Istraživanje podataka 1

Vežbe 6

26. März 2021

Outline

Outline

Istraživanje podataka u programskom jeziku Python

- biblioteke
  - pandas - obezbeđuje strukture podataka za rad sa relacionim ili označenim podacima.
  - *scikit-learn* - biblioteka za mašinsko učenje

NumPy

Biblioteka *NumPy* osnovna biblioteka za naučno izračunavanje u programskom jeziku Python.

- **ndarray** (alias array) klasa za nizove
  import numpy as np
  b = np.array([6, 7, 8])
- dimenzije se nazivaju osama (eng. axes)

pandas

Biblioteka *pandas* obezbeđuje strukture podataka za rad sa relacionim ili označenim podacima.
Osnovne strukture podataka su:

- **Series** za rad sa 1D podacima
- **DataFrame** za rad sa 2D podacima

Series - primer

```
import pandas as pd
import numpy as np
```

```
s1 = pd.Series([1,2,3,5])
```

```
0    1
1    2
2    3
3    5
dtype: int64
```

```
s1[2]
```

```
3
```

```
s1.get(1)
```

```
2
```

```
s1.get(8, np.nan)
```

```
nan
```

Series - primer

```
s1 = pd.Series([1,2,3,5], index=['a', 'b', 'c', 'd'])
```

```
a    1
b    2
c    3
d    5
dtype: int64
```

```
s1['b']
```

```
2
```

Series

Neki atributi:

- **index** - oznake vrednosti
- **values** - vrednosti

Neke metode:

- **keys** - oznake vrednosti
- **value_counts** - broj pojavljivanja za svaku vrednost

Operacije $(+, -, *, /)$ se vrše nad elementima sa istim vrednostima indeksa

Series - primer

```
s1.index
```

```
Index(['a', 'b', 'c', 'd'], dtype='object')
```

```
s1.values
```

```
array([1, 2, 3, 5], dtype=int64)
```

```
s1.value_counts()
```

```
5    1
3    1
2    1
1    1
dtype: int64
```

DataFrame

DataFrame je 2D označena struktura podataka sa kolonama koje mogu biti različitih tipova.

- **index** - oznaka reda
- **column** - oznaka kolone

pandas.DataFrame(data, index, columns)

DataFrame - primer

```
d1= {'prva': pd.Series([1,2,3, 4], index=['a', 'b', 'c', 'd']),
     'druga': pd.Series(['x', 'y', 'z'], index=['a', 'b', 'c']
                        )}
```

```
df1=pd.DataFrame(d1)
```

```
df1
```

	prva	druga
a	1	x
b	2	y
c	3	z
d	4	NaN

DataFrame

Za tipove kolona *pandas* koristi

- nizove biblioteke NumPy (float, int, bool)
- pandas.CategoricalDtype - kategorički podaci (sa kategorijama i poretkom)
  t = pd.CategoricalDtype(categories=['b', 'a'], ordered=True)
  pd.Series(['a', 'b', 'a', 'c'], dtype=t)
- za čuvanje niski koristi dtype *object*
- ...

DataFrame - primer

```
df2 = pd.DataFrame({'cat' : pd.Categorical(['a', 'b', 'a', 'x'],
                                           categories=['b', 'a'], ordered=True),
                    'num' : [1,2,2,3],
                    'obj' : ['c', 'd', 'e', 'c']
                    })
```

```
df2
```

	cat	num	obj
0	a	1	c
1	b	2	d
2	a	2	e
3	NaN	3	c

DataFrame - primer

```
df2.dtypes
```

```
cat     category
num        int64
obj       object
dtype: object
```

DataFrame

Izdvajanje redova i kolona:

- **iloc** - izdvajanje redova i kolona prema poziciji
  iloc[izbor reda, izbor kolone]
  izbor: pozicija (jedan red), [lista pozicija], opseg (donja pozicija : gornja pozicija)
- **loc** - izdvajanje redova i kolona prema oznaci/indeksu
  loc[izbor reda, izbor kolone]
  izbor: labela, [lista labela], opseg (donja labela : gornja labela)
- **df[col]** - izdvajanje kolone
- **df[uslov]** - izdvajanje redova prema uslovu

DataFrame - primer

```
df1['prva']
```

```
d    4
c    3
b    2
a    1
Name: prva, dtype: int64
```

```
df1['prva']['c']
```

```
3
```

