



Mašinsko učenje

Regresija

Nemanja Maček

- Uvodne napomene
- Jednostruka regresija
- Nelinearni modeli zavisnosti
- Zaključne napomene

Šta je regresija?

- U velikom broju eksperimenata uočava se veza između dve ili više promenljivih.
- Na primer,
 - može se uočiti veza između stepena erozije i količine padavina,
 - može se uočiti veza između širine reke i maksimalnog godišnjeg proticaja,
 - može se uočiti veza između broja rođene dece po ženi, nivoa obrazovanja i vrste zaposlenja, itd.

Šta je regresija?

- Ako posmatramo obeležja $X_1, X_2, \dots, X_p$ i Y , tada tražimo funkciju $\varphi(x_1, x_2, \dots, x_p)$ za koju će biti:

$$Y \approx \varphi(X_1, X_2, \dots, X_p)$$

- Funkcija φ se bira tako da srednje-kvadratno odstupanje $E \left(Y - \varphi(X_1, X_2, \dots, X_p) \right)^2$ bude najmanje.
- Funkcija φ se zove regresija Y po $X_1, X_2, \dots, X_p$.

Šta je jednostruka regresija?

- Najjednostavnija regresija je jednostruka regresija kada se posmatraju dve promenljive X i Y .
- Traži se funkcija φ takva da je $Y \approx \varphi(X)$.
- Iz populacije se izdvaja realizovani uzorak $((x_1, y_1), (x_2, y_2), \dots, (x_n, y_n))$ i predstavlja se u Dekartovoj ravni.
- Na osnovu dobijenog dijagrama, koji se zove dijagram rasturanja, bira se familija funkcija sa kojom će se raditi, npr:
 - $y = ax + b$,
 - $y = ae^{bx}$,
 - $y = a \ln x + b$.
- Na kraju se određuju vrednosti parametara regresije.

Jednostruka linearna regresija.

- Ako je zavisnost φ između promenljivih X i Y linearna, tj. oblika $Y = aX + b$, tada kažemo da je φ jednostruka linearna regresija.
- Jednostruka linearna regresija može biti:
 - prve vrste, ukoliko obeležje Y zavisi od slučajne promenljive X ,
 - druge vrste, ukoliko obeležje Y zavisi od neslučajne (kontrolisane) promenljive X .

Jednostruka linearna regresija prve vrste.

- Zavisnost je oblika $Y = aX + b$.
- Parametri a i b su nepoznati parametri koji se određuju iz uslova da je srednje-kvadratno odstupanje $E(Y - aX - b)^2$ najmanje.
- Ocene parametara su:

$$\hat{a} = \frac{\sum X_i Y_i - \frac{1}{n} \sum X_i \sum Y_i}{\sum X_i^2 - \frac{1}{n} (\sum X_i)^2}$$

$$\hat{b} = \bar{Y}_n - \hat{a} \bar{X}_n$$

- Vrednost $\hat{Y}_i$ dobijena kao $\hat{Y}_i = \hat{a}\hat{X}_i + \hat{b}$ je procena vrednosti Y_i na osnovu vrednosti X_i .

Jednostruka linearna regresija prve vrste.

- Greška ocenjivanja se definiše na sledeći način:

$$S_{Y-\hat{Y}}^2 = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$

- Greška ocenjivanja sadrži informaciju o tome koliko izabrana funkcija dobro aproksimira zavisnost obeležja Y po X .
- U slučaju da je uzorak mali, greška ocenjivanja se definiše na sledeći način:

$$S_{Y-\hat{Y}}^2 = \frac{1}{n-1} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$


Primer.

- Na osnovu merenja pretprolećnog minimalnog srednjemesečnog nivoa podzemnih voda (X), i srednjeg godišnjeg nivoa (Y) u godinama 1952-1958. dobijeno je:

godina	1952	1953	1954	1955	1956	1957	1958
X	19,51	19,02	19,04	15,80	17,52	15,96	16,31
Y	17,57	17,66	18,74	14,48	15,44	13,92	15,22

- Odrediti pravu linearne regresije Y po X i na osnovu nje prognozirati Y za izmerenu vrednost $x=16,99$ u 1959. godini. Izračunati grešku ocenjivanja.

Primer – dijagram rasturanja.



Primer – rešenje.

- Koeficijenti prave linearne regresije su:

$$\hat{a} = \frac{2005,18 - \frac{1}{7} \times 123,16 \times 113,03}{2182,25 - \frac{1}{7} \times 123,16^2} = 1,076$$

$$\hat{b} = \frac{113,03}{7} - 1,076 \times \frac{123,16}{7} = -2,784$$

- Tražena prava linearne regresije je: $\hat{Y} = 1,076 \times X - 2,784$.
- Procenjujemo da je u 1959. godini srednji godišnji nivo bio:
 $y(16,99) = 1,076 \times 16,99 - 2,784 = 15,50$


Primer – rešenje.

- Greška ocenjivanja je:

$$S_{Y-\hat{Y}}^2 = \frac{2,3795}{6} = 0,3966$$

- Pošto je greška mala u odnosu na vrednosti obeležja Y , zaključujemo da smo dobro aproksimirali vrednosti obeležja Y po X .

