

# Istraživanje podataka 1

## Vežbe 6

# Outline

1 Unakrsna validacija

2 K najbližih suseda

# Outline

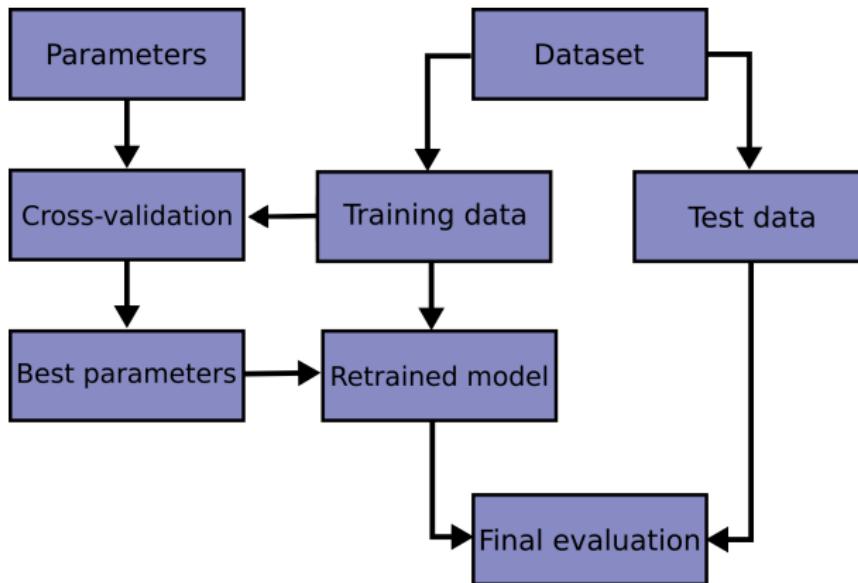
1 Unakrsna validacija

2 K najbližih suseda

# Podela skupa

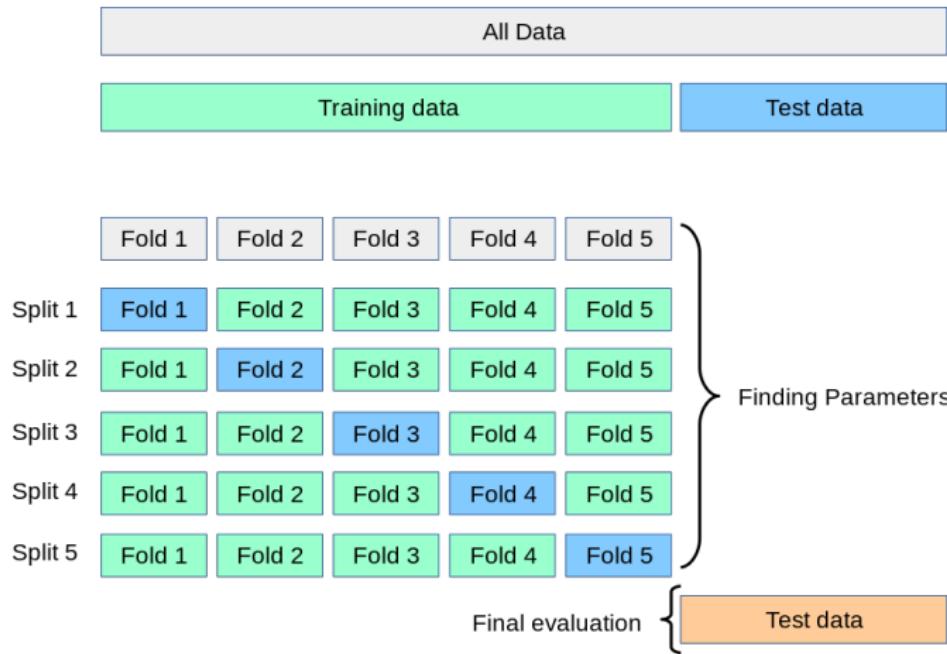
- Trening i test deo
- Trening deo, test deo i deo za validaciju

# Unakrsna validacija



- Podešavanje hiper-parametara procenjivača

# Unakrsna validacija



# Unakrsna validacija

- `sklearn.model_selection.GridSearchCV`
- iscrpna pretraga korišćenjem zadatih vrednosti parametara za procenjivača
- parametri
  - *estimator* - procenjivač (npr. `KNeighborsClassifier`)
  - *param\_grid* - rečnik ili lista rečnika sa definisanim mogućim vrednostima za parametre procenjivača
  - *scoring* - mera za proveru modela
  - *cv* - broj podskupova za unakrsnu validaciju, default= 3-fold
  - *refit* - da li ponovo napraviti model sa najboljim parametrima nad celim skupom podataka. Da bi mogla da se radi predikcija nad drugim skupom potrebno je staviti True. (default=True)

# Unakrsna validacija

- atributi

- *cv\_results\_* - rečnik sa podacima o zadatim parametrima i rezultatima
- *best\_estimator\_* - najbolji klasifikator
- *best\_score\_* - najbolji skor
- *best\_params\_* - parametri koji daju najbolji rezultat
- *scorer\_* - funkcija za skor

# Unakrsna validacija

- metode

- $fit(x,y)$  - pravljenje modela sa optimalnim parametrima na osnovu skupa  $(x,y)$
- $predict(x)$  - predviđanje klase za test instance

# Outline

1 Unakrsna validacija

2 K najbližih suseda

# Algoritam K najблиžih suseda (KNN)

klasifikacija instance je zasnovana na sličnosti sa drugim instancama.

