

Náhodný vektor

V praxi veľakrát nestačí popisovať výsledok experimentu len pomocou jednej premennej, ale je nutné uvažovať väčší počet premenných (napríklad zisťujeme dĺžku, hrúbku a hmotnosť nejakej súčiastky). Teda na študovaných objektoch zisťujeme súčasne hodnoty niekoľkých náhodných premenných X_1, X_2, \dots, X_n , ktoré spolu logicky súvisia. Môžeme ich považovať za zložky n -rozmerného náhodného vektora $(X_1, X_2, \dots, X_n)^T$ alebo n -rozmernej náhodnej premennej (X_1, X_2, \dots, X_n) .

V tomto prípade existujú tri typy rozdelení: *združené*, *marginálne* a *podmienené*. Uvedené typy budeme prezentovať na dvojrozmernej náhodnej premennej.

Definícia dvojrozmerného rozdelenia

Združené rozdelenie

Nech (X, Y) je dvojrozmerná náhodná premenná, potom jej rozdelenie definujeme pomocou *združenej (dvojrozmernej) distribučnej funkcie*

$$F(x, y) = P(X \leq x, Y \leq y),$$

ktorá udáva pravdepodobnosť súčasného nastatia dvoch udalostí $\{X \leq x\}$ a $\{Y \leq y\}$.

Vlastnosti združenej distribučnej funkcie

$$0 \leq F(x, y) \leq 1 \text{ pre ľubovoľné reálne čísla } x \text{ a } y$$

$$F(-\infty, y) = F(x, -\infty) = F(-\infty, -\infty) = \lim_{\substack{x \rightarrow -\infty \\ y \rightarrow -\infty}} F(x, y) = 0$$

$$F(\infty, \infty) = \lim_{\substack{x \rightarrow \infty \\ y \rightarrow \infty}} F(x, y) = 1$$

$$P(x_1 < X \leq x_2, y_1 < Y \leq y_2) = F(x_2, y_2) - F(x_2, y_1) - F(x_1, y_2) + F(x_1, y_1)$$

$F(x, y)$ je neklesajúca funkcia vzhľadom k obidvom premenným

Marginálne rozdelenia

Marginálna distribučná funkcia, ktorú odvodíme zo združenej distribučnej funkcie $F(x, y)$, je definovaná pre náhodnú premennú X vzťahom

$$F_1(x) = P(X \leq x) = P(X \leq x, Y \leq \infty) = F(x, \infty)$$

a pre náhodnú premennú Y

$$F_2(y) = P(Y \leq y) = P(X \leq \infty, Y \leq y) = F(\infty, y)$$

kde

$$F(x, \infty) = \lim_{y \rightarrow \infty} F(x, y) \text{ a } F(\infty, y) = \lim_{x \rightarrow \infty} F(x, y)$$

Podmienené rozdelenia

Podmienená distribučná funkcia náhodnej premennej X , za podmienky, že pre náhodnú premennú Y platí $Y = y$, je definovaná vzťahom

$$F(x|y) = P(X \leq x | Y = y)$$

a podmienená distribučná funkcia náhodnej premennej Y , za podmienky, že náhodná premenná $X = x$, je všeobecne definovaná vzťahom

$$F(y|x) = P(Y \leq y | X = x)$$

Spojité a diskrétné rozdelenie dvojrozmernej náhodnej premennej

Diskrétné združené rozdelenie

Združená pravdepodobnostná funkcia

Dvojrozmerná náhodná premenná (X, Y) má *diskrétné združené rozdelenie pravdepodobnosti*, ak nadobúda hodnoty (x_i, y_j) ($i = 1, 2, \dots, m$, $j = 1, 2, \dots, n$) s kladnými pravdepodobnosťami

$$p_{ij} = p(x_i, y_j) = P(X = x_i, Y = y_j)$$

pre ktoré platí

$$\sum_{i=1}^m \sum_{j=1}^n p_{ij} = 1$$

Funkcia sa nazýva *združená pravdepodobnostná funkcia*.

Diskrétné dvojrozmerné rozdelenie možno vyjadriť aj vo forme dvojrozmernej tabuľky alebo grafu.

Združená distribučná funkcia

Združená distribučná funkcia (tiež distribučná funkcia dvojrozmernej náhodnej premennej) je definovaná vzťahom

$$F(x, y) = \sum_{x_i \leq x} \sum_{y_j \leq y} P(X = x_i, Y = y_j)$$

Diskrétné marginálne rozdelenia

Rozdelenie jednej zložky X resp. Y dvojrozmernej náhodnej premennej (X, Y) , ktoré získame z jej združeného rozdelenia pravdepodobnosti definovaného v (3.11) a (3.12) nazývame marginálne (okrajové) rozdelenie pravdepodobnosti.