Primer – grafik prave linearne regresije.



Jednostruka linearna regresija prve vrste.

- Može se posmatrati i linearna regresija X po Y .
- Ona je oblika $X = cY + d$, gde su c i d nepoznati parametri koji se određuju iz uslova da je srednje-kvadratno odstupanje $E(X - cY - d)^2$ najmanje.
- Ocene parametara su:

$$\hat{c} = \frac{\sum X_i Y_i - \frac{1}{n} \sum X_i \sum Y_i}{\sum Y_i^2 - \frac{1}{n} (\sum Y_i)^2}$$

$$\hat{d} = \bar{X}_n - \hat{c} \bar{Y}_n$$

Jednostruka linearna regresija prve vrste.

- Greška ocenjivanja se definiše na sledeći način:

$$S_{X-\hat{X}}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \hat{X}_i)^2$$

- U slučaju da je uzorak mali, greška ocenjivanja se definiše na sledeći način:

$$S_{X-\hat{X}}^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \hat{X}_i)^2$$

Jednostruka linearna regresija druge vrste.

- Zavisnost je oblika $Y = aX + b + \varepsilon$, gde je ε slučajna promenljiva koja se najčešće identifikuje kao greška merenja.

Šta su nelinearni modeli zavisnosti?

- Nelinearni modeli zavisnosti su modeli koji jednostavnim transformacijama mogu da se svedu na linearne modele.
- Posmatraćemo:
 - model linearan po parametrima,
 - stepeni model,
 - eksponencijalni model.
- Nelinearni modeli mogu biti prve i druge vrste.

Model linearan po parametrima.

- Model linearan po parametrima prve vrste je oblika

$$Y = ag(X) + b$$

- gde je g unapred poznata funkcija od slučajne promenljive X , a a i b nepoznati parametri.
- Model se smenom $Z = g(X)$ svodi na linearan model prve vrste $Y = aZ + b$.
- Nepoznati parametri a i b se ocenjuju na osnovu uzorka $((Z_1, Y_1), \dots, (Z_n, Y_n))$ koji je dobijen transformacijom $Z_i = g(X_i), i = 1, \dots, n$ od početnog uzorka $((X_1, Y_1), \dots, (X_n, Y_n))$.

Model linearan po parametrima.

- Ocene parametara a i b regresionog modela $Y = aZ + b$ su:

$$\hat{a} = \frac{\sum Z_i Y_i - \frac{1}{n} \sum Z_i \sum Y_i}{\sum Z_i^2 - \frac{1}{n} (\sum Z_i)^2}$$

$$\hat{b} = \bar{Y}_n - \hat{a} \bar{Z}_n$$

- U tom slučaju početni regresioni model je oblika:


$$\hat{Y} = \hat{a}g(X) + \hat{b}$$

Primer.

- Odrediti regresionu krivu $Y = a \log X + b$ veze između širine reke Y i maksimalog godišnjeg proticaja X (u m³/sec) na osnovu uzorka od deset reka:

maks. proticaj	5,7	17	22	31	50	61	85	120	12	19
širina reke	63	260	92	230	720	890	2500	1150	93	210

Primer – dijagram rasturanja.



Primer – rešenje.

- Realizovane vrednosti ocena $\hat{a}$ i $\hat{b}$ su redom:


$$\hat{a} = \frac{25857,48 - \frac{1}{10} \times 33,781 \times 6208}{122,108 - \frac{1}{10} \times 33,781^2} = 611,360$$

$$\hat{b} = \frac{6208}{10} - 611,360 \times \frac{33,781}{10} = -1407,754$$

- Regresiona prava između obeležja Y i Z je oblika: $\hat{Y} = 611,360 \times Z - 1407,754$.
- Regresiona kriva koja opisuje vezu između širine reke i maksimalnog godišnjeg proticaja je:

$$\hat{Y} = 611,360 \log X - 1407,754$$

Primer – grafik regresione krive.



Stepeni model.

- Stepeni model prve vrste je oblika

$$Y = bX^a$$

- gde su a i b nepoznati parametri.
- Model se smenama $Z = \ln X$, $W = \ln Y$ i $c = \ln b$ svodi na linearan model prve vrste, odnosno na $W = aZ + c$.
- Nepoznati parametri a i c se ocenjuju na osnovu uzorka $((Z_1, W_1), \dots, (Z_n, W_n))$ koji je dobijen transformacijama $Z_i = \ln X_i, i = 1, \dots, n$ i $W_i = \ln Y_i, i = 1, \dots, n$ od početnog uzorka $((X_1, Y_1), \dots, (X_n, Y_n))$.

Stepeni model.

- Ocene parametara a i c regresionog modela $W = aZ + c$ su:

$$\hat{a} = \frac{\sum Z_i W_i - \frac{1}{n} \sum Z_i \sum W_i}{\sum Z_i^2 - \frac{1}{n} (\sum Z_i)^2}$$

$$\hat{c} = \bar{W}_n - \hat{a} \bar{Z}_n$$

- Parametar b ocenjujemo kao $\hat{b} = e^{\hat{c}}$.
- U tom slučaju početni regresioni model je oblika:

$$\hat{Y} = \hat{b} X^{\hat{a}}$$


Primer.

