



LINEARNA REGRESIJA

STABLO ODLUČIVANJA

SLUČAJNA ŠUMA

Željka Ujević Andrijić
zujevic@fkit.unizg.hr

UVOD U LINEARNU REGRESIJU

- **Definicija regresije:** statistička tehnika koja se koristi za modeliranje veza između zavisnih i nezavisnih varijabli.
- Cilj regresijske analize je utvrditi način na koji promjene u nezavisnim varijablama utječu na zavisnu varijablu. Omogućuje **predviđanje** vrijednosti zavisne varijable na temelju nezavisnih varijabli.

- **Jednostavna regresija:** Kada postoji jedna zavisna i jedna nezavisna varijabla.

$$y_i = \beta_0 + \beta_1 x_{i1}$$

- **Viševeličinska regresija:** Kada postoji više nezavisnih varijabli.

Viševeličinski linearni model

Što je viševeličinski linearni model?

Model koji uključuje više nezavisnih varijabli za predviđanje zavisne varijable.

Opći oblik modela:

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \cdots + \beta_K x_{iK} + e_i$$

gdje su:

y_i je zavisna varijabla,

x_{ij} su nezavisne varijable,

β_j su regresijski koeficijenti,

e_i je pogreška.

Regresijski koeficijenti viševerižinskog linearnog modela

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \cdots + \beta_K x_{iK} + e_i$$

Što su regresijski koeficijenti?

- β_0 : Konstanta, vrijednost kada su nezavisne varijable nula.
- β_j : Koeficijenti koji pokazuju za koliko se zavisna varijabla mijenja kad se odgovarajuća nezavisna varijabla poveća za jedan, uz ostale varijable na konstantnoj razini.
- Npr. koeficijent β_1 pokazuje koliko se y_i mijenja kada se x_1 poveća za jedan, uz uvjet da ostale nezavisne varijable (poput $x_2, x_3, \dots$) ostanu nepromijenjene.

Procjena parametara pomoću metoda najmanjih kvadrata

- Za procjenu parametara (koeficijenata) regresijskog modela koristi se **metoda najmanjih kvadrata** koja minimizira sumu kvadrata razlika između stvarnih i predviđenih vrijednosti zavisne varijable.
- Kako bi se pronašli optimalni parametri koji minimiziraju funkciju, računaju se **parcijalne derivacije funkcije** u odnosu na svaki parametar).
- Parcijalne derivacije regresijske funkcije daju uvid u to kako se y_i mijenja kada se promijeni samo jedna nezavisna varijabla x_j , dok su ostale varijable konstantne.


Primjer Python koda za višestruku linearnu regresiju

Paket: scikit-learn (sklearn)

Naredbe: `model = LinearRegression()`
`model.fit(X, y)`


```
1
2  from sklearn.linear_model import LinearRegression
3  import pandas as pd
4
5  # Učitavanje podataka iz Excel datoteke
6  data = pd.read_excel('data.xlsx')
7
8  # Definiranje nezavisnih varijabli i zavisne varijable
9  X = data[['x1', 'x2', 'x3']] # nezavisne varijable
10 y = data['y'] # zavisna varijabla
11
12 # Kreiranje i treniranje modela
13 model = LinearRegression()
14 model.fit(X, y)
15
16 # Prikaz koeficijenata i konstante
17 print('Koeficijenti:', model.coef_)
18 print('Konstanta:', model.intercept_)
```

Primjer razvoja viševereličinskog linearnog modela



Predviđanje temperature kraja destilacije proizvoda dna splitera


Temperatura vrha kolone
 Temperatura ulaza u spliter
 Temperatura vrha splitera
 Temperatura dna splitera
 Tlak vrha splitera
 Protok refluksa (t/h)



$$T_{EBP} = -28,747 + 1,135 \cdot T_{vrhkol} - 6,084 \cdot p_{vrhsp} - 0,068 \cdot T_{vrhsp} - 0,035 \cdot \text{Refluks} + 0,190 \cdot T_{ulsp} + 0,354 \cdot T_{dnosp}$$


STABLO ODLUČIVANJA

- **Stablo odlučivanja** (engl. *decision tree*) je nadzirani model strojnog učenja koji ima strukturu nalik stablu.
- Njegova glavna prednost je što omogućuje jednostavno razumijevanje i interpretaciju odluka, jer jasno prikazuje kako se donose odluke kroz različite faze analize podataka.
- Model organizira podatke u hijerarhijsku strukturu sastavljenu od korijenskog čvora (engl. *root node*), unutarnjih čvorova (engl. *internal nodes*), grana (engl. *branches*) i listova (engl. *leaf nodes*).



STABLO ODLUČIVANJA

- **Korijenski čvor:** početni čvor u stablu odlučivanja, gdje se skup za učenje počinje dijeliti na temelju atributa podataka. **Atributi** su karakteristike ili svojstva koja se koriste za podjelu podataka.
- **Unutarnji čvorovi** provode testove ili donose odluke temeljem atributa podataka te predstavljaju mjesta daljnjeg razdvajanja podataka.
- **Grane** predstavljaju ishod testa ili odluke te vode do sljedećeg čvora ili **lista** koji predstavlja konačnu predikciju ili odluku.