Marginálna pravdepodobnostná funkcia

Marginálnu pravdepodobnostnú funkciu premennej X resp. Y dostaneme z (3.11)

$$p_{i\bullet} = \sum_{j=1}^n p_{ij} = \sum_{j=1}^n p(x_i, y_j) = \sum_{j=1}^n P(X = x_i, Y = y_j)$$

$$p_{\bullet j} = \sum_{i=1}^m p_{ij} = \sum_{i=1}^m p(x_i, y_j) = \sum_{i=1}^m P(X = x_i, Y = y_j)$$

Marginálnou pravdepodobnostnou funkciou je definované rozdelenie náhodnej premennej X , (prvej zložky dvojrozmernej náhodnej premennej) resp. rozdelenie náhodnej premennej Y .

Marginálna distribučná funkcia

Distribučné funkcie, príslušné uvedeným marginálnym rozdeleniam pravdepodobnosti, sú dané vzťahmi

$$F_1(x) = \sum_{x_i \leq x} p_{i\bullet} = \sum_{x_i \leq x} \sum_{j=1}^n p(x_i, y_j) = \sum_{x_i \leq x} \sum_{j=1}^n P(X = x_i, Y = y_j)$$

$$F_2(y) = \sum_{y_j \leq y} p_{\bullet j} = \sum_{y_j \leq y} \sum_{i=1}^m p(x_i, y_j) = \sum_{y_j \leq y} \sum_{i=1}^m P(X = x_i, Y = y_j)$$

Marginálnou distribučnou funkciou je definované rozdelenie náhodnej premennej X , (prvej zložky dvojrozmernej náhodnej premennej) a marginálnou distribučnou funkciou resp. rozdelenie náhodnej premennej Y (druhej zložky dvojrozmernej náhodnej premennej).

Diskrétna podmienená rozdelenia

Z dvojrozmernej diskkrétnej náhodnej premennej (X, Y) , ktorá nadobúda hodnoty (x_i, y_j) ($i = 1, 2, \dots, m$, $j = 1, 2, \dots, n$) s kladnými pravdepodobnosťami možno získať podmienené rozdelenia.

Podmienené pravdepodobnostné funkcie

Podmienená pravdepodobnostná funkcia náhodnej premennej X za podmienky, že náhodná premenná Y nadobudla hodnotu y_j , je definovaná vzťahom

$$p(x_i|y_j) = \frac{P(X = x_i, Y = y_j)}{P(Y = y_j)} = \frac{P(X = x_i, Y = y_j)}{\sum_{i=1}^m P(X = x_i, Y = y_j)} = \frac{p_{ij}}{p_{\bullet j}}$$

a podmienená pravdepodobnostná funkcia náhodnej premennej Y , za podmienky, že náhodná premenná X nadobudla hodnotu x_i , je definovaná vzťahom

$$p(y_j|x_i) = \frac{P(X = x_i, Y = y_j)}{P(X = x_i)} = \frac{P(X = x_i, Y = y_j)}{\sum_{j=1}^n P(X = x_i, Y = y_j)} = \frac{p_{ij}}{p_{i\bullet}}$$

Podmienené distribučné funkcie

Podmienená distribučná funkcia náhodnej premennej X za podmienky, že náhodná premenná Y nadobudla hodnotu y_j , je definovaná vzťahom

$$F_1(x|y_j) = \sum_{x_i \leq x} p(x_i|y_j) = \frac{\sum_{x_i \leq x} P(X = x_i, Y = y_j)}{\sum_{i=1}^m P(X = x_i, Y = y_j)} = \frac{\sum_{x_i \leq x} p_{ij}}{p_{\bullet j}}$$

a podmienená distribučná funkcia náhodnej premennej Y , za podmienky, že náhodná premenná X nadobudla hodnotu x_i , je definovaná vzťahom

$$F_2(y|x_i) = \sum_{y_j \leq y} p(y_j|x_i) = \frac{\sum_{y_j \leq y} P(X = x_i, Y = y_j)}{\sum_{j=1}^n P(X = x_i, Y = y_j)} = \frac{\sum_{y_j \leq y} p_{ij}}{p_{i\bullet}}$$

Spojité združené rozdelenie

Dvojrozmerná náhodná premenná (X, Y) má *spojité združené rozdelenie pravdepodobnosti*, ak existuje nezáporná reálna funkcia dvoch premenných $f(x, y)$ taká, že pre každé reálne x a y sa dá dvojrozmerná distribučná funkcia vyjadriť v tvare

$$F(x, y) = P(X \leq x, Y \leq y) = \int_{-\infty}^x \int_{-\infty}^y f(x, y) dx dy, \quad (1.47)$$

pričom platí, že

$$F(\infty, \infty) = \lim_{\substack{x \rightarrow \infty \\ y \rightarrow \infty}} F(x, y) = P(X \leq \infty, Y \leq \infty) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) dx dy = 1$$

$$f(x, y) = \frac{\partial^2 F(x, y)}{\partial x \partial y} \text{ pre všetky } (x, y) \text{ kde existuje derivácia}$$

$$P(x_1 < X \leq x_2, y_1 < Y \leq y_2) = \int_{x_1}^{x_2} \int_{y_1}^{y_2} f(x, y) dx dy$$

Funkcia $f(x, y)$ sa nazýva *združená funkcia hustoty*.