- Na obali zaliva se ispituje vlažnost mulja (u gramima vode na 100 grama suve materije). Iz jedne bušotine je dobijeno:

dubina (X)	1,5	3	4,5	6	7,5	9	10,5
vlažnost (Y)	84	50	32	28	24	23	25

- Odredite regresionu krivu $Y = bX^a + \varepsilon$.

Primer – dijagram rasturanja.



Primer – rešenje.

- Realizovane vrednosti ocena nepoznatih parametara su:

$$\hat{a} = \frac{37,614 - \frac{1}{7} \times 11,363 \times 24,450}{21,259 - \frac{1}{7} \times 11,363^2} = -0,738$$


$$\hat{c} = \frac{24,450}{7} + 0,738 \times \frac{11,363}{7} = 4,961$$

$$\hat{b} = e^{4,961}$$

Primer – rešenje.

- Regresiona prava između obeležja W i Z je oblika: $\hat{W} = -0,738 \times Z + 4,691$.
- Regresiona kriva koja opisuje vezu između dubine i vlažnosti mulja je:
 $\hat{Y} = 108,962X^{-0,738} + \varepsilon$.

Primer – grafik regresione krive.



Eksponencijalni model.

- Eksponencijalni model prve vrste je oblika

$$Y = be^{aX}$$

- gde su a i b nepoznati parametri.
- Model se smenama $W = \ln Y$ i $c = \ln b$ svodi na linearan model prve vrste $W = aX + c$.
- Nepoznati parametri a i c se ocenjuju na osnovu uzorka $((X_1, W_1), \dots, (X_n, W_n))$ koji je dobijen transformacijom $W_i = \ln Y_i, i = 1, \dots, n$ od početnog uzorka $((X_1, Y_1), \dots, (X_n, Y_n))$.

Eksponencijalni model.

- Ocene parametara a i c regresionog modela $W = aX + c$ su:

$$\hat{a} = \frac{\sum X_i W_i - \frac{1}{n} \sum X_i \sum W_i}{\sum X_i^2 - \frac{1}{n} (\sum X_i)^2}$$

$$\hat{c} = \bar{W}_n - \hat{a} \bar{X}_n$$

- Parametar b ocenjujemo kao $\hat{b} = e^{\hat{c}}$.
- U tom slučaju početni regresioni model je oblika:

$$\hat{Y} = \hat{b} e^{\hat{a} X}$$


Primer.

- Na obali zaliva se ispituje vlažnost mulja (u gramima vode na 100 grama suve materije). Iz jedne bušotine je dobijeno:

dubina (X)	1,5	3	4,5	6	7,5	9	10,5
vlažnost (Y)	84	50	32	28	24	23	25

- Odredite regresionu krivu $Y = be^{aX} + \varepsilon$.

Primer – dijagram rasturanja.



Primer – rešenje.

- Realizovane vrednosti ocena nepoznatih parametara su:

$$\hat{a} = \frac{137,8 - \frac{1}{7} \times 42 \times 24,450}{315 - \frac{1}{7} \times 42^2} = -0,146$$


$$\hat{c} = \frac{24,450}{7} + 0,146 \times \frac{42}{7} = 4,369$$

$$\hat{b} = e^{4,366} = 78,965$$

Primer – rešenje.

- Regresiona prava između obeležja W i X je oblika: $\hat{W} = -0,146 \times X + 4,369 + \varepsilon$.
- Regresiona kriva koja opisuje vezu između dubine i vlažnosti mulja je:
 $\hat{Y} = 78,965e^{-0,146X} + \varepsilon$.

Primer – grafik regresione krive.



- Sama reč regresija znači vraćanje unatrag.
- Naziv regresija za ovakve modele potiče od statističara Sir Fransis Galtona, (1822 - 1911) koji je prvi upotrebio date modele za ispitivanje bioloških i psiholoških pojava.
- Galton je ispitivao vezu između visina roditelja i dece – ustanovio je da roditelji sa natprosečnom visinom teže da imaju decu koja su takođe viša od proseka, ali ne toliko visoka kao roditelji. Ta činjenica važi i za decu izuzetno niskih roditelja – deca su takođe bila niska ali ne toliko niska kao roditelji. Visine su se „vraćale natrag“, regresirale prema proseku.
- Galton je ovu činjenicu nazvao „regresija prema proseku“, a naziv je ostao i za metodu.

- Beleške pripremljene prema knjizi – Luis Pedro Coelho, Willi Richert (2015): „Building Machine Learning Systems with Python, Second Edition“. Packt Publishing.
- Dodatni materijali korišćeni prilikom pripreme beleški:
 - „Regresija“, predavanja dostupna na sajtu Prirodno matematičkog fakulteta, Univerziteta u Nišu.

Pitanja su dobrodošla.