


# Slučajne varijable i njihove raspodjele

Pri analizi inženjerskih procesa mnoge varijable i parametri mogu bitidefinirani kao slučajne varijable. Slučajne varijable su funkcije koje imaju realne vrijednosti i koje predstavljaju preslikavanje iz prostora slučajnih vrijednosti ( $S$ ) u prostor realnih brojeva ( $R$ )



# Slučajne varijable

---

- ❑ Uobičajena konvencija je da se slučajne varijable označuju s velikim slovom dok mala slova označavaju realizaciju odgovarajuće slučajne varijable. Na primjer,  $Q$  označava protok kao slučajnu varijablu dok  $q$  predstavlja vrijednost koju slučajna varijable može imat.
- ❑ Slučajne varijable mogu biti diskretne (kao broj sušnih ili kišnih dana u nekom promatranom vremenu) ili kontinuirane kao što su protok, intenzitet kiše, nivo vode, koncentracija itd.

# Osnove stohastičkih procesa

## ➤ Vjerojatnost i slučajne varijable

Za opisivanje neke kontinuirane slučajne varijable  $X$  (koje često susrećemo u tehničkim znanostima) koristimo funkciju gustoće raspodjele  $f(x)$ . Za bilo koja dva broja  $a$  i  $b$  vrijedi:

$$\int_a^b f(x)dx = P(a < X \leq b)$$

što definira vjerojatnost da se  $X$  nalazi unutar intervala  $(a, b)$ . Funkcija gustoće  $f(x)$  ima inverznu jedinicu od  $x$  te mora zadovoljavati dva ključna svojstva:

$$f(x) \geq 0 \quad -\infty < x < \infty$$

$$\int_{-\infty}^{\infty} f(x)dx = 1$$

Drugo svojstvo je vrlo važan zakon održanja u prostoru vjerojatnosti. Osim funkcije gustoće također se često za kontinuiranu slučajnu varijablu definira i funkcija sumarne raspodjele  $F(x)$  za koju vrijedi:

$$P(X \leq x) = F(x) = \int_{-\infty}^x f(y)dy$$

odnosno,

$$\frac{dF}{dx} = f(x)$$

Dakle, funkcija gustoće  $f(x)$  slučajne varijable je derivacija funkcije sumarne raspodjele  $F(x)$ .

# Funkcija raspodjele i funkcija gustoće




Figure 2.1. Cumulative probability distribution function and probability density function for a random variable  $X$ .

$$P[X \leq x] = \frac{\text{broj uzoraka } X \leq x}{\text{ukupni broj uzoraka}}$$

Sumarna funkcija raspodjele se stalno povećava i ide od 0 do 1 kako  $x$  ide ka beskonačnosti. Integrirajući funkciju gustoće  $f(x)$  dobije se sumarna raspodjela  $F(x)$

# Matematičko očekivanje ili osrednjavanje

Matematičko očekivanje slučajne varijable  $x$ , označava se velikim slovom  $E$ , i piše se kao

$$E(x) = \mu_x = \int_{-\infty}^{\infty} xf(x)dx \Rightarrow \bar{x} = \frac{1}{N} \sum_{i=1}^N x_i$$

Drugi dio gornje jednadžbe označava srednju vrijednost diskretne slučajne varijable  $x$ . Proces dobivanja srednje vrijednosti je sumiranje za diskretnu varijablu ili integracija za kontinuiranu slučajnu varijablu. Od posebnog interesa u praktičnoj primjeni su izrazi za centralne momente (momenti oko srednje vrijednosti) koji se definiraju izrazom:

ili absolutni  
momenti

$$M_i = E[(x - \mu)^i] = \int_{-\infty}^{\infty} (x - \mu)^i f(x)dx$$

$$m_i = E[x^i] = \int_{-\infty}^{\infty} x^i f(x)dx$$

Nulti centralni moment ( $i=0$ ) je jedan, prvi centralni moment ( $i=1$ ) je nula dok drugi centralni moment predstavlja mjeru rasprostiranja, disperzije funkcije gustoće oko srednje vrijednosti i naziva se varijanca,

$$\sigma^2 = \int_{-\infty}^{\infty} (x - \mu)^2 f(x)dx = E[(x - \mu)^2] \Rightarrow \text{var}(x) = \frac{1}{N-1} \sum_{i=1}^N [x_i - \bar{x}]^2$$

Drugi dio gornjeg izraza predstavlja varijancu za slučaj diskretne varijable  $x$ . Kvadratni korijen varijance je standardna devijacija, koja ima jedinicu istu kao srednja vrijednost i opisuje mjeru odstupanja oko srednje vrijednosti. Standardna devijacija će u stohastičkom modeliranju predstavljati ključnu dodatnu informaciju koja može definirati interval povjerenja ili poslužiti kao mjera onoga što se često u tehničkim znanostima koristi kao «faktor sigurnosti» pri projektiranju.