Spojité marginálne rozdelenia

Marginálne hustoty

Marginálne hustoty rozdelenia pravdepodobnosti náhodnej premennej X resp. Y sú definované vzťahmi

$$f_1(x) = \int_{-\infty}^{\infty} f(x, y) dy \quad \text{resp.} \quad f_2(y) = \int_{-\infty}^{\infty} f(x, y) dx$$

Marginálne distribučné funkcie

Marginálne distribučné funkcie náhodnej premennej X resp. Y sú definované vzťahmi

$$F_1(x) = \int_{-\infty}^x f_1(x) dx = \int_{-\infty}^x \left(\int_{-\infty}^{\infty} f(x, y) dy \right) dx$$

$$F_2(y) = \int_{-\infty}^y f_2(y) dy = \int_{-\infty}^y \left(\int_{-\infty}^{\infty} f(x, y) dx \right) dy$$

Poznámka. Ak je známa združená distribučná funkcia $F(x, y)$ resp. združená hustota pravdepodobnosti $f(x, y)$, vieme vždy nájsť marginálne distribučné funkcie $F_1(x)$, $F_2(y)$ aj marginálne hustoty $f_1(x)$, $f_2(y)$. Opačné tvrdenie neplatí.

Spojité podmienené rozdelenia

Nech (X, Y) je spojitá dvojrozmerná náhodná premenná so združenou hustotou pravdepodobnosti $f(x, y)$ a marginálnymi hustotami $f_1(x)$, $f_2(y)$. Potom rozdelenie jednej premennej, za predpokladu, že druhá premenná nadobudla konkrétnu hodnotu sa nazýva *podmienené rozdelenie*.

Podmienená hustota pravdepodobnosti

Podmienená hustota pravdepodobnosti $f_1(x|y)$ premennej X , za podmienky, že $Y = y$, je daná vzťahom

$$f_1(x|y) = \frac{f(x, y)}{f_2(y)} \quad \text{pre } f_2(y) > 0$$

a podmienená hustota pravdepodobnosti $f_2(y|x)$ premennej Y , za podmienky, že $X = x$, je daná vzťahom

$$f_2(y|x) = \frac{f(x, y)}{f_1(x)} \quad \text{pre } f_1(x) > 0.$$

Združenú funkciu hustoty $f(x, y)$ môžeme potom vyjadriť ako súčin marginálnej hustoty $f_1(x)$ resp. $f_2(y)$ s podmienenou hustotou $f_2(y|x)$ resp. $f_1(x|y)$, t. j

$$f(x, y) = f_2(y)f_1(x|y) = f_1(x)f_2(y|x)$$

Podmienená distribučná funkcia

Podmienená distribučná funkcia $F_1(x|y)$ premennej X , za podmienky, že $Y = y$, je daná vzťahom

$$F_1(x|y) = \frac{\int_{-\infty}^x f(x, y) dx}{f_2(y)} \quad \text{pre } f_2(y) > 0.$$

Podmienná distribučná funkcia $F_2(y|x)$ premennej Y , za podmienky, že $X = x$, je daná vzťahom

$$F_2(y|x) = \frac{\int_{-\infty}^y f(x, y) dy}{f_1(x)} \quad \text{pre } f_1(x) > 0$$

Nezávislosť dvoch náhodných premenných

Nech (X, Y) je dvojrozmerná náhodná premenná, ktorej združená distribučná funkcia je $F(x, y) = P(X \leq x, Y \leq y)$ a marginálne distribučné funkcie sú $F_1(x) = P(X \leq x)$ a $F_2(y) = P(Y \leq y)$. Nezávislosť dvoch náhodných premenných budeme definovať pomocou nezávislosti dvoch udalostí $\{X \leq x\}$ a $\{Y \leq y\}$, pre ľubovoľné reálne čísla x, y .

