

# Istraživanje podataka 1 - vežbe 10, 2020.

## 1 Zadaci

1. U programskom jeziku Python izvršiti klasterovanje nad skupom *unbalance.csv* primenom algoritama K-sredina, DBSCAN i hijerarhijskog sakupljajućeg klasterovanja za različit broj klastera. Skup *unbalance.csv* sadrži numeričke attribute  $X$  i  $Y$ . Rezultate klasterovanja prikazati pomoću šeme sa raspršenim elementima. Za svaki algoritam napraviti i grafik koji prikazuje silueta koeficijent za različit broj izdvojenih klastera.

Rešenje: *klasterovanje\_nebalansiranog\_skupa.py*

2. Izvršiti klasterovanje država na osnovu podataka o ishrani stanovništva primenom algoritma K-sredina u alatu IBM SPSS Modeler. Skup *ishrana.csv* sadrži podatak koliko su određene namirnice zastupljene u ishrani stanovništva nekih država. Vrednosti numeričkih atributa su izražene u procentima. Atributi skupa su:

- *Country* - država
- *RedMeat* - crveno meso
- *Eggs* - jaja
- *Milk* - mleko
- *Fish* - riba
- *Cereals* - žitarice
- *Starch* - skrob
- *Nuts* - koštunjavo voće
- *Fruit&Veg* - voće i povrće

Rešenje:

- radni tok: *drzave\_ishrana.str*
- komentari: *ipVezbe10Primer2.pdf*

3. U programskom jeziku Python izvršiti hijerarhijsko sakupljajuće klasterovanje nad skupom u datoteci *studenti.csv* za različit broj klastera u intervalu od 2 do 34 i primenom različitih veza za određivanje bliskosti dva klastera. Skup u datoteci *studenti.csv* sadrži podatke o studentima koji su diplomirali. Za svakog studenta su izdvojeni sledeći podaci: indeks, naziv smeru koji je diplomirao, dužina studiranja u godinama, broj položenih ispita i prosečna ocena. Za svaku primenjenu vezu

- rezultat klasterovanja prikazati pomoću grafika sa silueta koeficijentom i brojem izdvojenih klastera

- za klasterovanje sa najvećim senka koeficijentom izdvojiti deskriptivne statistike za svaki klaster da bi se uočilo šta ga karakteriše

Rešenje: *klasterovanje\_studenti.py*