# Matematičko očekivanje ili osrednjavanje (2)

Standardna devijacija od  $x$  koja se označava s  $\sigma_x$ , dok se varijance može pisati u formi matematičkog očekivanja kao:

$$\begin{aligned} S^2 &= E\left[(x - E[x])^2\right] = E\left[x^2 - 2xE[x] + (E[x])^2\right] \\ &= E[x^2] - 2E[x]E[x] + (E[x])^2 = E[x^2] - (E[x])^2 \end{aligned}$$

Osim varijance slučajne varijable u inženjerskim problemima analize pouzdanosti i stupnja rizika vrlo su važni i slijedeći momenti. Skošenost ("skewness") ili treći moment normaliziran s  $\sigma^3$  se definira kao:

$$E\left[\frac{1}{\sigma^3}(x - m)^3\right] = \int \frac{(x - m)^3}{\sigma^3} f(x) dx = \frac{1}{N-1} \sum_{j=1}^N \frac{(x_j - m)^3}{\sigma^3}$$

Dok četvrti moment daje informaciju o spljoštenosti funkcije gustoće i normaliziran s  $\sigma^4$  iznosi:

$$E\left[\frac{1}{\sigma^4}(x - m)^4\right] = \int \frac{(x - m)^4}{\sigma^4} f(x) dx = \frac{1}{N-1} \sum_{j=1}^N \frac{(x_j - m)^4}{\sigma^4}$$

# Statistički momenti

---

## Centralni momenti

$$M_i = E[(x - \mu)^i] = \int_{-\infty}^{\infty} (x - \mu)^i f(x) dx$$

## Apsolutni ili standardni momenti

$$m_i = E[x^i] = \int_{-\infty}^{\infty} x^i f(x) dx$$

Vježba: Dokaži slijedeće relacije

$$M_2 = m_2 - m_1^2$$

$$M_3 = m_3 - 3m_1m_2 + 2m_1^3$$

$$M_4 = m_4 - 4m_1m_3 + 6m_1^2m_2 - 3m_1^4$$

# Osrednjavanja

---

Postoje tri temeljne vrste osrednjavanja:

## 1. Osrednjavanje po vremenu

$$E[A(x, t)] = \frac{1}{T} \int_{t=0}^T A(x, t) dt \qquad E[A(x, t)] = \frac{1}{N} \sum_{i=0}^N A(x, t_i)$$

## 2. Osrednjavanje po prostoru:

$$E[A(x, t)] = \frac{1}{S} \int_{x=0}^S A(x, t) dx \qquad E[A(x, t)] = \frac{1}{S} \sum_{i=0}^N A(x_i, t_i)$$

## 3. Osrednjavanje poprostoru vjerojatnosti

$$E[A(x, t)] = \frac{1}{N} \sum_{i=0}^N A_i(x, t)$$

Naj idealniji slučaj bi bio osrednjavanje po prostoru vjerojatnosti što i je slučaj kod opetovanih mjerenja nekog eksperimenta. Međutim, u primjeni kod fizikalnih procesa često se moramo zadovoljiti s druge dvije vrste osrednjavanja. Ako je vremenski period ili prostorna domena osrednjavanja dovoljno velika onda u limitu kod stacionarnih procesa sva osrednjavanja se izjednačavaju s osrednjavanjem po prostoru vjerojatnosti. Taj limit zovemo EGODICITET i označava slučaj kada je neki fizikalni proces u nekom vremenu  $T$  ili prostoru  $S$  demonstrirao sve slučajeve fluktuacija tako da sva tri osrednjavanja daju isti rezultat.



# Funkcija dviju slučajnih varijabli

---

U mnogim primjerima zanima nas zajedničko ponašanje dviju slučajnih varijabli.

Uzmimo na primjer vrijednost transmisivnosti u dvije bliske lokacije u istom vodonosniku. Želimo procijeniti kako mjerenje jedne lokacije transmisivnosti utječe na drugu. Odnosno, da li izmjerena veća transmisivnost na jednoj lokaciji daje vjerojatno i veću transmisivnost na drugoj lokaciji. Zajednička funkcija gustoće  $f(x,y)$  ima ista svojstva kao u A.2, a nadalje se može definirati i marginalna funkcija gustoće:

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

koja predstavlja vjerojatnosti pojave jedne varijable ako je druga osrednjena. Uvjetna funkcija gustoće varijable  $x$ , ako je  $y=Y$  se označava  $f(x/y)=f(x,y)/f(y)$ . Ova se funkcija se tumači kao funkcija gustoće jedne varijable uvjetno informaciji da druga varijabla  $y$  ima vrijednost  $Y$ . Na primjer, uzmimo da  $x$  i  $y$  označavaju vrijednosti transmisivnosti u dvije bliske točke. Prije uzimanja mjerenja, funkcija gustoće za  $x$  je njena marginalna funkcija A.9 osrednjena po pretpostavljenoj formi za  $f(x,y)$ . Međutim nakon mjerenja  $y$ , funkcija gustoće postaje uvjetna  $f(x/y)$ . Dakle, veća transmisivnost u  $y$  može povećati vjerojatnost pojave veće transmisivnosti i u  $x$ . U specijalnom slučaju marginalna je jednaka uvjetnoj,  $f(x/y)=f(x)$ , kada su dvije varijable nezavisne. Tada vrijedi da je zajednička funkcija gustoće jednaka produktu dviju marginalnih,  $f(x,y)=f(x)f(y)$ . Kod takvih varijabli informacija o jednoj ne utječe na prognozu druge varijable.