STABLO ODLUČIVANJA

Izgradnja stabla odlučivanja sastoji se od sljedećih koraka:

- **Odabir najboljeg atributa:** Prvi korak je odabrati atribut koji najbolje razdvaja podatke prema nekom kriteriju.
- **Podjela skupa podataka:** Na temelju odabranog atributa, podaci se dijele na podskupove.
- **Ponavljanje procesa:** Proces se ponavlja rekurzivno za svaki podskup, stvarajući novi unutarnji čvor ili list dok se ne ispune određeni kriteriji za zaustavljanje, poput unaprijed određenih dubina stabla ili kada podaci u čvoru pripadaju istoj klasi.

Primjena stabla odlučivanja - hoće li osoba kupiti proizvod


Imamo podatke o kupovini proizvoda na temelju dva atributa: **dob** i **prihodi** na temelju kojih stablo odlučivanja može donijeti odluku hoće li osoba kupiti proizvod ili ne.

Korak 1: Odabir atributa koji najbolje razdvaja podatke

Može se koristiti **dob** kao prvi atribut. Podaci se dijele u dvije grane:

$Dob < 30$

$Dob \geq 30$



Korak 2: Podjela skupa podataka

Na temelju odabrane granice za dob, podaci se dijele u dva skupa. Zatim, za svaki skup podataka, može se koristiti drugi atribut — **prihodi**.

Ako je Dob < 30:


Ako su $prihodi > 40.000$: Osoba će kupiti proizvod (**List: Da**).

Ako su $prihodi \leq 40.000$: Osoba neće kupiti proizvod (**List: Ne**).

Ako je Dob ≥ 30:

Ako su $prihodi > 50.000$: Osoba će kupiti proizvod (List: Da).

Ako su $prihodi \leq 50.000$: Osoba neće kupiti proizvod (List: Ne).




Primjena stabla odlučivanja - hoće li osoba kupiti proizvod

• Korak 3: Ponavljanje procesa


Proces se ponavlja za svaki podskup podataka, stvarajući nove unutarnje čvorove dok se ne ispune uvjeti za zaustavljanje. Npr. može se zaustaviti kad svi podaci u čvoru pripadaju istoj klasi (npr. svi će kupiti proizvod) ili kad se postigne unaprijed zadana dubina stabla.

- **Korijenski čvor:** Početni čvor u stablu gdje dijelimo podatke prema atributu "dob".
- **Unutarnji čvorovi:** Mjesta gdje se podaci dalje razdvajaju prema drugim atributima, u ovom slučaju prema prihodima.
- **Grane:** Ove linije povezuju čvorove i predstavljaju mogući ishod testa, tj. ako su njeni prihodi veći od 40.000.
- **Listovi:** Predstavljaju konačnu odluku (kupnja ili ne kupnja proizvoda).




SLUČAJNA ŠUMA

- **Slučajna šuma** (engl. *random forest*) je ansambl metoda strojnog učenja koja koristi velik broj stabala odlučivanja s ciljem poboljšanja točnosti i robusnosti modela.
- Ključne karakteristike slučajne šume: **pakiranje** (engl. *bootstrapping*) i **nasumičan odabir značajki**.
- **Pakiranje** je ansambl metoda koja koristi više modela temeljenih na istom algoritmu učenja.
- Svaki model se uči na različitim **nasumično odabranim** podskupovima originalnog skupa podataka.
- Kombiniranjem rezultata putem računanja **prosjeaka** u regresiji ili **glasanja** (engl. *Majority voting*) u klasifikaciji, dobiva se **konačna predikcija**.



SLUČAJNA ŠUMA

- Svako stablo u slučajnoj šumi gradi se koristeći **nasumičan podskup podataka** i **nasumičan odabir značajki**. Za svaki unutarnji čvor, nasumično se odabire manji skup značajki iz ukupnog skupa značajki. Ovaj pristup povećava raznolikost među stablima.
- Na temelju tog nasumično odabranog skupa značajki, bira se najbolja značajka za testiranje u svakom čvoru, a taj proces se ponavlja za sve čvorove u stablu.
- Rezultat svakog stabla odlučivanja je jedna predikcija, a konačna predikcija modela slučajne šume dobiva se računanjem **prosjeaka** rezultata u regresiji ili **glasanjem** u klasifikaciji.



Primjer Python koda za stablo odlučivanja i slučajne šume

Paket: scikit-learn (sklearn)

```
1  import pandas as pd
2  # Učitavanje podataka iz Excel datoteke
3  data = pd.read_excel('data.xlsx')
4
5  # Definiranje nezavisnih varijabli i zavisne varijable
6  X = data[['x1', 'x2', 'x3']] # nezavisne varijable
7  y = data['y'] # zavisna varijabla
8
9
10 # Stablo odlučivanja / Slučajna šuma (Decision Tree / Random Forest)
11
12 from sklearn.tree import DecisionTreeRegressor
13
14 DTRmodel = DecisionTreeRegressor()
15
16 DTRmodel.fit(X, y)
17
18 y_pred = DTRmodel.predict(X)
19
20
21
22 from sklearn.ensemble import RandomForestRegressor
23
24 RFRmodel = RandomForestRegressor()
25
26 RFRmodel.fit(X, y)
27
28 y_pred = RFRmodel.predict(X)
```