Nezávislosť náhodných premenných X a Y

Náhodné premenné X a Y sú nezávislé vtedy a len vtedy, keď pre ľubovoľné reálne čísla x, y platí:

$$P(X \leq x, Y \leq y) = P(X \leq x) \cdot P(Y \leq y)$$

t. j.

$$F(x, y) = F_1(x) \cdot F_2(y)$$

Diskrétné náhodné premenné X a Y

Pre diskrétnu dvojrozmernú náhodnú premennú (X, Y) , ktorá nadobúda hodnoty (x_i, y_j) ($i = 1, 2, \dots, m$, $j = 1, 2, \dots, n$) s kladnými pravdepodobnosťami $P(X = x_i, Y = y_j)$, sa dá dokázať, že jej zložky sú nezávislé vtedy a len vtedy, keď pre ľubovoľné reálne čísla x, y platí

$$\sum_{x_i \leq x} \sum_{y_j \leq y} P(X = x_i, Y = y_j) = \sum_{x_i \leq x} P(X = x_i) \cdot \sum_{y_j \leq y} P(Y = y_j)$$

čo je ekvivalentné s tým, že združená pravdepodobnostná funkcia sa dá vyjadriť ako súčin marginálnych t. j. pre (x_i, y_j) ($i = 1, 2, \dots, m$, $j = 1, 2, \dots, n$) platí

$$P(X = x_i, Y = y_j) = P(X = x_i) \cdot P(Y = y_j)$$

Poznámka. Dajú odvodiť ekvivalentné vzťahy pre nezávislosť:

$$p(x|y) = p_1(x) \text{ a } p(y|x) = p_2(y).$$

Spojité náhodné premenné X a Y

Pre spojitú dvojrozmernú náhodnú premennú (X, Y) so združenou hustotou pravdepodobnosti $f(x, y)$, marginálnymi hustotami $f_1(x)$ resp. $f_2(y)$ a podmienenými hustotami pravdepodobnosti $f_1(x|y)$ resp. $f_2(y|x)$, sa dá dokázať, že jej zložky X a Y sú nezávislé vtedy a len vtedy, keď pre ľubovoľné reálne čísla x, y platí

$$f(x, y) = f_1(x) \cdot f_2(y)$$

čo je ekvivalentné so vzťahmi

$$f_1(x|y) = f_1(x) \text{ a } f_2(y|x) = f_2(y)$$

Charakteristiky dvojrozmerného náhodného vektora

Nech náhodné premenné X a Y , ktoré sú zložkami náhodného vektora $(X, Y)^T$, majú stredné hodnoty $E(X) = \mu_x$, $E(Y) = \mu_y$ a rozptyly $D(X) = \sigma_x^2$, $D(Y) = \sigma_y^2$.

Vektor stredných hodnôt

Vektor stredných hodnôt náhodného vektora $(X, Y)^T$ je definovaný ako vektor:

$$\boldsymbol{\mu} = (\mu_x, \mu_y)^T$$

Stredná hodnota a rozptyl funkcie náhodného vektora

Nech funkcia náhodného vektora $(X, Y)^T$ je $h(X, Y)$, čo je jednorozmerná náhodná premenná.

Diskrétny náhodný vektor

Pre diskrétny náhodný vektor $(X, Y)^T$, ktorý nadobúda hodnoty (x_i, y_j) ($i=1, 2, \dots, m$, $j=1, 2, \dots, n$) s kladnými pravdepodobnosťami $p(x_i, y_j) = P(X = x_i, Y = y_j)$ je *stredná hodnota premennej* $h(X, Y)$

$$E(h(X, Y)) = \sum_{i=1}^m \sum_{j=1}^n h(x_i, y_j) p(x_i, y_j)$$

a *rozptyl premennej* $h(X, Y)$

$$D(h(X, Y)) = \sum_{i=1}^m \sum_{j=1}^n h^2(x_i, y_j) p(x_i, y_j) - E^2(h(X, Y))$$

Spojité náhodný vektor

Pre spojité náhodný vektor $(X, Y)^T$, so združenou hustotou pravdepodobnosti $f(x, y)$, je *stredná hodnota premennej* $h(X, Y)$

$$E(h(X, Y)) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} h(x, y) f(x, y) dx dy$$

a *rozptyl premennej* $h(X, Y)$

$$D(h(X, Y)) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} h^2(x, y) f(x, y) dx dy - E^2(h(X, Y))$$

Podmienené stredné hodnoty

Stredná hodnota podmieneného rozdelenia sa nazýva *podmienená stredná hodnota*.

