = \text{VAR}[N] + \text{VAR}[N] = 0.76 + 0.76 = 1.52.$$



SLIKA 3: Verjetnostna funkcija $p_M(m)$

3. Naloga: Analiza variance

Na odlagališču odpadkov so merili koncentracije kroma v ppm (part per million). Odlagališče so razdelili na tri območja in v vsakem območju izmerili koncentracijo kroma na šestih slučajno izbranih merilnih mestih. Ugotovite ali je območje odlagališča statistično značilen faktor. Stopnja tveganja naj bo 1%. Podatke podajamo v naslednji preglednici:

območje	Količina Cr [ppm]					
prvo območje	35	36	30	29	32	32
drugo območje	14	21	19	24	26	37
tretje območje	13	6	21	23	21	33

Rešitev: Najprej izračunajmo povprečno vrednost vseh meritev \bar{x} ter povprečne vrednosti meritev po območjih \bar{x}_1 , \bar{x}_2 in \bar{x}_3 :

$$\bar{x} = \frac{1}{3 \cdot 6} \sum_{i=1}^3 \sum_{j=1}^6 x_{ij} = \frac{35 + 36 + \dots + 21 + 33}{18} = 25.11,$$

$$\bar{x}_1 = \frac{1}{6} \sum_{j=1}^6 x_{1j} = \frac{35 + 36 + 30 + 29 + 32 + 32}{6} = 32.33,$$

$$\bar{x}_2 = \frac{1}{6} \sum_{j=1}^6 x_{2j} = \frac{14 + 21 + 19 + 24 + 26 + 37}{6} = 23.50,$$

$$\bar{x}_3 = \frac{1}{6} \sum_{j=1}^6 x_{3j} = \frac{13 + 6 + 21 + 23 + 21 + 33}{6} = 19.50.$$

Izračunajmo še vsoto kvadratov odstopanj od povprečnih vrednosti:

$$\begin{aligned} SS_A &= 6 \cdot \sum_{i=1}^3 (\bar{x}_i - \bar{x})^2 = \\ &= (32.33 - 25.11)^2 + (23.5 - 25.11)^2 + (19.5 - 25.11)^2 = 517.44, \end{aligned}$$

$$\begin{aligned} SS_E &= \sum_{i=1}^3 \sum_{j=1}^6 (x_{ij} - \bar{x}_i)^2 = \\ &= (35 - 32.33)^2 + (36 - 32.33)^2 + \dots + \\ &\quad + (14 - 23.50)^2 + (21 - 23.50)^2 + \dots + \\ &\quad + (13 - 19.50)^2 + (6 - 19.5)^2 + \dots = 766.33, \end{aligned}$$

$$\begin{aligned} SS_T &= \sum_{i=1}^3 \sum_{j=1}^6 (x_{ij} - \bar{x})^2 = \\ &= (35 - 25.11)^2 + (36 - 25.11)^2 + \dots + (33 - 25.11)^2 = 1283.78. \end{aligned}$$

Ta izračun preverimo tudi z izrazom

$$SS_T = SS_A + SS_E \quad \rightarrow \quad 1283.78 = 517.44 + 766.33.$$

Število prostostnih stopenj za faktor je $3 - 1 = 2$, za napako oziroma nepojasnjena odstopanja $6 \cdot 3 - 3 = 15$ in za skupna odstopanja $6 \cdot 3 - 1 = 17$.

Sedaj lahko pripravimo preglednico analize variance:

Vzrok	SS	n_{ps}	MS
Faktor	517.44	2	258.72
Napaka	766.33	15	51.09
Skupaj	1283.78	17	

Postavimo ničelno in alternativno hipotezo:

H_0 : Območje ne vpliva na koncentracijo kroma.

H_1 : Območje vpliva na koncentracijo kroma.

Statistika, na osnovi katere bomo ničelno hipotezo morda lahko zavrnili, je:

$$\frac{MS_A}{MS_E} = 5.064.$$

To vrednost primerjamo z vrednostjo porazdelitvene funkcije porazdelitve $F_{2,15}$ in sicer za stopnjo zaupanja 0.99. Iz preglednice za porazdelitev F lahko odčitamo približno vrednost $F_{2,15,0.99}$. Natančneje to vrednost določimo z računalniškim programom (na primer EXCEL: ukaz $\text{FINV}(0.01; 2; 15)$):

$$F_{2,15,0.99} = 6.359.$$

Ker je $MS_A/MS_E < F_{2,15,0.99}$, ničelne hipoteze ne moremo zavrniti in moramo zaključiti:
Za stopnjo statističnega tveganja 1% velja, da vpliv območij ni statistično značilen.

