

Višedimenzionalne slučajne varijable i Teorija pogrešaka

Višedimenzionalne slučajne varijable

Jednostavan primjer:

- možemo se pitati kolika je vjerojatnost da je koordinata x neke točke u intervalu (x_1, x_2) , te tretirati taj slučaj 1D statističkim pristupom
- no, možemo se i pitati i kolika je vjerojatnost da je položaj neke točke u određenom dijelu ravnine, tj. da je $x_1 < x < x_2$ i $y_1 < y < y_2$
- slučajna varijabla tada je vektor $\vec{r} = \hat{x}\hat{i} + \hat{y}\hat{j}$, koji se sastoji od dvije nezavisne dimenzije x i y

Dakle:

$$\begin{array}{ccc} P(x) & \leftrightarrow & P(\vec{r}) = P(x, y) \\ 1D & & 2D \\ & \vec{r} = \hat{x}\hat{i} + \hat{y}\hat{j} & \\ & & P(\vec{r}) = P(x, y, z) \\ & & 3D \\ & & \vec{r} = \hat{x}\hat{i} + \hat{y}\hat{j} + \hat{z}\hat{k} \end{array}$$

Višedimenzionalne slučajne varijable

Def.: neka su X i Y dvije diskretne slučajne varijable definirane na prostoru elementarnih događaja nekog eksperimenta. Združena raspodjela vjerojatnosti $p(x,y)$ definirana je za svaki par točaka (x,y) kao vjerojatnost da istodobno varijabla X poprimi vrijednost x i varijabla Y poprimi vrijednost y :

$$p(x,y) = P(X=x \text{ i } Y=y)$$

Primjer

Na PMF-u studente razvrstamo prema područjima studiranja (varijabla X) i prema spolu (varijabla Y). Združenu raspodjelu vjerojatnosti za dva obilježja (područje i spol) možemo prikazati tablicom:

	M	Ž	
Matematika	0,151	0,105	
Fizika	0,125	0,079	
Kemija	0,069	0,074	
Biologija	0,062	0,153	
Geo-znanosti	0,124	0,058	

Višedimenzionalne slučajne varijable - rubne raspodjele vjerojatnosti

Def.: Rubne (marginalne) raspodjele vjerojatnosti za varijable X i Y označavamo $p_x(x)$ i $p_y(y)$, a dane su izrazima:

$$p_x(x) = \sum_{y \in D_y} p(x,y) \quad i \quad p_y(y) = \sum_{x \in D_x} p(x,y)$$

U gornjem primjeru je, npr., rubna vjerojatnost za matematiku $p_x(\text{mat}) = 0.256$, a rubna vjerojatnost za muški spol $p_y(M) = 0.531$.

	M	Ž	
Matematika	0,151	0,105	
Fizika	0,125	0,079	
Kemija	0,069	0,074	
Biologija	0,062	0,153	
Geo-znanosti	0,124	0,058	

Višedimenzionalne slučajne varijable - očekivanja

Očekivanja su dana sljedećim izrazima:

$$E(x) = \sum_{i=1}^n x_i P(x_i) = \sum_{i,j} x_i P(x_i, y_j),$$

$$E(y) = \sum_{j=1}^n y_j P(y_j) = \sum_{i,j} y_j P(x_i, y_j)$$

Neovisnost varijabli X i Y

- sjetimo se: dva su događaja neovisna ukoliko je $P(A_1 \cdot A_2) = P(A_1)P(A_2)$

Slično, dvije su varijable neovisne ako je:

$$p(x_i, y_j) = P(x_i)P(y_j)$$

Višedimenzionalne slučajne varijable - očekivanja

Neka važna svojstva očekivanja:

(1) $E(x+y) = E(x) + E(y)$

$$E(x+y) = \sum_{i,j} (x_i + y_j) p(x_i, y_j) = \sum_{i,j} x_i p(x_i, y_j) + \sum_{i,j} y_j p(x_i, y_j) = E(x) + E(y)$$