Diskrétny náhodný vektor

Pre diskrétny náhodný vektor $(X, Y)^T$, ktorý nadobúda hodnoty (x_i, y_j) ($i = 1, 2, \dots, m$, $j = 1, 2, \dots, n$) s kladnými pravdepodobnosťami $p(x_i, y_j) = P(X = x_i, Y = y_j)$, je *podmienená stredná hodnota premennej X*, za podmienky $Y = y_j$ rovná

$$E(X|Y = y_j) = \sum_{i=1}^m x_i p(x_i|y_j)$$

a *podmienená stredná hodnota premennej Y* za podmienky $X = x_i$

$$E(Y|X = x_i) = \sum_{j=1}^n y_j p(y_j|x_i)$$

Spojité náhodný vektor

Pre spojité náhodný vektor $(X, Y)^T$, so združenou hustotou pravdepodobnosti $f(x, y)$, je *podmienená stredná hodnota premennej X*, za podmienky $Y = y$ rovná

$$E(X|y) = E(X|Y = y) = \int_{-\infty}^{\infty} x f_1(x|y) dx$$

a *podmienená stredná hodnota premennej Y* za podmienky, že $X = x$

$$E(Y|x) = E(Y|X = x) = \int_{-\infty}^{\infty} y f_2(y|x) dy$$

Poznámka. Stredná hodnota (3.47) podmieneného rozdelenia premennej X závisí od podmienky (hodnoty premennej Y) a je teda jej funkciou : $E(X|y) = E(X|Y = y) = g_2(y)$. Táto funkcia sa nazýva *regresná funkcia* premennej X vzhľadom k Y a ukazuje priebeh závislosti X od Y . Podobne je definovaná závislosť Y

od X ako *regresná funkcia* premennej Y vzhľadom k X , t. j.
 $E(Y|x) = E(Y|X = x) = g_1(x)$.

Poznámka. Ak sú premenné X a Y nezávislé, tak $E(X|y) = E(X)$ a $E(Y|x) = E(Y)$.

Podmienené rozptyly

Rozptyl podmieneného rozdelenia sa nazýva *podmienený rozptyl*.

Diskrétny náhodný vektor

Pre diskrétny náhodný vektor $(X, Y)^T$, ktorý nadobúda hodnoty (x_i, y_j) ($i = 1, 2, \dots, m$,
 $j = 1, 2, \dots, n$) s kladnými pravdepodobnosťami $p(x_i, y_j) = P(X = x_i, Y = y_j)$ je
podmienený rozptyl premennej X za podmienky $Y = y_j$

$$D(X|Y = y_j) = \sum_{i=1}^m [x_i - E(X|Y = y_j)]^2 p(x_i|y_j)$$

a *podmienený rozptyl premennej Y za podmienky $X = x_i$*

$$D(Y|X = x_i) = \sum_{j=1}^n [y_j - E(Y|X = x_i)]^2 p(y_j|x_i)$$

Spojité náhodný vektor

Pre spojité náhodný vektor $(X, Y)^T$ so združenou hustotou pravdepodobnosti $f(x, y)$,
 podmienenými hustotami $f_1(x|y)$ a $f_2(y|x)$ je *podmienený rozptyl premennej X za
 podmienky $Y = y$*

$$D(X|y) = D(X|Y = y) = \int_{-\infty}^{\infty} [x - E(X|Y)]^2 f_1(x|y) dx$$

a *podmienený rozptyl premennej Y za podmienky, že $X = x$*

$$D(Y|x) = D(Y|X = x) = \int_{-\infty}^{\infty} [y - E(Y|X)]^2 f_2(y|x) dy$$

Poznámka. Analogicky ako podmienená stredná hodnota aj podmienený rozptyl premennej X je funkciou hodnoty premennej Y t. j. $D(X|y) = D(X|Y = y) = d_2(y)$. Táto funkcia sa nazýva *skedastická* a jej tvar charakterizuje menlivosť rozptylu premennej X v závislosti od hodnôt y . Podobne je definovaná závislosť podmieneného rozptylu premennej Y od hodnôt premennej X , t. j. $D(Y|x) = D(Y|X = x) = d_1(x)$.

Poznámka. Dôležitú úlohu v teórii pravdepodobnosti a v štatistike hrajú rozdelenia, ktorých podmienené rozptyly nezávisia od podmienky, t. j. majú konštantnú skedastickú funkciu. Takéto rozdelenia sa nazývajú *homoskedastické*. V opačnom prípade ide o *heteroskedastické rozdelenia*.

Kovariancia

Kovariancia je miera lineárnej závislosti dvoch náhodných premenných X a Y definovaná vzťahom

$$\text{cov}(X, Y) = E(X \cdot Y) - E(X) \cdot E(Y)$$

Kovariancia nadobúda hodnoty z intervalu $(-\infty, \infty)$.

