


ORIS PROBLEMA

Dobimo določene podatke X . Zanima nas Y .

Primer: Problem trgovskega potnika:

X = graf z uteženimi povezavami
 Y = optimalni obhod

Matematični model



Verjetnostni/stohastični model



Statistični model

Stohastični model vsebuje slučaj: Vsaj eno od količin X in Y modeliramo kot slučajno. Tako Y tipično ni natančno določen z X .

Statistični model običajno upošteva še ponavljanje.

Ena izmed glavnih nalog sklepe statistike je najti opazljivo količino \hat{Y} , $\hat{Y} = h(X)$, h merljiva izračunljiva funkcija, da bo \hat{Y} čim bližje Y .

V Bayesovem modelu sta X in Y slučajni spremenljivki na (Ω, \mathcal{F}, P) .

Če poznamo X in Y živi v \mathbb{R} , je smiselna napoved/prediktor za Y slučajna spremenljivka $E(Y|X) = h(X)$.

Diskreten primer: $\hat{Y} = h(X)$, $h(x) = E(Y|X=x)$

Poznamo $P(X=x|Y=y)$. Privzamemo apriorno porazdelitev napovedovalca/
predikanda Y . Po Bayesovi formuli izračunamo $P(Y=y|X=x)$. Iz slednjih
dobimo napoved $E(Y|X=x)$.

Fisherjeva statistika na (Ω, \mathcal{F}) pa gleda celo družino verjetnostnih
mer P_θ , $\theta \in \Theta$.

Splošno: $X = F(\omega, \theta)$, $Y = G(\omega, \theta)$

Dostikrat je Y karakteristika modela, torej $Y=y = g(\theta)$.

Tipično je $X = X(\omega)$.

Primer: Opazimo X_1, X_2, \dots, X_n , ki so neodvisne in porazdeljene kot $N(\mu, \sigma^2)$.

$$\Theta = \mathbb{R} \times (0, \infty)$$

$$\theta = (\mu, \sigma)$$

Ocenjujemo na primer:

$$\cdot g(\mu, \sigma) = \mu$$

$$\cdot g(\mu, \sigma) = \sigma^2$$

$$\cdot g(\mu, \sigma) = \mu^2$$

$$\cdot g(\mu, \sigma) = \mu + 2\sigma \quad (\text{VaR})$$

Terminološka pojasnila:

	deterministična	slučajna
poznamo	konstanta	opazanje
ne poznamo	karakteristika	predikant ali šum

Če je predmet našega zanimanja karakteristika, potem namesto o prediktorju govorimo o cenilki preden opazimo podatke, in o ceni potem ko jih opazimo.

Primer: Vrnimo se k prejšnjemu primeru ...

$$X_k = \mu + \varepsilon_k, \quad k = 1, 2, \dots, n$$

$$\varepsilon_k \sim N(0, \sigma^2) \text{ so šumi.}$$

$$\text{Smiselna cenilka za } \mu \text{ je } \hat{\mu} = \frac{X_1 + X_2 + \dots + X_n}{n} = \bar{X}.$$

VREDNOTENJE CENILK IN PREDIKTORJEV

Naj bo $\hat{y} = h(X)$ cenilka za y .

slučajna spremenljivka

Definicija: Pričakovana ali srednja kvadratična napaka cenilke \hat{y} karakteristike y je:

$$\text{MSE}_\theta(\hat{y}|y) := E_\theta[(\hat{y} - y)^2]$$

mean squared error

ne označuje pogojevanja

pričakovana vrednost pri vsajinski meri P_θ

Definicija: Korenjena pričakovana kvadratična napaka cenilke \hat{y} karakteristike y je:

$$\text{RMSE}_\theta(\hat{y}|y) := \sqrt{\text{MSE}_\theta(\hat{y}|y)}$$

Definicija: Pristranskost cenilke \hat{y} za y je:

$$\text{Bias}_\theta(\hat{y}|y) := E_\theta(\hat{y}) - y = E_\theta(\hat{y} - y)$$

Definicija: Cenilka je nepristranska, če za vse $\theta \in \Theta$ velja:

$$\text{Bias}_\theta(\hat{y}|y) = 0$$

Opazka 4.1: Če je cenilka nepristranska, je $\text{MSE}_\theta(\hat{y}|y) = \text{var}_\theta(\hat{y}) = \text{var}_\theta(\hat{y} - y)$.