(2) Ako su x i y nezavisne varijable vrijedi:

$$E(xy) = E(x)E(y)$$

$$\begin{aligned} E(x \cdot y) &= \sum_{i,j} (x_i \cdot y_j) p(x_i, y_j) = \sum_{i,j} x_i y_j P(x_i) P(y_j) = \\ &= \sum_i x_i P(x_i) \sum_j y_j P(y_j) = E(x)E(y) \end{aligned}$$

Višedimenzionalne slučajne varijable - momenti

Pomoćni moment reda (r,s) je:

$$m_{rs} = \sum_{i,j} x_i^r y_j^s p(x_i, y_j)$$

$$1D : m_r = \sum_i x_i^r p(x_i)$$

Centralni moment reda (r,s) je:

$$M_{rs} = \sum_{i,j} (x - \mu)^r (y - v)^s p(x_i, y_j)$$

gdje je $\mu = E(x)$, a $v = E(y)$

$$1D : M_r = \sum_i (x_i - \mu)^r p(x_i)$$

Posebno: $\mu = E(x) = \sum_{i,j} x_i p(x_i, y_j) = m_{10},$

$$v = E(y) = \sum_{i,j} y_j p(x_i, y_j) = m_{01},$$

$$\sigma_x^2 = V(x) = \sum_{i,j} (x_i - \mu)^2 p(x_i, y_j) = M_{20},$$

$$\sigma_y^2 = V(y) = \sum_{i,j} (y_j - v)^2 p(x_i, y_j) = M_{02}.$$

Višedimenzionalne slučajne varijable - kovarijanca

Kovarijancom dviju varijabli nazivamo:

$$M_{11} = \sigma_{xy} = \sum_{i,j} (x_i - \mu)(y_i - \nu) p(x_i, y_j)$$

Jednostavnije je pisati:

$$\sigma_{xy} = \sum_{i,j} x_i y_j p(x_i, y_j) - \mu \sum_{i,j} y_j p(x_i, y_j) - \nu \sum_{i,j} x_i p(x_i, y_j) + \mu \nu \sum_{i,j} p(x_i, y_j)$$

The diagram shows three light blue ovals. The first oval contains the term $\sum_{i,j} y_j p(x_i, y_j)$. An arrow points from this oval to the symbol v below it. The second oval contains the term $\sum_{i,j} x_i p(x_i, y_j)$. An arrow points from this oval to the symbol μ below it. The third oval contains the term $\sum_{i,j} p(x_i, y_j)$. An arrow points from this oval to the symbol 1 below it.

$$\sigma_{xy} = \sum_{i,j} x_i y_j p(x_i, y_j) - \mu \nu = E(xy) - E(x)E(y)$$
$$M_{11} = m_{11} - m_{10}m_{01}$$

Kovarijanca je mjera toga koliko se se varijable zajedno mijenjaju

Višedimenzionalne slučajne varijable - kovarijanca

Primjer:




Figure 5.4 $p(x, y) = 1/10$ for each of ten pairs corresponding to indicated points; (a) positive covariance; (b) negative covariance; (c) covariance near zero

Važno! Kovarijanca nezavisnih varijabli jednaka je nuli

$$\sigma_{xy} = \sum_{i,j} x_i y_j p(x_i, y_j) - \mu v = \sum_i x_i p(x_i) \sum_j y_j p(y_j) - \mu v = \mu v - \mu v = 0$$

To je vrlo važno svojstvo, jer nam kazuje da li postoji **KORELACIJA** danog skupa kao rezultat mjerenja, npr. jesu li visine majki i kćeri povezane

Višedimenzionalne slučajne varijable - kovarijanca

Neka važna svojstva varijanci:

$$V(x+y) = V(x) + V(y) + 2\sigma_{xy}$$

$$V(ax+by) = a^2V(x) + b^2V(y) + 2ab\sigma_{xzy}$$

Kovarijanca je veličina koja nam govori o povezanosti (zavisnosti) varijabli X i Y. Međutim, iznos kovarijance ovisi i o jedinicama u kojima mjerimo. Da bismo mogli nešto reći o stupnju zavisnosti, moramo tu povezanost izraziti bezdimenzionalnim veličinama. Stoga uvodimo pojam korelaciјe.