Korelačný koeficient

Korelačný koeficient je miera lineárnej závislosti (korelačnej) dvoch náhodných premenných X a Y definovaná vzťahom

$$\rho(X, Y) = \frac{\text{cov}(X, Y)}{\sigma_x \cdot \sigma_y}$$

kde

$$\sigma_x = \sqrt{D(X)}, \quad \sigma_y = \sqrt{D(Y)}.$$

Vlastnosti korelačného koeficienta:

- ρ nadobúda hodnoty z intervalu $[-1, 1]$;
- ak $\rho = 1$, ide o priamu lineárnu (t. j. funkčnú) závislosť;
- ak $\rho = -1$ ide o nepriamu lineárnu (t. j. funkčnú) závislosť;
- ak $\rho = 0$ vieme vo všeobecnosti povedať iba to, že náhodné premenné sú nekorelované

Poznámka. Pre nezávislé náhodné premenné X a Y platí vždy, že $\rho(X, Y) = 0$. Opačné tvrdenie neplatí všeobecne. Len v prípade dvojrozmerného normálneho rozdelenia náhodného vektora $(X, Y)^T$ platí, že: $\rho(X, Y) = 0$ vtedy a len vtedy, ak sú náhodné premenné X a Y nezávislé.

Kovariančná matica

Kovariančná matica náhodného vektora $(X, Y)^T$ je definovaná takto:

$$\mathbf{\Sigma} = (\sigma_{ij}) = \begin{pmatrix} \sigma_x^2 & \sigma_{xy} \\ \sigma_{yx} & \sigma_y^2 \end{pmatrix}$$

kde

σ_{xy} ($= \sigma_{yx}$) je kovariancia medzi zložkami náhodného vektora;

σ_x^2 , σ_y^2 sú rozptyly jednotlivých zložiek náhodného vektora.

Korelačná matica

Korelačná matica náhodného vektora $(X, Y)^T$ je definovaná takto:

$$(\rho_{ij}) = \begin{pmatrix} 1 & \rho_{xy} \\ \rho_{yx} & 1 \end{pmatrix}$$

kde

ρ_{xy} ($= \rho_{yx}$) je korelačný koeficient medzi zložkami náhodného vektora.

Vlastnosti stredných hodnôt a rozptylov

Nech $a, b, c, k_i, i = 1, 2, \dots, n$ sú reálne čísla (konštanty) a nech $X, X_i, i = 1, 2, \dots, n$ sú spojité náhodné premenné, potom platí:

$$E(aX + b) = aE(X) + b;$$

$$D(aX + b) = a^2D(X);$$

$$D(X) = E(X^2) - [E(X)]^2;$$

$$E(k_1X_1 + k_2X_2 + \dots + k_nX_n) = \sum_{i=1}^n k_i E(X_i);$$

$$D(k_1X_1 + k_2X_2 + \dots + k_nX_n) = \sum_{i=1}^n k_i^2 D(X_i) + \sum_{i=1}^n \sum_{j=1}^n k_i k_j \text{cov}(X_i, X_j);$$

$$D(X_1 \pm X_2) = D(X_1) + D(X_2) \pm 2 \cdot \text{cov}(X_1, X_2).$$

Keď okrem vyššie uvedených predpokladov sú náhodné premenné X_1, X_2, \dots, X_n aj nezávislé, potom platí:

$$E(X_1 \cdot X_2 \cdot \dots \cdot X_n) = E(X_1) \cdot E(X_2) \cdot \dots \cdot E(X_n);$$

$$D(k_1X_1 + k_2X_2 + \dots + k_nX_n) = \sum_{i=1}^n k_i^2 D(X_i).$$

Rozdelenie viacrozmernej náhodnej premennej

Združené rozdelenie

Združená distribučná funkcia

Združená distribučná funkcia (tiež distribučná funkcia viacrozmernej náhodnej premennej) je definovaná vzťahom

$$F(x_1, x_2, \dots, x_n) = P(X_1 \leq x_1, X_2 \leq x_2, \dots, X_n \leq x_n)$$

Táto funkcia vyjadruje pravdepodobnosť súčasného nastatia n udalostí uvedených na pravej strane rovnosti.

Združená funkcia hustoty

Združená funkcia hustoty (nazývaná tiež funkcia hustoty viacrozmernej náhodnej premennej) $f(x_1, x_2, \dots, x_n)$ je funkcia, pre ktorú platí

$$F(x_1, x_2, \dots, x_n) = \int_{-\infty}^{x_1} \int_{-\infty}^{x_2} \dots \int_{-\infty}^{x_n} f(x_1, x_2, \dots, x_n) dx_1 dx_2 \dots dx_n$$