Če bi izbrali večje tveganje (na primer 5%), bi bil zaključek v tem primeru drugačen. Vrednost porazdelitvene funkcije je namreč $F_{2,15,0.95} = 3.682 < MS_A/MS_E$. Tedaj bi zaključili: *Za stopnjo statističnega tveganja 5% velja, da je vpliv območij statistično značilen.*

4. Naloga: Določanje parametra porazdelitve gama

Gostota verjetnosti porazdelitve gama (Γ), ki opisuje čas, ko se zgodi k -ti uspeh, je:

$$f_X(x) = \frac{\lambda(\lambda x)^{k-1} e^{-\lambda x}}{(k-1)!} \quad x \geq 0.$$

Srednja ozziroma pričakovana vrednost te porazdelitve je:

$$E[X] = m_X = \frac{k}{\lambda}.$$

Določite oceno parametra porazdelitve λ po metodi momentov in po metodi največje verjetnosti. Vzorec podatkov sestavlja pet vrednosti x_i . Vzemimo, da je drugi parameter porazdelitve $k = 10$.

0.7816	0.9398	0.6834	0.8141	1.5637
--------	--------	--------	--------	--------

Rešitev: Iz podanega vzorca lahko izračunamo njegovo povprečno vrednost \bar{X} , ki predstavlja oceno srednje vrednosti \hat{m}_X slučajne spremenljivke X :

$$\hat{m}_X = \bar{X} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{0.7816 + 0.9398 + 0.6834 + 0.8141 + 1.5637}{5} = 0.9565.$$

Ob upoštevanju podane enačbe o zvezi med m_X in parametrom λ lahko podamo oceno parametra $\hat{\lambda}$ po *metodi momentov*

$$\hat{\lambda} = \frac{k}{\hat{m}_X} = \frac{10}{0.9565} = 10.45.$$

Oceno po metodi največje verjetnosti moramo še izpeljati. Definirajmo funkcijo L

$$L(\lambda) = \prod_{i=1}^n f_X(x_i) = \prod_{i=1}^n \frac{\lambda(\lambda x_i)^{k-1} e^{-\lambda x_i}}{(k-1)!}.$$

Ekstrem te funkcije določimo s pogojem, da je odvod $dL/d\lambda$ enak nič. Zaradi preprostejše izpeljave funkcijo L logaritmiramo, saj zaradi monotonosti logaritemske funkcije velja, da imata ekstremne vrednosti za iste vrednosti argumenta. Po logaritmiranju moramo upoštevati še lastnosti logaritmov ($\ln(ab) = \ln a + \ln b$ in $\ln a^c = c \ln a$)

$$\begin{aligned} \ln L(\lambda) &= \ln \left[\prod_{i=1}^n \frac{\lambda(\lambda x_i)^{k-1} e^{-\lambda x_i}}{(k-1)!} \right] = \\ &= \sum_{i=1}^n \ln \lambda + \sum_{i=1}^n \ln(\lambda x_i)^{k-1} + \sum_{i=1}^n (-\lambda x_i) - \sum_{i=1}^n \ln(k-1)! = \\ &= n \ln \lambda + (k-1) \sum_{i=1}^n \ln(\lambda x_i) - \sum_{i=1}^n \lambda x_i - n \ln(k-1)! . \end{aligned}$$

Če zadnjo enačbo odvajamo po λ , dobimo

$$\begin{aligned} \frac{d \ln L(\lambda)}{d \lambda} &= n \frac{1}{\lambda} + (k-1) \sum_{i=1}^n \left(\frac{1}{\lambda x_i} x_i \right) - \sum_{i=1}^n x_i = n \frac{1}{\lambda} + (k-1) n \frac{1}{\lambda} - \sum_{i=1}^n x_i = \\ &= \frac{n k}{\lambda} - \sum_{i=1}^n x_i \end{aligned}$$

Zahtevajmo sedaj, da je ta odvod enak nič, in dobimo izraz za oceno parametra $\hat{\lambda}$ po *metodi največje verjetnosti*:

$$\frac{d \ln L(\lambda)}{d \lambda} = 0 = \frac{n k}{\hat{\lambda}} - \sum_{i=1}^n x_i \quad \rightarrow \quad \hat{\lambda} = \frac{n k}{\sum_{i=1}^n x_i} = \frac{k}{\bar{X}} = \frac{10}{0.9565} = 10.45$$

Dobili smo torej enak rezultat kot po metodi momentov.