Višedimenzionalne slučajne varijable - korelacija

Def.: Koeficijent korelaciјe varijabli X i Y definiran je kao:

$$\text{Corr}(X,Y) = \rho_{x,y} = \frac{\sigma_{xy}}{\sigma_x \sigma_y}$$

Svojstva:


1. $\text{Corr}(aX+b, cY+d) = \text{Corr}(X, Y)$
2. $-1 \leq \rho \leq 1$
3. Ako su X i Y nezavisne varijable onda je $\rho = 0$ (obrat ne vrijedi)
4. Ako je $Y = aX+b$ onda i samo onda je $\rho = 1$ ili $\rho = -1$

Korelacija koja iščezava ne isključuje povezanost veličina, nego samo linearu povezanost.

Korelacija blizu 1 ne znači nužno da porast veličine X uzrokuje porast veličino Y , nego samo da postoji veza među njima.

Višedimenzionalne slučajne varijable - korelacija

Koeficijenti korelaciјe:



Ne brkati korelaciјu i ovisnost!

Višedimenzionalne slučajne varijable - kontinuirane varijable

Def.: Neka su X i Y dvije kontinuirane slučajne varijable. Funkcija $f(x,y)$ je njihova združena funkcija gustoće vjerojatnosti ako za bilo koji dvodimenzionalni skup $A \subseteq \mathbb{R} \times \mathbb{R}$ vrijedi:


$$P((X,Y) \in A) = \iint_A f(x,y) dx dy$$

Takva funkcija mora zadovoljavati uvjete:

$$f(x,y) \geq 0; \quad \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x,y) dx dy = 1$$

Višedimenzionalne slučajne varijable - kontinuirane varijable

Zamislimo li plohu u 3D koordinatnom sustavu čija visina iznad točke $(x,y) \in A$ iznosi $f(x,y)$, tada je vjerojatnost $P[(x,y) \in A]$ određena volumenom ispod te plohe



Def.: Rubne (marginalne) funkcije gustoće vjerojatnosti za varijable X i Y označavamo $f_x(x)$ i $f_y(y)$, a dane su izrazima:

$$f_x(x) = \int_{-\infty}^{\infty} f(x,y) dy \quad i \quad f_y(y) = \int_{-\infty}^{\infty} f(x,y) dx$$

Višedimenzionalne slučajne varijable - kontinuirane varijable

Očekivane vrijednosti:

$$E(x) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} xf(x,y) dx dy = \int_{-\infty}^{\infty} xp(x) dx$$

$$E(y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} yf(x,y) dx dy = \int_{-\infty}^{\infty} yp(y) dx$$

$E(x+y)$ i $E(xy)$, kao i ostala opća svojstva ne ovise o tome je li raspodjela kontinuirana ili diskretna!

Višedimenzionalne slučajne varijable - kontinuirane varijable

$$m_{rs} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x^r y^s f(x, y) dx dy$$

$$M_{rs} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x - \mu)^r (y - v)^s f(x, y) dx dy$$

$$\sigma_{xy} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} xy f(x, y) dx dy - \mu v$$

$$\sigma_x^2 = \int_{-\infty}^{\infty} (x - \mu)^2 p(x) dx$$

$$\sigma_y^2 = \int_{-\infty}^{\infty} (y - v)^2 p(y) dy$$

Teorija slučajnih pogrešaka

- znanstveni pokus, tj. mjeranje neke fizikalne veličine, uvijek rezultira nizom vrijednosti x_1, x_2, \dots , koje se razlikuju od prave vrijednosti X , te međusobno
- pažljivi eksperimentator eliminira **sistematske pogreške** pa su gornje razlike rezultat **slučajnih pogrešaka**
- prva ocjena rezultata je računanje:

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n}; \quad \sigma^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}$$

- međutim, ove veličine ne dotiču se X i njene pogreške koje su obje nepoznate veličine
- teorija slučajnih pogrešaka ima za cilj opisati rezultat s obzirom na X na najbolji mogući način, koristeći eksperimentalno dostupne veličine

Gaussov zakon pogrešaka

- ako je X prava vrijednost neke veličine, onda se za najvjerojatniju vrijednost te veličine uzima:

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n}$$

gdje su x_i mjerena te veličine


- neka je $v_i = \bar{x} - x_i$ onda je vjerojatnost za tu grešku jednaka:

$$\varphi(v)dv = \frac{h}{\sqrt{\pi}} e^{-h^2 v^2} dv$$

Gaussov zakon pogreške

- značenje parametra h odredit ćemo kasnije

Gaussov zakon pogrešaka



Značenje: izmjereni rezultati distribuiraju se približno po Gaussovoj raspodjeli oko \bar{x}

Zakon rasprostranjenja pogrešaka

Neka je $\varepsilon_i = X - x_i$



ovo ne znamo jer ne znamo X!