Marginálne rozdelenia

Marginálna distribučná funkcia náhodnej premennej X_i

Rozdelenie jednej premennej X_i , ktoré získame zo združeného rozdelenia náhodného vektora $(X_1, X_2, \dots, X_n)^T$, sa nazýva *marginálne rozdelenie*. Marginálna distribučná funkcia pre X_i ($i = 1, 2, \dots, n$) je definovaná vzťahom

$$F_i(x_i) = P(X_1 \leq \infty, \dots, X_i \leq x_i, \dots, X_n \leq \infty) =$$

$$= \int_{-\infty}^{\infty} \dots \int_{-\infty}^{x_i} \dots \int_{-\infty}^{\infty} f(x_1, x_2, \dots, x_n) dx_1 dx_2 \dots dx_n$$

Marginálna funkcia hustoty náhodnej premennej X_i

Marginálnu hustotu premennej X_i vypočítame tak, že funkciu $f(x_1, x_2, \dots, x_n)$ integrujeme cez všetky premenné, okrem x_i , na ich príslušných definičných oboroch.

Vzájomná nezávislosť zložiek náhodného vektora

Majme teraz n -rozmerný náhodný vektor $(X_1, X_2, \dots, X_n)^T$. Pre náhodný vektor s viac ako dvomi zložkami, možno okrem nezávislosti dvojíc, definovať aj vzájomnú nezávislosť. Náhodné premenné X_1, X_2, \dots, X_n sú vzájomne nezávislé vtedy a len vtedy, ak platí:

$$f(x_1, x_2, \dots, x_n) = f_1(x_1)f_2(x_2)\dots f_n(x_n)$$

čo je ekvivalentné s tým, že

$$F(x_1, x_2, \dots, x_n) = F_1(x_1)F_2(x_2)\dots F_n(x_n)$$

kde

$f_i(x_i)$ resp. $F_i(x_i)$ sú marginálne funkcie hustoty resp. marginálne distribučné funkcie náhodných premenných (meraných veličín) X_i , ($i = 1, 2, \dots, n$).

Kovariančná matica

Kovariančná matica náhodného vektora $(X_1, X_2, \dots, X_n)^T = \mathbf{X}^T$ je

$$\mathbf{\Sigma} = \begin{pmatrix} \sigma_{11} & \sigma_{12} & \cdots & \sigma_{1n} \\ \sigma_{21} & \sigma_{22} & \cdots & \sigma_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{n1} & \sigma_{n2} & \cdots & \sigma_{nn} \end{pmatrix}$$

kde

$\sigma_{ij} = \text{cov}(X_i, X_j)$, $i, j = 1, 2, \dots, n$, $i \neq j$ sú kovariancie medzi zložkami náhodného vektora;

$\sigma_{ii} = \text{cov}(X_i, X_i) = \sigma_i^2$, $i = 1, 2, \dots, n$ sú rozptyly jednotlivých zložiek náhodného vektora.

Kovariančná matica je štvorcová a symetrická matica. Keď sú zložky náhodného vektora po dvoch nezávislé alebo aspoň nekorelované, potom kovariančná matica je diagonálna t.j. nediagonálne prvky sú rovné 0. Ak navyše, rozptyly všetkých premenných X_i ($i = 1, 2, \dots, n$) sú rovnaké, t.j. $D(x_i) = \sigma^2$ ($i = 1, 2, \dots, n$), potom kovariančná matica náhodného vektora $(X_1, X_2, \dots, X_n)^T = \mathbf{X}^T$ má tvar $\Sigma = \sigma^2 \mathbf{E}$, kde \mathbf{E} je jednotková matica, t. j. diagonálne prvky sú rovné 1 a nediagonálne sú rovné 0.

Charakteristiky lineárnych foriem

Nech k_i , $i = 1, 2, \dots, n$ sú reálne čísla, z ktorých aspoň jedno, je rôzne od nuly, t. j.

$\sum_{i=1}^n k_i^2 > 0$, potom náhodná premenná

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

je *lineárnou formou* náhodných premenných X_i ($i = 1, 2, \dots, n$).

Označme strednú hodnotu náhodnej premennej X_i ako μ_i , jej rozptyl σ_i^2 a kovarianciu náhodných premenných X_i, X_j ako σ_{ij} .

Stredná hodnota premennej X

$$E(X) = \sum_{i=1}^n k_i \mu_i;$$

a jej rozptyl

$$D(X) = \sum_{i=1}^n k_i^2 \sigma_i^2 + \sum_{\substack{i=1 \\ i \neq j}}^n \sum_{j=1}^n k_i k_j \sigma_{ij}$$

alebo pri použití korelačných koeficientov

$$D(X) = \sum_{i=1}^n k_i^2 \sigma_i^2 + \sum_{\substack{i=1 \\ i \neq j}}^n \sum_{j=1}^n k_i k_j \sigma_i \sigma_j \rho_{ij}$$

Keď rozptyly náhodných premenných X_1, X_2, \dots, X_n sú rovnaké, t. j.