Neka je:

- $k$  zadati broj suseda
- $D$  skup instanci za treniranje; svaka instanca je predstavljena sa  $(x, y)$  gde su  $x$  vrednosti atributa za predviđanje, a  $y$  klasa kojoj instanca pripada
- svaka test instanca  $z$  je predstavljena sa  $(x', y')$  gde su  $x'$  vrednosti atributa za predviđanje, a  $y'$  dodeljena klasa

# Algoritam K najблиžih suseda (KNN)

- 1: **for all**  $z = (x', y')$  **do**
- 2:   izračunatu  $dist(x', x)$  (rastojanje između instance  $z$  i svake instance  $(x, y) \in D$ )
- 3:   izdvojiti  $D_z \subseteq D$ , skup  $k$  najблиžih trening instanci test instanci  $z$
- 4:    $y' = \arg \max_v \sum_{(x_i, y_i) \in D_z} I(v = y_i)$
- 5: **end for**

# Preprocesiranje

- `sklearn.preprocessing`
- svaki atribut se zasebno obrađuje
- standardizacija
  - `scale(X)` - vraća standardizovane vrednosti
  - `StandardScaler` - klasa za standardizaciju
    - `fit(x)`
    - `transform(x)`
    - `inverse_transform(x)`
    - `fit_transform(x)`

# Preprocesiranje

- skaliranje na određeni interval
  - $\text{MinMaxScaler}(\text{feature\_range}=(0, 1))$  - klasa za skaliranje
    - $\text{fit}(x)$
    - $\text{transform}(x)$
    - $\text{fit\_transform}(x)$
    - $\text{inverse\_transform}(x)$

# Klasifikacija - KNN

- `sklearn.neighbors.KNeighborsClassifier`
- parametri
  - *n\_neighbors* - broj suseda (default = 5)
  - *p* - stepen za rastojanje Minkovskog
  - *metric* - izbor metrike za rastojanje, (default ‘minkowski’), moguće vrednosti su definisane u `sklearn.neighbors.DistanceMetric`
  - *weights* - težina suseda
    - *uniform* - svi susedi imaju istu težinu (default)
    - *distance* - težina suseda je obrnuta rastojanju - najблиži sused ima najveću težinu, najdaljeniji sused ima najmanju težinu

# Klasifikacija - KNN

- metode

- $fit(x)$  - pravi model
- $predict(x)$  - određuje klase instancama
- $kneighbors(x)$  - vraća rastojanje i poziciju suseda

# Klasifikacija - KNN

- Preprocesiranje

- Normalizacija numeričkih atributa

$$x' = \frac{2 * (x - x_{min})}{x_{max} - x_{min}} - 1$$

- Kodiranje kategoričkih atributa primenom kodiranja *jedan-od-c*, gde je *c* broj kategorija. Vrednost se kodira kao binarni vektor dimenzije *c*. Prva kategorija ima vrednost (1,0,...,0), druga (0,1,0,...,0), a poslednja (0,0,...,1).

# Klasifikacija - KNN

- Metrike za računanje rastojanja između instance koja se klasificiše i suseda
  - (Težinsko) Euklidsko rastojanje
  - (Težinsko) Menhetn rastojanje
  - težina atributa se računa prema značajnosti atributa

$$w_i = \frac{FI_i}{\sum_{p=1}^d FI_p}$$

# Klasifikacija - KNN

- Unakrsna validacija za određivanje najboljeg  $k$  iz opsega  $[k_{min}, k_{max}]$ 
  - bira se  $k$  sa najmanjom prosečnom stopom greške

# Klasifikacija - KNN

- Izbor atributa (izbor unapred)
  - moguće zadavanje obaveznih atributa
  - u svakom koraku se bira po jedan atribut koji nije među izabranim atributima i koji najviše doprinosi smanjenju greške stope. Postupak se ponavlja dok se ne zadovolji jedan od kriterijuma za zaustavljanje.

# Klasifikacija - KNN

- Instance sa nedostajućim vrednostima se ne uzimaju u obzir
- Instanca se klasificuje prema glasovima k najблиžih suseda - dodeljuje se klasa sa najviše glasova.