

Inženjerska hidrologija

PRIMENA VEROVATNOĆE I STATISTIKE U HIDROLOGIJI – Korelacija i regresiona analiza

Korelacija i regresiona analiza


- Povezanost dve ili više promenljivih može biti od velike koristi u hidrologiji
 - najčešće za procenu jedne veličine na osnovu druge koja se meri/osmatra
 - popunjavanje i produžavanje nizova na susednim stanicama
 - veza između oticaja i padavina na jednom slivu
 - veza između oticaja i karakteristika slivova
 - analiza trenda
 - zavisnost padavina od nadmorske visine
 - ...

Korelacija i regresiona analiza

- *Funkcionalna veza* je najjača veza
 - svakoj vrednosti jedne veličine odgovara tačno određena vrednost druge veličine
 - primer 1: površina kruga je u funkcionalnoj vezi sa poluprečnikom kruga
 - primer 2: starost stabla i broj godova
- *Koreaciona ili stohastička veza* je slabija veza
 - između veličina koje su podložne odstupanjima

Korelacija

- Stohastička zavisnost ili **korelacija**
 - kada se ne može utvrditi funkcionalna zavisnost
 - postoji eksperimentalni skup podataka izmerenih vrednosti parova X i Y
 - grafički prikaz zavisnosti i međuzavisnosti između X i Y je *dijagram rasipanja*
 - primer 1: X = telesna visina i Y = telesna težina
 - primer 2: X = broj sati koje je osoba provela trenirajući i Y = telesna težina
 - ali: ishodi bacanja dve kocke – *nekorelisane veličine*



Milan Kilibarda

Korelacija

- Mera linearne povezanosti dve promenljive

- Kovarijansa


$$\text{cov}(X, Y) = E[(X - \mu_X)(Y - \mu_Y)] = \mu_{XY} - \mu_X \cdot \mu_Y$$

Razlikom između μ_{XY} i $\mu_X \cdot \mu_Y$ meri se jačina linearne veze između promenljivih X i Y .

- Koeficijent korelacije

$$\rho_{XY} = \frac{\text{cov}(X, Y)}{\sigma_X \sigma_Y}$$

$$0 \leq |\rho_{XY}| \leq 1$$



Korelacija

- Empirijski koeficijent korelacije dva niza x i y

$$r = \frac{\frac{1}{n-1} \sum (y_i - \bar{y})(x_i - \bar{x})}{\sqrt{\frac{1}{n-1} \sum (x_i - \bar{x})^2} \sqrt{\frac{1}{n-1} \sum (y_i - \bar{y})^2}} = \frac{\frac{1}{n-1} \sum (y_i - \bar{y})(x_i - \bar{x})}{S_x S_y}$$



`r = CORREL(nizX, nizY)`

Regresiona analiza

- **Regresiona analiza:** pronalaženje jednačine zavisnosti jedne promenljive od druge ili više njih
- Opšti model


$$Y = f(X) + \varepsilon, \quad \varepsilon: N(0, \sigma_\varepsilon^2)$$

- X – nezavisna promenljiva (opisna promenljiva)
- Y – zavisna promenljiva (odzivna promenljiva)
- ε – slučajna greška (odstupanje, rezidual)
sa normalnom raspodelom $N(0, \sigma_\varepsilon^2)$, tj. sa sredinom 0

Milan Kilibarda

Regresiona analiza

- Regresioni model $f(x)$ je očekivano mesto za vrednosti slučajne promenljive Y
- Realizovana vrednost slučajne promenljive Y odstupa od regresione prave za grešku ε




$$Y = f(X) + \varepsilon, \quad \varepsilon: N(0, \sigma_\varepsilon^2)$$

Prosta linearna regresija

■ Model proste linearne regresije

$$Y = \beta_0 + \beta_1 x + \varepsilon, \quad \varepsilon: N(0, \sigma^2_\varepsilon)$$



