

Očekivanja

$$\mu_X = \sum_{x \in D_X} x \cdot p_X(x) = \sum_{x \in D_X} \sum_{y \in D_Y} x \cdot p(x, y) \quad ili$$

$$\mu_X = \int_{-\infty}^{\infty} x \cdot f_X(x) dx = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x \cdot f(x, y) dxdy$$

$$\mu_Y = \sum_{y \in D_Y} y \cdot p_Y(y) = \sum_{x \in D_X} \sum_{y \in D_Y} y \cdot p(x, y) \quad ili$$

$$\mu_Y = \int_{-\infty}^{\infty} y \cdot f_Y(y) dy = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} y \cdot f(x, y) dxdy$$

Momenti 2D raspodjele

Pomoćni momenti

$$m_{rs} = \sum_{x \in D_X} \sum_{y \in D_Y} x^r y^s p(x, y) \quad ili$$

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

Središnji momenti

$$M_{rs} = \sum_{x \in D_X} \sum_{y \in D_Y} (x - \mu_X)^r (y - \mu_Y)^s p(x, y) \quad ili$$

$$M_{rs} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x - \mu_X)^r (y - \mu_Y)^s f(x, y) dxdy$$

$$m_{10} = \mu_X \quad \text{očekivanja}$$

$$m_{01} = \mu_Y$$

$$M_{20} = V(X) = \sigma_X^2 \quad \text{varijance}$$

$$M_{02} = V(Y) = \sigma_Y^2$$

$$M_{11} = \sigma_{XY} = Cov(X, Y) \quad \text{kovarijanca}$$





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

Pomoćna formula

$$Cov(X, Y) = m_{11} - m_{10} \cdot m_{01} = E(X \cdot Y) - E(X)E(Y)$$

Korelacija

koeficijent korelacije:

$$Corr(X, Y) = \rho_{X,Y} = \rho = \frac{\sigma_{XY}}{\sigma_X \cdot \sigma_Y}$$

Svojstva:

1. $Corr(aX + b, cY + d) = Corr(X, Y)$
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 $\rho=-1$.

Linearna kombinacija dviju slučajnih varijabli

2D raspodjela

Slučajne varijable X_1 i X_2 koje se mogu zbrajati

Združena raspodjela vjerojatnosti $p(X_1, X_2)$

$$a_1, a_2 \in \mathbb{R}$$

Def: $Y = a_1X_1 + a_2X_2$ (linearna kombinacija)

Očekivanje linearne kombinacije

$$E(Y) = a_1E(X_1) + a_2E(X_2)$$

Varijanca linearne kombinacije

$$V(Y) = a_1^2V(X_1) + a_2^2V(X_2) + 2a_1a_2Cov(X_1, X_2)$$

Varianca razlike nezavisnih varijabli

$$V(X_1 - X_2) = V(X_1) + V(X_2) = \sigma_1^2 + \sigma_2^2$$

Varianca razlike je
zbroj varijanci,
a ne razlika!

Linearna kombinacija n slučajnih varijabli

Za bilo koji skup slučajnih varijabli X_1, X_2, \dots, X_n i konstanti

a_1, a_2, \dots, a_n , slučajna varijabla

$$Y = a_1X_1 + a_2X_2 + \dots + a_nX_n$$

zove se **linearna kombinacija** X_i -ova.

Očekivanje linearne kombinacije

$$E(a_1X_1 + a_2X_2 + \dots + a_nX_n) = a_1E(X_1) + a_2E(X_2) + \dots + a_nE(X_n)$$

Varianca linearne kombinacije

$$V(a_1X_1 + a_2X_2 + \dots + a_nX_n) = a_1^2V(X_1) + a_2^2V(X_2) + \dots + a_n^2V(X_n) + \sum_i \sum_{j \neq i} a_j a_j Cov(X_i, X_j)$$

za nezavisne varijable:

$$V(a_1X_1 + a_2X_2 + \dots + a_nX_n) = a_1^2V(X_1) + a_2^2V(X_2) + \dots + a_n^2V(X_n)$$

Slučajni uzorak

U mnogim statističkim problemima vrijednosti u uzorku od n elemenata $\{x_1, x_2, \dots, x_n\}$ iz neke populacije mogu se zamisliti kao opažene vrijednosti niza od n jednakih slučajnih varijabli.

Neka su X_1, X_2, \dots, X_n takve nove slučajne varijable.