Tada je srednja pogreška dana s:

$$m^2 = \frac{\sum_{i=1}^n \varepsilon_i^2}{n}$$

(primijetite: isto kao σ^2 samo $X \leftrightarrow \bar{x}$)

Neka je $X = X_1 + X_2$, gdje X_1 ima pogrešku m_1 , a X_2 pogrešku m_2 . Koliki je m za X ?

$$m_1^2 = \frac{\sum_{i=1}^{n_1} \varepsilon_{i1}^2}{n_1}, \quad m_2^2 = \frac{\sum_{j=1}^{n_2} \varepsilon_{j2}^2}{n_2}$$

Zakon rasprostranjenja pogrešaka

Pogreška kod $X = X_1 + X_2$ mogu nastati svim zbrajanjem ε_{i1} i ε_{j2} , tj.

$$m^2 = \frac{\sum_{i,j} (\varepsilon_{i1} + \varepsilon_{j2})^2}{n_1 n_2} = \frac{\sum_{i,j} (\varepsilon_{i1}^2 + \varepsilon_{j2}^2 + 2\varepsilon_{i1}\varepsilon_{j2})}{n_1 n_2} = \frac{\sum_{j=1}^{n_2} \sum_{i=1}^{n_1} \varepsilon_{i1}^2}{n_1 n_2} + \frac{\sum_{i=1}^{n_1} \sum_{j=1}^{n_2} \varepsilon_{j1}^2}{n_1 n_2} =$$
$$= \frac{\sum_{i=1}^{n_1} \varepsilon_{i1}^2}{n_1} + \frac{\sum_{j=1}^{n_2} \varepsilon_{j2}^2}{n_2} = m_1^2 + m_2^2$$

Općenitije, vrijedi zakon rasprostranjenja pogrešaka!

Ako je: $X = X_1 \pm X_2 \pm X_3 \pm \dots \pm X_n$ tada je:

$$m^2 = m_1^2 + m_2^2 + m_3^2 + \dots + m_n^2$$

Napomena: m se naziva i
'pogreška jednog mjerjenja'

Srednja pogreška, nepouzdanost

- imamo niz mjeranja, x_1, x_2, \dots, x_n , te izračunamo očekivanu vrijednost

$$\bar{x} = \frac{\sum_i x_i}{n}$$

- pitanje: kako interpretirati taj rezultat?

- pretpostavka: vrijedi Gaussov zakon pogreške

- prije smo uveli $\varepsilon_i = X - x_i$

- sada uvodimo $v_i = \bar{x} - x_i$  **TO ZNAMO!**


- neka \bar{x} odstupa od X za M , veličinom koju nazivamo **NEPOUZDANOST**

$$X = \bar{x} \pm M$$

$$\varepsilon_i = X - x_i = \bar{x} \pm M - x_i = v_i \pm M$$

Srednja pogreška, nepouzdanost

Srednja pogreška je:

$$m^2 = \frac{\sum_{i=1}^n \varepsilon_i^2}{n} = \frac{\sum_{i=1}^n (\nu_i \pm M)^2}{n} = \frac{\sum_{i=1}^n \nu_i^2}{n} \pm 2M \frac{\sum_{i=1}^n \nu_i}{n} + M^2 \frac{\sum_{i=1}^n 1}{n} = \sigma^2 + M^2$$


Pogledajmo kolika je POGREŠKA ARITMETIČKE SREDINE:

$$\bar{x} = \frac{x_1}{n} + \frac{x_2}{n} + \dots + \frac{x_n}{n}$$

x_1 ima pogrešku m , x_2 ima pogrešku m , itd., pa svaki član gornje sume ima pogrešku m/n