Prosta linearna regresija

■ Određivanje regresionih koficijenata – metoda najmanjih kvadrata

- cilj: minimizovati zbir kvadrata odstupanja od regresione prave
- sistem koji se rešava

$$S^2 = \sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)^2 \rightarrow 0$$

$$\frac{\partial S^2}{\partial \beta_0} = -2 \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i) = 0$$

$$\frac{\partial S^2}{\partial \beta_1} = -2 \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i) x_i = 0$$

$$b_1 = r \frac{S_y}{S_x}$$

$$b_0 = \bar{y} - b_1 \bar{x}$$




b1 = SLOPE(nizY, nizX)
b0 = INTERCEPT(nizY, nizX)

Prosta linearna regresija

■ Određivanje regresionih koficijenata

- primer



$$\begin{aligned} n &= 40 \quad \bar{x} = 24.45 \quad \bar{y} = 60.14 \\ S_x &= 0.16 \quad S_y = 5.01 \quad r = 0.436 \end{aligned}$$

$$\begin{aligned} b_1 &= 0.436 \cdot \frac{5.01}{0.16} = 13.68 \\ b_0 &= 60.14 - 13.68 \cdot 24.45 = -274.4 \end{aligned}$$

$$Y_m = f(x) = 13.68x - 274.4$$

$$Y = f(x) + \varepsilon = 13.68x - 274.4 + \varepsilon$$

Prosta linearna regresija

■ Reziduali

$$\varepsilon_i = y_i - (b_1 x_i + b_0)$$

- srednja vrednost reziduala
- $$\frac{1}{n} \sum_{i=1}^n \varepsilon_i = \frac{1}{n} \sum_{i=1}^n (y_i - b_1 x_i - b_0) = \underbrace{\bar{y} - b_1 \bar{x}}_{b_0} - b_0 = 0$$
- **standardna greška regresije** = „standardna devijacija“ reziduala – pokazatelj kvaliteta regresionog modela

$$S_{Y|X} = \hat{\sigma}_\varepsilon = \sqrt{\frac{1}{n-2} \sum_{i=1}^n \varepsilon_i^2} = S_y \sqrt{\frac{n-1}{n-2}(1-r^2)}$$




$S_{Y|X} = \text{STEYX}(\text{nizY}, \text{nizX})$

Prosta linearna regresija

- Interval poverenja odstupanja slučajne promenjive Y od regresione prave za fiksirano x

$$P\{Y_m(x_0) - z_{\alpha/2} \cdot S_{Y|X} \leq Y | X = x_0 \leq Y_m(x_0) + z_{1-\alpha/2} \cdot S_{Y|X}\} = 1 - \alpha$$

$$Y_m(x_0) = b_0 + b_1 x_0$$




Prosta linearna regresija

- Interval poverenja odstupanja slučajne promenjive Y od regresione prave za fiksirano x

- primer

$$S_{Y|X} = 5.01 \sqrt{\frac{39}{38}(1 - 0.436^2)} = 4.57$$



Broj tačaka izvan intervala poverenja 90%: 4 od $n = 40$

Prosta linearna regresija

- Prognoza slučajne promenjive Y za zadato x_0
 - bez slučajne komponente

$$Y(x_0) = Y_m(x_0) = b_0 + b_1 x_0$$

- sa slučajnom komponentom

$$Y(x_0) = b_0 + b_1 x_0 + \varepsilon_0, \quad \varepsilon_0 = z_0 \cdot S_{Y|X} : N(0, \sigma^2_\varepsilon)$$

gde je z_0 slučajni broj iz normalne raspodele, odnosno kvantil normalne raspodele za slučajan broj p

$$z_0 = \Phi^{-1}(p), \quad 0 < p < 1$$



```
p = RAND()
z0 = NORMSINV(p)
```

Prosta linearna regresija

- Prognoza slučajne promenjive Y za zadato x_0

- primer
 - bez slučajne komponente

$$x_0 = 24.75$$

$$Y_m(x_0) = 13.68 \cdot 24.75 - 274.4 = 64.18$$

- sa slučajnom komponentom

$$p = 0.679, \quad z_0 = \Phi^{-1}(0.679) = 0.465$$

$$\varepsilon_0 = 0.465 \cdot 4.57 = 2.12$$

$$Y_m(x_0) = Y_m(x_0) + \varepsilon_0 = 64.18 + 2.12 = 66.30$$