

Pratybos (Lab.) 1

Tiesinis regresijos metodas

Duomenų aibė (x_i, y_i) , $i=1, \dots, m$

Ieškome nežinomo atvaizdavimo

$$y = f(x)$$

Pasirenkame parametrinį metodą,
ir $f(x)$ ieškome tarp tiesių

$$f^*(x, \beta) = \beta_0 + \beta_1 x.$$

Parametrai β_0 ir β_1 randame sprendami uždavinį (minimavim.) uždav

$$\text{cerg min}_{(\beta_0, \beta_1)} \sum_{i=1}^m (y_i - (\beta_0 + \beta_1 x_i))^2$$

Formules, koeficientų skaičiav.

$$\bar{x} = \frac{1}{m} \sum_{i=1}^m x_i, \quad \bar{y} = \frac{1}{m} \sum_{i=1}^m y_i$$

$$\hat{\beta}_1 = \frac{\sum_{i=1}^m (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^m (x_i - \bar{x})^2}$$

$$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}$$

Duomenys

(1, 1), (2, 3), (4, 3), (3, 2), (5, 5)

Ats.: $\beta_0 = 0.4, \beta_1 = 0.8$

$m = 5$
RMSE = 0.69282

- 1) Sudarykite tiesinį regresijos modelį
- 2) Atvaizduokite informaciją grafike
- 3) Apskaičiuokite prognozę, kai

$x = 1, 1.5, 2, 3, 4, 4.5, 5$.

- 4) Įvertinkite prognozi pateiktą apmėlymą duomenims!

RMSE (root mean square error)

Gradientinis nusileidimo metodas

Turime dviejų kintamųjų f -ją

$$F(\beta_0, \beta_1)$$

Norime rasti minimumo reikšmę
(lokalaus minimumo)

Surandame f -jos gradientą (tai
vektorius, kurio kryptimi funkcija
didėja greičiausiai)

$$\text{grad } F = \left(\frac{\partial F}{\partial \beta_0}, \frac{\partial F}{\partial \beta_1} \right)$$

Taško $\bar{\beta} = (\bar{\beta}_0, \bar{\beta}_1)$ aplinkoje.

Tada eidami anti gradientu kryptimi
sumažiname f -jos reikšmę

$$\beta_{\text{~~0~~ }^{n+1}} = \beta_{\text{~~0~~ }^n - \gamma \text{ grad } F(\beta^n)$$

γ - pakankamai mažas parametras

Pritaikydami šį metodą tiesinės regresijos metodikai (tiesinės regresijos aproksimacijos skaičiavimui)

$$F(\beta_0, \beta_1) = \sum_{i=1}^n (y_i - (\beta_0 + \beta_1 x_i))^2$$

$$\frac{\partial F}{\partial \beta_0} = -2 \sum_{i=1}^n [y_i - (\beta_0 + \beta_1 x_i)]$$

$$\frac{\partial F}{\partial \beta_1} = -2 \sum_{i=1}^n [y_i - (\beta_0 + \beta_1 x_i)] x_i$$

Apskaičiuojame $F(\beta^{n+1})$:

- Jei $F(\beta^{n+1}) < F(\beta^n)$ tęsiamame iteraciniame procese
- Jei $F(\beta^{n+1}) \geq F(\beta^n)$, tai sumažiname $\gamma_i = \frac{1}{2} \gamma_i$ ir kartojame β^{n+1} skaičiavimus.

Uāduotis

Įsprendkite ankstesnį pavyzdį (seraškute tiesinis regresijos lygtis.) Pradinį artinį imkite

$$\beta_0^0 = 0, \beta_1^0 = 0.$$

Iteracijos tęskite, kol bus išpildyta būtinoji minimumo sąlyga norime toksienu.

Pastaba. Jei n (duomenų skaičius) yra didelis (o mes domame BIG DATA uždav.), tai regresijos tiesės radimas algoritme kvadratoje iteracijojė reikia perskaiciuoti gradiento vektorius ir apskaičiuoti $F(\beta^{n+1})$ reikšmes, kol surasime tinkamą β reikšmę. Tai gali reikšmėti pakankamai didelį apimties skaičiavimų

Stochastinis gradientinis nusileidimo metodas (stochastic gradient descent).

Koeficientus β_0, β_1 perskaiciuojame imdame po vieną elementą duomenų porą (x_i, y_i) . Tokiu būdu smarkčiau sumažiname vidurkio reikšmės realizavimo kaštus.

$$\beta^{n+1, i} = \beta^{n+1, i-1} - \gamma \text{grad } F^i(\beta^{n+1, i-1})$$

$$\beta^{n+1, 0} = \beta^n, \quad \beta^{n+1} = \beta^{n+1, m}$$

$$\frac{\partial F^i}{\partial \beta_0}(\beta) = -2 (y_i - (\beta_0 + \beta_1 x)) \cdot 1.$$

$$\frac{\partial F^i}{\partial \beta_1}(\beta) = -2 (y_i - (\beta_0 + \beta_1 x)) x.$$

Terminai: kai užbaigiame atraujin-
ti β^i reikšmes visiems $i=1, \dots, m$,
sakome, kad įvykdėme vienos epoches
skaičiavimus

Užduotis: Imkite ankstesnis paįpydūt
duomenis ir skaiciuolite tiesines
regresijas f_j (tiesę) stochastiniu
gradientiniu nusileidimo metodu.

$$\beta_0^0 = 0, \beta_1^0 = 0$$

Iteraciuo parametru γ reikšmę
imkite $\gamma = 0.01$

Apskaičiuolite 4 epoches (20
iteracijų).