DataFrame - primer

```
df2
```

	cat	num	obj
0	a	1	c
1	b	2	d
2	a	2	e
3	NaN	3	c

```
df2.iloc[0,1]   #[pozicija reda, pozicija kolone]
```

```
1
```

DataFrame - primer

```
df2.iloc[1,1:]
```

```
num     2
obj     d
Name: 1, dtype: object
```

```
df2.iloc[[1],1:]
```

	num	obj
1	2	d

```
df2.iloc[[1,3],1:]
```

	num	obj
1	2	d
3	3	c

DataFrame - primer

```
df1
```

	druga	prva
d	NaN	4
c	z	3
b	y	2
a	x	1

```
df1.loc['a']
```

```
druga    x
prva     1
Name: a, dtype: object
```

DataFrame - primer

```
df1.loc['c':'a']
```

	druga	prva
c	z	3
b	y	2
a	x	1

```
df1.loc[['a', 'c'], ['prva', 'druga']]
```

	prva	druga
a	1	x
c	3	z

DataFrame - primer

```
df1[df1['prva']>1]
```

	druga	prva
d	NaN	4
c	z	3
b	y	2

```
df1[df1['prva']>1]['druga']
```

```
d    NaN
c      z
b      y
Name: druga, dtype: object
```

```
df1[df1['prva']>1][['druga']]
```

	druga
d	NaN
c	z
b	y

DataFrame

Neke metode:

- **sort_index** - sortiranje redova/kolona prema oznakama
- **sort_values** - sortiranje redova/kolona prema vrednostima
- **describe** - sortiranje redova/kolona prema vrednostima
- **any** - provera da li je neka vrednost *True*
- **all** - provera da li su sve vrednosti *True*
- **drop** - brisanje reda

DataFrame - primer

```
df1.sort_index(ascending=False, inplace=True)
```

```
df1
```

	prva	druga
d	4	NaN
c	3	z
b	2	y
a	1	x

DataFrame - primer

```
df1.sort_index(ascending=True, inplace=True, axis=1)
```

```
df1
```

	druga	prva
d	NaN	4
c	z	3
b	y	2
a	x	1

DataFrame - primer

```
df2.describe(include='all')
```

	cat	num	obj
count	3	4.000000	4
unique	2	NaN	3
top	a	NaN	c
freq	2	NaN	2
mean	NaN	2.000000	NaN
std	NaN	0.816497	NaN
min	NaN	1.000000	NaN
25%	NaN	1.750000	NaN
50%	NaN	2.000000	NaN
75%	NaN	2.250000	NaN
max	NaN	3.000000	NaN

DataFrame - primer

```
df2['new']=df2['num']*2
```

```
df2
```

	cat	num	obj	new
0	a	1	c	2
1	b	2	d	4
2	a	2	NaN	4
3	NaN	3	c	6

DataFrame - primer

```
df2.isna()
```

	cat	num	obj	new
0	False	False	False	False
1	False	False	False	False
2	False	False	True	False
3	True	False	False	False

```
df2.isna().any()
```

```
cat      True
num     False
obj      True
new     False
dtype: bool
```

```
df2.isna().any().any()
```

```
True
```

DataFrame

Statistike:

- **mean**
- **quantile**
- **mode** - sortiranje redova/kolona prema vrednostima
- **nunique** - sortiranje redova/kolona prema vrednostima
- ...

DataFrame - primer

```
df2.mean()
```

```
num    2.0
dtype: float64
```

```
df2.mean(axis=1)
```

```
0    1.0
1    2.0
2    2.0
3    3.0
dtype: float64
```

DataFrame - primer

```
df2.quantile(0.25)
```

```
num     1.75
Name: 0.25, dtype: float64
```

```
df2.quantile([0.25, 0.5, 0.75])
```

	num
0.25	1.75
0.50	2.00
0.75	2.25

Obrada nedostajućih vrednosti

numpy.nan - nedostajuća vrednost
Metode za rad sa nedostajućim vrednostima:

- **isnull** - detekcija nedostajućih vrednosti (za *numpy.nan* vraća *True*)
- **notnull** - detekcija nedostajućih vrednosti (za *numpy.nan* vraća *False*)
- **fillna** - zamena *numpy.nan* sa zadatim argumentom
- **dropna** - brisanje redova/kolona sa *numpy.nan* vrednostima
- **replace** - zamena jedne vrednosti sa drugom