V tem primeru označimo tudi $\text{SE} := \sqrt{\text{var}_\theta(\hat{y})}$, čemur pravimo standardna napaka (standard error).

V splošnem pa velja:

$$\begin{aligned}\text{var}_\theta(\hat{y}) &= \text{var}_\theta(\hat{y} - y) \\ &= E_\theta[(\hat{y} - y)^2] - (E_\theta(\hat{y} - y))^2 \\ &= \text{MSE}_\theta(\hat{y}|y) - (\text{Bias}_\theta(\hat{y}|y))^2\end{aligned}$$

$$\Rightarrow \text{MSE}_\theta(\hat{y}|y) = \text{var}_\theta(\hat{y}) + (\text{Bias}_\theta(\hat{y}|y))^2$$

Definicija: Zaporedje cenilk $\hat{y}_1, \hat{y}_2, \dots$ je šibko dosledno za y , če v porazdelitvi konvergira proti y :

$$\forall \theta \in \Theta: \hat{y}_n \xrightarrow[n \rightarrow \infty]{d|\theta} y = y(\theta)$$

Trditve 4.2: Brž ko je limita pričakovanih kvadratičnih napak $\lim_{n \rightarrow \infty} \text{MSE}_\theta(\hat{y}_n|y) = 0$ za vse $\theta \in \Theta$, je zaporedje cenilk $\hat{y}_1, \hat{y}_2, \dots$ šibko dosledno za y .

Dokaz: Rezultat sledi iz trditve 2.18:

$$W_n \geq 0$$
$$p > 0$$

$$\lim_{n \rightarrow \infty} E(W_n^p) = 0 \Rightarrow W_n \xrightarrow[n \rightarrow \infty]{d} 0$$

Po posledici 2.16 velja:

$$X_n \xrightarrow[n \rightarrow \infty]{d} c \Leftrightarrow d(X_n, c) \xrightarrow[n \rightarrow \infty]{d} 0$$

Vstavimo $X_n = \hat{y}_n$, $c = y$, $p = 2$, $W_n = |\hat{y}_n - y|$, $d(a, b) = |a - b|$.

Posledica 4.3: Če je zaporedje cenilk \hat{y}_n za y asimptotično nepristransko ($\lim_{n \rightarrow \infty} E_{\theta}(\hat{y}_n) = y$ za vse $\theta \in \Theta$) in če je tudi $\lim_{n \rightarrow \infty} \text{var}_{\theta}(\hat{y}_n) = 0$ za vse $\theta \in \Theta$, je to zaporedje šibko dosledno za y .

Primer: Naj bodo X_1, X_2, \dots enako porazdeljene s pričakovano vrednostjo μ in varianco σ^2 .

$$\mu = E_{\theta}(X_1) = g(\theta)$$

Tedaj je $\hat{\mu} = \bar{X} = \frac{X_1 + X_2 + \dots + X_n}{n}$ nepristranska cenilka za μ .

Ni pa nujno tudi šibko dosledna. Lahko je denimo $X_1 = X_2 = \dots$ in $\sigma > 0$.

Če privzamemo, da so X_1, X_2, \dots nekorelirane, pa je $\hat{\mu}$ tudi šibko dosledna:

$$\text{MSE}(\bar{X} | \mu) = \text{var}(\bar{X}) = \frac{\sigma^2}{n}$$

$$\text{RMS}(\bar{X} | \mu) = \text{SE}(\bar{X}) = \frac{\sigma}{\sqrt{n}}$$

Ko gre $n \rightarrow \infty$, gre $MSE \rightarrow 0$, torej je $\hat{\mu}$ šibko dosledna za μ .