## Funkcija dviju slučajnih varijabli (2)

---

Operator matematičkog očekivanja se može definirati za dvije i više slučajnih varijabli na sličan način. Uzmimo za primjer dvije slučajne varijable  $x$  i  $y$  sa zajedničkom funkcijom gustoće  $f(x,y)$  i jednom determinističkom funkcijom  $g(x,y)$  koja može predstavljati neku fizikalnu povezanost tih dviju varijabli. Očekivana vrijednost, odnosno srednja vrijednost funkcije  $g(x,y)$  je

$$E[g(x, y)] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} g(x, y) f(x, y) dx dy$$

dok su ostali centralni momenti:

$$M_{i,j} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x - E[x])^i (y - E[y])^j f(x, y) dx dy$$

U slučaju dviju varijabli od posebnog značaja je centralni moment  $i=j=1$  poznat kao kovarijanca, koja se računa iz izraza:

$$C_{xy} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x - E[x])(y - E[y]) f(x, y) dx dy$$

# Korelacija

---

Normalizirani i bezdimenzionalni oblik kovarijance je korelacioni koeficijent:

$$\rho_{xy} = \frac{C_{xy}}{\sigma_x \sigma_y}$$

koji se kreće u granicama između -1 i 1. Ako su varijable  $x$  i  $y$  nezavisne tada je korelacioni koeficijent tačno 0. Suprotna tvrdnja ne vrijedi, osim ako varijable  $x$  i  $y$  nemaju Gaussovu funkciju gustoće.

**U tehničkim znanostima često susrećemo ograničen broj podataka za svaku varijablu te se nameće pitanje da li je odnos među njima značajan ili ne?**

## Korelacija (2)

---

Na primjer, da li je mjerenje atmosferskog ugljičnog dioksida i srednje temperature zraka značajno? Lako ćemo se prisjetiti da je ovo ključno pitanje koje je okupiralo znanost u ekologiji oko pitanja globalnog zatopljenja - «green house effect». Ako prikupimo te podatke za neki vremenski interval, tada se njihova međusobna korelacija može izračunati iz diskretnog oblika slijedećeg izraza

$$r = \frac{\text{cov}(x, y)}{sdev(x)sdev(y)} \quad \text{cov}(x, y) = \sum_x \sum_y (x - \bar{x})(y - \bar{y}) f(x, y)$$

gdje cov označava kovarijancu, a sdev standardnu devijaciju. U gornjem izrazu kovarijanca se izračuna iz podataka po izrazu:

gdje  $\bar{x}$  i  $\bar{y}$  su srednje vrijednosti, a zajednička funkcija gustoće koja se pojavljuje u izrazu za diskretne varijable ima teorijsku premisu da je jednaka očekivanoj vrijednosti. U praksi se A.14 svodi na jednostavni izraz

$$\text{cov}(x, y) = \frac{N \sum_{i=1}^N x_i y_i - \sum_{i=1}^N x_i \sum_{i=1}^N y_i}{N(N-1)}$$

# Autokorelacija (3)

---

Ono što se uvijek debatira među znanstvenicima je pitanje unutar kojeg područja se korelacija smatra značajnom? Opća pravila su da se korelacija između 0.8-1.0 smatra jakom, dok se između -0.5 i 0.5 smatra slabom dok se za ostale vrijednosti korelacija smatra umjerenom. Kad govorimo o jednoj varijabli, tada se kovarijanca pretvara u autokorelaciju koja se definira kao:

$$acor(L) = \frac{\text{COV}(x_i, x_{i+L})}{\text{var}(x)}$$

gdje  $L$  označava interval u vremenskoj seriji na kojem se računa autokovarijanca (uzimaju se svi parovi temperature u raspoloživoj seriji koji su udaljeni  $L$ ) dok je u nazivniku varijanca jedine varijable koja se promatra. Ovo je slučaj koji se isto primjenjuje u prostoru kada interval označava udaljenost među točkama u prostoru kao u geostatistici.

U dosadašnjem dijelu ovog Dodatka često smo spominjali funkciju gustoće kako jedne, tako i više varijabli. Sada ćemo dati samo kratki pregled nekih osnovnih raspodjela koje se koriste u praksi a vezane su za geostatistiku. To su u prvom redu, već u Uvodu ove knjige spomenuta, Gaussova ili normalna raspodjela koja ima slijedeći oblik:

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}, \quad -\infty < x < \infty$$

gdje  $\mu$  označava srednju vrijednost a je standardna devijacija od  $x$ . Veće numeričke populacije vrlo često imaju normalnu raspodjelu koja je simetrična i srednja vrijednost se nalazi u sredini i jednaka je medijanu. Također je poznato da 67% raspodjele se nalazi unutar područja jedne standardne devijacije okolo srednje vrijednosti, 95% se nalazi unutar dvije standardne devijacije i 99.9% raspodjele se nalazi unutar tri standardne devijacije oko srednje vrijednosti.