DataFrame - primer

```
df1
```

	druga	prva
d	NaN	4.0
c	z	NaN
b	y	2.0
a	x	1.0

```
df1['prva'].replace(np.NaN, df1['prva'].mean(), inplace=True)
```

```
df1
```

	druga	prva
d	NaN	4.000000
c	z	2.333333
b	y	2.000000
a	x	1.000000

DataFrame - primer učitavanja skupa

```
iris = pd.read_csv('iris.csv')
```

```
iris.shape
```

```
(146, 5)
```

```
iris.head(5)
```

	Sepal_Length	Sepal_Width	Petal_Length	Petal_Width	Species
0	5.1	3.5	1.4	0.2	setosa
1	4.9	3.0	1.4	0.2	setosa
2	4.7	3.2	1.3	0.2	setosa
3	4.6	3.1	1.5	0.2	setosa
4	5.0	3.6	1.4	0.2	setosa

Klasifikacija: podela na skup za treniranje i testiranje

- *model_selection.train_test_split* - podela skupa podataka na deo za treniranje modela i deo za testiranje
  - *train_size* - veličina skupa za treniranje
    - ako je realan broj onda je procenat instanci u trening skupu
    - ako je ceo broj onda je broj instanci u trening skupu
  - *test_size* - veličina skupa za testiranje, default=0.25
    - ako je realan broj onda je procenat instanci u test skupu
    - ako je ceo broj onda je broj instanci u test skupu
  - *shuffle* - da li se vrši mešanje instanci u skupu pre podele, default=True
  - *random_state* - seme za generisanje slučajnih brojeva
  - *stratify* - stratifikovana podela, navodi se lista oznaka klasa

Klasifikacija: drveta odlučivanja u scikit-learn

Klasa tree.DecisionTreeClassifier

- neki parametri
  - *criterion* - kriterijum za podelu : gini, entropy , default=gini
  - *max_depth* - maksimalna dubina drveta: ako nije zadata, drvo se širi do čistih listova ili dok čvorovi imaju više od *min_samples_split* instanci.
  - *min_samples_split* - minimalan broj instanci u čvoru da bi došlo do podele čvora : default=2

Klasifikacija: drveta odlučivanja u scikit-learn

- neki parametri
  - *min_samples_leaf* - minimalan broj instanci u listu: default=1
  - *max_leaf_nodes* - maksimalan broj listova
  - *min_impurity_decrease* - minimalno smanjenje nečistoće. Čvor će biti podeljen ako je smanjenje nečistoće veće ili jednako od zadate vrednosti.

Klasifikacija: drveta odlučivanja u scikit-learn

- neki atributi
  - *classes_* - oznake klasa
  - *feature_importances_* - značajnost atributa
  - *tree_* - drvo odlučivanja

Klasifikacija: drveta odlučivanja u scikit-learn

- metode
  - *fit(x,y)* - za pravljnje drveta odlučivanja na osnovu skupa (x,y)
  - *predict(x)* - za predviđanje klase za x
  - *predict_proba(x)* - vraća verovatnoću klasa za x. Predviđena verovatnoća klase je procenat instanci te klase u listu. Redosled klasa odgovara onome u atributu *classes_*.

Klasifikacija: drveta odlučivanja u scikit-learn

- *tree.plot_tree* - funkcija za iscrtavanje drveta odlučivanja
  - *decision_tree*
  - *feature_names* - imena atributa radi lepšeg prikaza test-uslova, default=None
  - *class_names* - imena klasa radi prikaza imena najzastupljenije klase, default=None
  - *filled* - svakoj klasi se dodeljuje boja i čvorovi se boje prema najzastupljenijom klasi, default=None
  - *impurity* - prikaz nečistoće čvora, default=True
  - *rounded* - prikaz čvora sa zaobljenih uglovima, default=False

Klasifikacija: mere performansi

- *confusion_matrix(y_true, y_pred)* - matrica konfuzije
- *accuracy_score(y_true, y_pred, normalize=True)* - preciznost, ako je normalize=False vraća broj tačno klasifikovanih instanci
- *precision_score(y_true, y_pred, average)* - preciznost
- *recall_score(y_true, y_pred, average)* - odziv
- *f1_score(y_true, y_pred, average)*
- *classification_report(y_true, y_pred)* - tekstualni izveštaj sa glavnim merama za klasifikaciju

Klasifikacija: mere performansi

- opcije za *average*
  - average=None, rezultat je skor za svaku klasu
  - average=binary, vraća rezultat samo za klasu navedenu preko parametra *pos_label*
  - average=micro, mera se računa globalno, brojanjem ukupnih tp, fn i fp instanci.
  - average=macro, računa meru za svaku klasu posebno i vraća srednju vrednost
  - average=weighted, računa meru za svaku klasu posebno i vraća srednju vrednost ponderisanu podrškom.