Def:

Neka su X_1, X_2, \dots, X_n slučajne varijable. Kažemo da one čine **slučajni uzorak** veličine n , ako su varijable X_i

(a) nezavisne i

(b) imaju iste raspodjele vjerojatnosti.

Kažemo da su X_i **nezavisne i identično raspodijeljene**.

primjena:

- mjerjenje fizikalne veličine (populacija je beskonačna)
- uzimanje uzorka s povratom
- uzimanje uzorka iz velike populacije

Prosjek \bar{X} slučajnog uzorka

= slučajna varijabla

= linearna kombinacija slučajnih varijabli X_i

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

Očekivanje prosjeka $E(\bar{X}) = \mu$

$$\text{Varianca prosjeka } V(\bar{X}) = \frac{\sigma^2}{n} \quad \sigma_{\bar{X}} = \frac{\sigma}{\sqrt{n}}$$

Total T_0 slučajnog uzorka

= slučajna varijabla

= linearna kombinacija slučajnih varijabli X_i

$$T_0 = \sum_{i=1}^n X_i$$

Očekivanje totala $E(T_0) = n\mu$


$$\text{Varianca totala } V(T_0) = n\sigma^2 \quad \sigma_{T_0} = \sigma\sqrt{n}$$

Raspodjela prosjeka uzorka

Neka je uzorak sastavljen od slučajnih varijabli proizvoljna oblika raspodjele!

Kakav će biti *oblik raspodjele* prosjeka (ili totala)?

Ako je uzorak sastavljen od normalnih slučajnih varijabli, onda je i prosjek normalno raspodijeljen



Raspodjela prosjeka i totala u općenitom slučaju

- Izračun pomoću pravila vjerojatnosti ili
- Simulacijski eksperiment


Primjer 1 (diskretna raspodjela):

Prodavač automobila prodaje 50% automobila niže klase po cijeni 65.000 kuna, 35% automobila srednje klase po 100.000 kuna i 15% automobila više klase po 135.000 kuna.

Definirajmo slučajnu varijablu

X =prihod od prodaje jednog automobila (u tisućama kuna)

x	$p(x)$
65	0,5
100	0,35
135	0,15



Određenog dana najavila su se dva kupca. Neka su slučajne varijable:



X_1 =prihod od prvog kupca
 X_2 =prihod od drugog kupca

Tablica mogućih prihoda:




x_1	x_2	$p(x_1, x_2)$	$x_1 + x_2$	\bar{x}
65	65	0,25	130	65
65	100	0,175	165	82,5
65	135	0,075	200	100
100	65	0,175	165	82,5
100	100	0,1225	200	100
100	135	0,0525	235	117,5
135	65	0,075	200	100
135	100	0,0525	235	117,5
135	135	0,0225	270	135

Slučajna varijabla \bar{X} raspodijeljena je ovako:

\bar{x}	$p(\bar{x})$
65	0,25
82,5	0,35
100	0,2725
117,5	0,105
135	0,0225



+



Primjer 2 (kontinuirana raspodjela):


Na putu do posla čekam autobus koji vozi svakih 10 minuta, a zatim tramvaj koji također vozi svakih 10 minuta.

Neka su slučajne varijable:


X_1 = vrijeme čekanja autobusa

X_2 = vrijeme čekanja tramvaja


$$f(x_1) = \begin{cases} 1/10 & , 0 \leq x_1 \leq 10 \\ 0 & , x_1 < 0 \text{ ili } x_1 > 10 \end{cases}$$



$$f(x_2) = \begin{cases} 1/10 & , 0 \leq x_2 \leq 10 \\ 0 & , x_2 < 0 \text{ ili } x_2 > 10 \end{cases}$$



$$T_0 = \text{ukupno vrijeme čekanja} = X_1 + X_2$$



<http://www.stat.sc.edu/~west/javahtml/CLT.html>

Središnji granični teorem (CLT)

Neka je X_1, X_2, \dots, X_n slučajni uzorak bilo koje raspodjele s očekivanjem μ i standardnom devijacijom σ . Ako je n dovoljno velik, \bar{X} ima približno normalnu raspodjelu s očekivanjem

$$\mu_{\bar{X}} = \mu \text{ i standardnom devijacijom } \sigma_{\bar{X}} = \frac{\sigma}{\sqrt{n}}.$$

T_0 ima također približno normalnu raspodjelu s očekivanjem $\mu_{T_0} = n\mu$ i standardnom devijacijom $\sigma_{T_0} = \sqrt{n} \cdot \sigma$.