$$D(X_i) = \sigma^2, \quad i = 1, 2, \dots, n,$$

potom dostaneme

$$D(X) = \sigma^2 \sum_{i=1}^n k_i^2 + \sum_{\substack{i=1 \\ i \neq j}}^n \sum_{j=1}^n k_i k_j \sigma_{ij}$$

alebo

$$D(X) = \sigma^2 \left(\sum_{i=1}^n k_i^2 + \sum_{\substack{i=1 \\ i \neq j}}^n \sum_{j=1}^n k_i k_j \rho_{ij} \right)$$

V prípade, že náhodné premenné X_1, X_2, \dots, X_n sú po dvoch nezávislé alebo aspoň nekorelované, zjednodušia sa vzorce na tvar

$$D(X) = \sum_{i=1}^n k_i^2 \sigma_i^2$$

Majme ďalej dve lineárne formy

$$X = \sum_{i=1}^n k_i X_i, \quad \sum_{i=1}^n k_i^2 > 0$$

$$Y = \sum_{i=1}^n l_i X_i, \quad \sum_{i=1}^n l_i^2 > 0$$

vyššie uvedených náhodných premenných X_1, X_2, \dots, X_n . Ich kovariancia je

$$\sigma(X, Y) = \sum_{i=1}^n k_i l_i \sigma_i^2 + \sum_{\substack{i=1 \\ i \neq j}}^n \sum_{j=1}^n k_i l_j \sigma_{ij}$$

alebo v ekvivalentnom vyjadrení

$$\sigma(X, Y) = \sum_{i=1}^n k_i l_i \sigma_i^2 + \sum_{\substack{i=1 \\ i \neq j}}^n \sum_{j=1}^n k_i l_j \sigma_i \sigma_j \rho_{ij}$$

Keď majú premenné X_1, X_2, \dots, X_n rovnaké rozptyly $\sigma_1^2 = \sigma_2^2 = \dots = \sigma_n^2 = \sigma^2$,

kovariancia je

$$\sigma(X, Y) = \sigma^2 \sum_{i=1}^n k_i l_i + \sum_{\substack{i=1 \\ i \neq j}}^n \sum_{j=1}^n k_i l_j \sigma_{ij}$$

alebo

$$\sigma(X, Y) = \sigma^2 \left(\sum_{i=1}^n k_i l_i + \sum_{\substack{i=1 \\ i \neq j}}^n \sum_{j=1}^n k_i l_j \rho_{ij} \right)$$

Pre nekorelované náhodné premenné X_1, X_2, \dots, X_n sa vzorce redukujú na tvar

$$\sigma(X, Y) = \sigma^2 \sum_{i=1}^n k_i l_i$$

Z charakteristík jednej a dvoch lineárnych foriem ľahko odvodíme charakteristiky n rozmerného náhodného vektora $\mathbf{Y} = (Y_1, Y_2, \dots, Y_n)^T$, ktorého prvky sú lineárnymi formami prvkov iného, n -rozmerného náhodného vektora $\mathbf{X} = (X_1, X_2, \dots, X_n)^T$, t. j.

$$Y_1 = k_{11}X_1 + k_{12}X_2 + \dots + k_{1n}X_n$$

$$Y_2 = k_{21}X_1 + k_{22}X_2 + \dots + k_{2n}X_n$$

.....

$$Y_n = k_{n1}X_1 + k_{n2}X_2 + \dots + k_{nn}X_n$$

$$\sum_{j=1}^n k_{ij}^2 > 0, \quad i = 1, 2, \dots, n$$

Tento systém lineárnych foriem možno zapísať v maticovom tvare takto

$$\begin{pmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{pmatrix} = \begin{pmatrix} k_{11} & k_{12} & \cdots & k_{1n} \\ k_{21} & k_{22} & \cdots & k_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ k_{n1} & k_{n2} & \cdots & k_{nn} \end{pmatrix} \cdot \begin{pmatrix} X_1 \\ X_2 \\ \vdots \\ X_n \end{pmatrix}, \text{ t. j. } \mathbf{Y} = \mathbf{A}\mathbf{X}$$

Keď vektor \mathbf{X} má vektor stredných hodnôt $\boldsymbol{\mu}_X = (\mu_1, \mu_2, \dots, \mu_n)^T$ a kovariančnú maticu $\boldsymbol{\Sigma}_X$, potom vektor \mathbf{Y} má vektor stredných hodnôt

$$\boldsymbol{\mu}_Y = \mathbf{A}\boldsymbol{\mu}_X$$

a kovariančnú maticu

$$\boldsymbol{\Sigma}_Y = \mathbf{A}\boldsymbol{\Sigma}_X\mathbf{A}^T$$