Outline

Unakrsna validacija

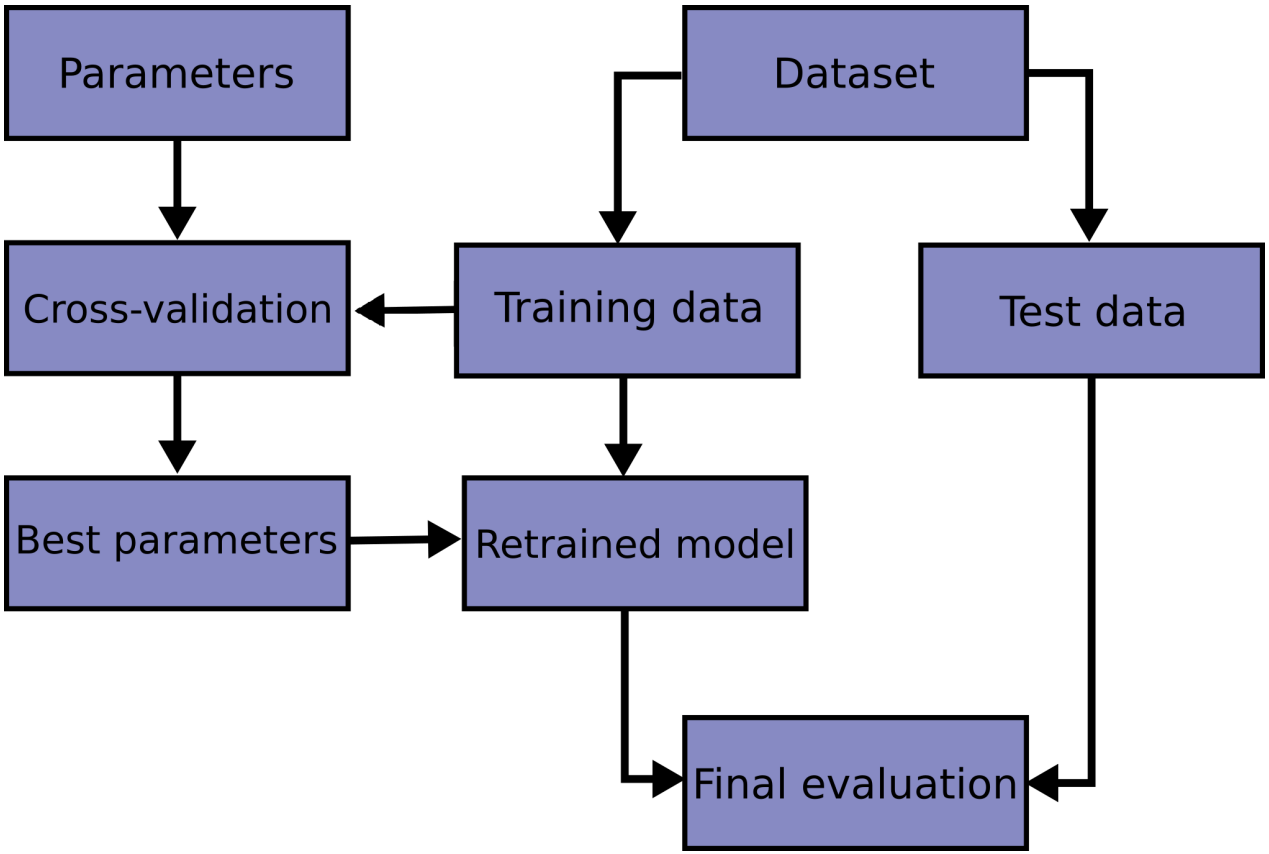

- Podešavanje hiper-parametara procenjivača

Unakrsna validacija

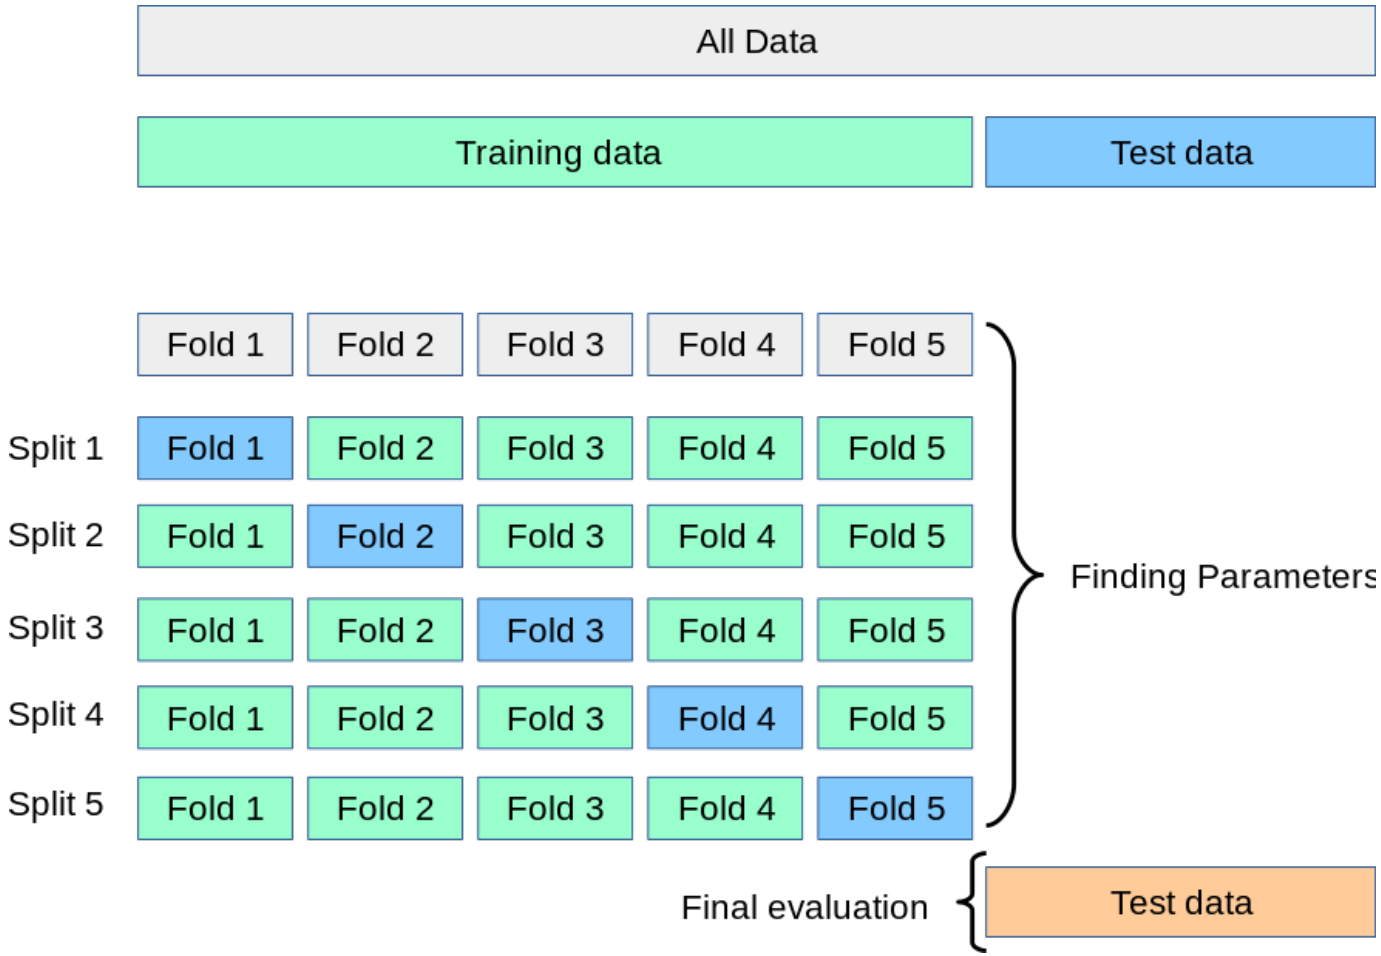

Unakrsna validacija

- 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)* - pravljnje modela sa optimalnim parametrima na osnovu skupa (x,y)
  - *predict(x)* - predviđanje klase za test instancex