Srednja pogreška, nepouzdanost

Prema zakonu o rasprostranjivanju pogrešaka:

$$m_{\bar{x}}^2 = \left(\frac{m}{n}\right)^2 + \left(\frac{m}{n}\right)^2 + \dots + \left(\frac{m}{n}\right)^2 = n \left(\frac{m}{n}\right)^2 = \frac{m^2}{n}$$

- hipoteza: $m_{\bar{x}}$ ne razlikuje se bitno od M
- iako se ova pretpostavka čini vrlo *ad hoc*, u praksi se pokazuje zadovoljavajućom

$$m^2 = \sigma^2 + M^2 \approx \sigma^2 + \frac{m^2}{n}$$

$$m \sqrt{\frac{n-1}{n}} \approx \sigma$$

Srednja pogreška, nepouzdanost

STANDARDNA
DEVIJACIJA

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}}$$

SREDNJA POGREŠKA
ili POGREŠKA JEDNOG
MJERENJA

$$m = \sqrt{\frac{n}{n-1}} \sigma = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}}$$

NEPOUZDANOST ili
POGREŠKA ARITMETIČKE
SREDINE

$$M = \frac{m}{\sqrt{n}} = \frac{\sigma}{\sqrt{n-1}} = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n(n-1)}}$$

Važno: $M = \frac{m}{\sqrt{n}}$

Srednja pogreška, nepouzdanost

- iskoristimo ove rezultate da nađemo h iz Gaussovog zakona pogrešaka
- za $n \rightarrow \infty$, $m \rightarrow \sigma$ ali uzimamo m (koja sadrži X) a ne σ kao relevantnu veličinu

$$m^2 \underset{n \gg 1}{\approx} \frac{\sum_{i=1}^n v_i^2}{n} \rightarrow \int_{-\infty}^{\infty} v^2 \varphi(v) dv = \frac{1}{2h^2}$$

pa je stoga:

$$h = \frac{1}{m\sqrt{2}}$$

Srednja pogreška, nepouzdanost

Važno! Rezultat se uvijek izražava kao:

$$X = \bar{x} \pm M$$

- tako izražen rezultat kazuje da je X u intervalu $(\bar{x} - M, \bar{x} + M)$ s vjerojatnošću 68%, u intervalu $(\bar{x} - 2M, \bar{x} + 2M)$ s vjerojatnošću 95%, u intervalu $(\bar{x} - 3M, \bar{x} + 3M)$ s vjerojatnošću 99%.
- mjera "dobrote mjerenja" je relativna nepouzdanost

$$R = \frac{M}{\bar{x}} (\cdot 100\%) \text{ i izražava se u postocima}$$

- budući da je $M \propto \frac{1}{\sqrt{n(n-1)}}$ preporučljivo je uvijek načiniti ne manje od $n = 10$ mjeranja, ali ni puno više, jer je ovisnost M o n za $n < 10$ jaka, a za $n > 10$ slaba.

Srednja pogreška, nepouzdanost

- M se uvijek zaokružuje na jednu znamenku, iznimno na dvije (ako je zadnja znamenka 5). \bar{x} se zaokružuje prema M

Primjer:

$$M = 0.0037624 \text{ cm}$$

$$\bar{x} = 0.0163274 \text{ cm}$$

$$M \rightarrow 0.004 \text{ cm}, \quad \bar{x} \rightarrow 0.016 \text{ cm} \qquad R = \frac{0.004}{0.016} \cdot 100$$


3. znamenka 3. znamenka

Pišemo: $x = (0.016 \pm 0.004) \text{ cm}$, $R = 25\%$ ili
 $x = (1.6 \pm 0.4) \cdot 10^{-2} \text{ cm}$, $R = 25\%$

Srednja pogreška, nepouzdanost

Primjer:

$$M = 0.153264 \text{ kg}$$

$$\bar{x} = 7.25434 \text{ kg}$$

$$M \rightarrow 0.15 \text{ kg}, \quad \bar{x} \rightarrow 7.26 \text{ kg}$$

$$x = (7.26 \pm 0.15) \text{ kg}, \quad R = 2\%$$