Če so X_1, X_2, \dots neodvisne, pa je po zakonu velikih števil (opazka 2.20 (1)) to velja tudi brez predpostavke o končnem drugem momentu.

Zaporedne cenilke X_1, X_2, \dots pa ni šibko dosledno za μ .

V resnici je \bar{X} najboljša nepristranska linearna cenilka (NNLC, best linear unbiased estimator, BLUE) za μ .

Če je N fiksna in so c_1, c_2, \dots, c_n take konstante, da je $\hat{\mu} = c_1 X_1 + c_2 X_2 + \dots + c_n X_n$ nepristranska cenilka za μ , velja:

$$MSE(\hat{\mu} | N) \geq MSE(\bar{X} | N)$$

||
var($\hat{\mu}$)

Za slednje je dovolj privzeti nekoreliranost.

Če pa je model Gaussov (X_1, X_2, \dots neodvisne in porazdeljene kot $N(\mu, \sigma^2)$) ter velja še eden izmed naslednjih pogojev:

i) σ je konstanten, torej znan

ii) μ in σ se spreminjata neodvisno drug od drugega



Potem je \bar{X} tudi najboljša nepristranska cenilka za μ nasploh.

Za tem stoji Rao-Graméjeva ocena.

(Calyampudi Radhakrishna Rao, 1920-2023)

(Carl Harald Gramér, 1893-1985)

Če dopustimo kar vse cenilke, pa tipično nobena ni enakomenno najboljša:

Padalska cenilka $\mu := 42$ je vsekakor najboljša, če je kar $\mu = 42$, sicer pa ne nujno.

Če pa ocenjujemo μ^2 , je \bar{X}^2 tipično pristranska cenilka, saj v primeru nekoreliranosti velja:

$$E(\bar{X}^2) = \text{var}(\bar{X}) + (E(\bar{X}))^2 = \frac{\sigma^2}{n} + \mu^2$$

Je pa asimptotično nepristranska:

$$\text{Bias}(\bar{X}^2 | \mu^2) = \frac{\sigma^2}{n} \xrightarrow{n \rightarrow \infty} 0 \quad \text{za vse } \theta \in \Theta$$

Je tudi šibko nedosledna, in sicer po trditvi 2.21:

Če gre $X_n \xrightarrow{d} X$ in je g zvezna, gre $g(X_n) \xrightarrow{d} g(X)$.

Splošni primer, ko je $\hat{Y} = h(X)$ prediktor za $Y = G(w, \theta)$:

Ostane pričakovana kvadratična napaka $\text{MSE}_\theta(\hat{Y} | Y) = E_\theta[(\hat{Y} - Y)^2]$.

Če za vsak θ velja $E_{\theta}(\hat{Y}) = E_{\theta}(Y)$, je nujno $MSE_{\theta}(\hat{Y}|Y) = \text{var}_{\theta}(\hat{Y} - Y)$, tipično pa to ni več enako $\text{var}_{\theta}(\hat{Y})$.

Primer: Naj bodo X_1, X_2, \dots nekovelirane in enako porazdeljene s pričakovano vrednostjo μ in varianco σ^2 .

$$X_i = \mu + \varepsilon_i$$

$\varepsilon_1, \varepsilon_2, \dots$ tvorijo beli šum, kar pomeni, da so nekovelirane z ničelno pričakovano vrednostjo in enakimi variancami.

Opazimo $X = (X_1, X_2, \dots, X_n)$.

Zanima nas $Y = X_{n+1}$.

$$Y = \mu + \varepsilon_{n+1}$$

Prediktor za Y : $\hat{X}_{n+1} = \hat{Y} = \frac{X_1 + X_2 + \dots + X_n}{n} = \bar{X}$

Ta prediktor je nepristranski v prejšnjem smislu: $E(\hat{X}_{n+1}) = E(X_{n+1})$

$$MSE = \text{var}(\bar{X} - X_{n+1}) = \text{var}(\bar{X}) + \text{var}(X_{n+1})$$

$$= \frac{\sigma^2}{n} + \sigma^2 = \left(1 + \frac{1}{n}\right) \cdot \sigma^2$$

