

# **k-Srednjih vrednosti (k-Means)**

TEHNIKA KLASTEROVANJA UZORAKA

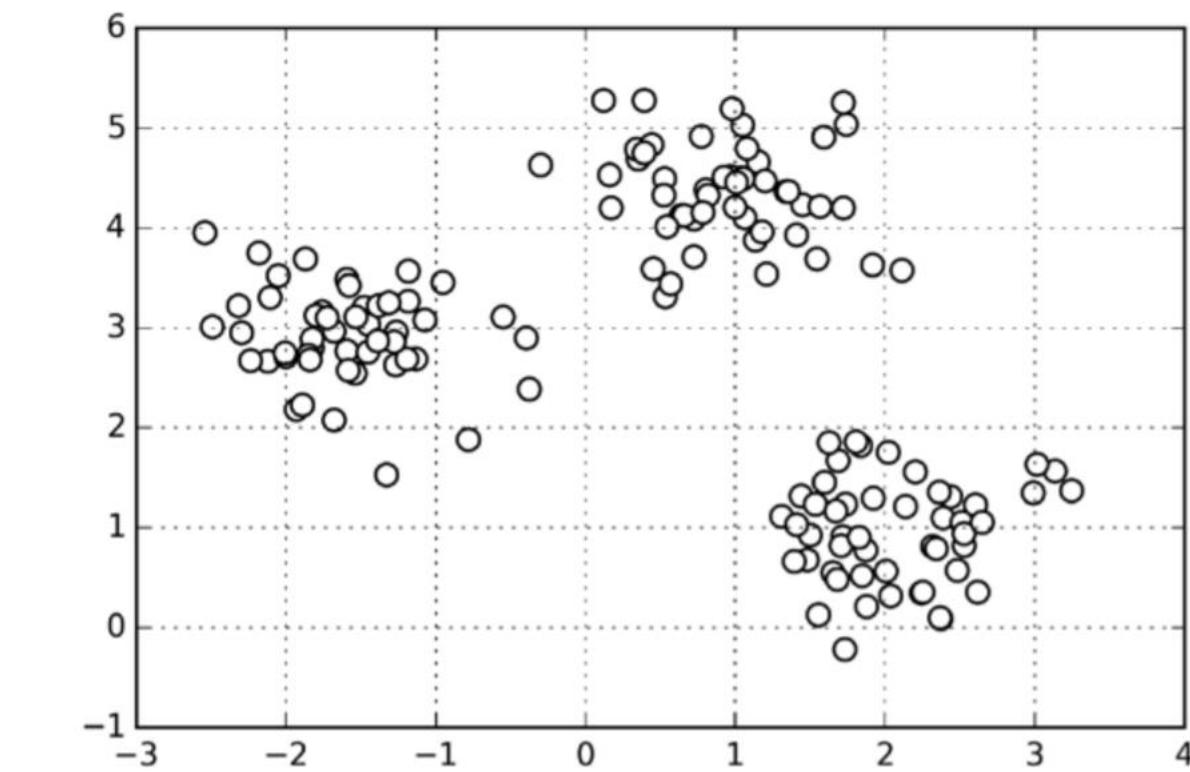
# Klasterovanje

- ▶ Za razliku od klasifikacije, ovde ne postoji "tačno" rešenje
- ▶ Zato je ocena uspešnosti algoritma teže doneti u odnosu na klasifikaciju
- ▶ Rezultat rešenja zavisi od domena i slučaja primene – jedno isto rešenje može biti različito ocenjeno u različitim slučajevima primene
- ▶ Zahteva angažovanje domenskih eksperata koji će evaluirati rešenje

# Tipovi klasterovanja

- ▶ Hijerarhijski algoritmi
  - ▶ Pronalaze sledeće klastere koristeći prethodno uspostavljene
  - ▶ bottom-up – kreću od svakog elementa kao pojedinačnog klastera i spajaju ih sukcesivno u veće
  - ▶ top-down – kreću od celog skupa kao jednog klastera i uzastopno ga smanjuju u manje klastere
- ▶ Parcionalno klasterovanje – prepoznaju se svi klasteri odjednom
  - ▶ K-means

# Klasterovanje



# Rastojanje

- ▶ Mera udaljenosti određuje kako se računa sličnost dva elementa i utiče na oblik klastera

- ▶ Euklidska distanca

$$d(x, y) = \sum_{i=1}^p |x_i - y_i|$$

- ▶ Menhetn

$$d(x, y) = \sqrt[2]{\sum_{i=1}^p |x_i - y_i|^2}$$

- ▶ Maksimum

$$d(x, y) = \max_{1 \leq i \leq p} |x_i - y_i|$$

- ▶ Ugao između dva vektora može se koristiti kao mera udaljenosti kada postoji više dimenzija podataka

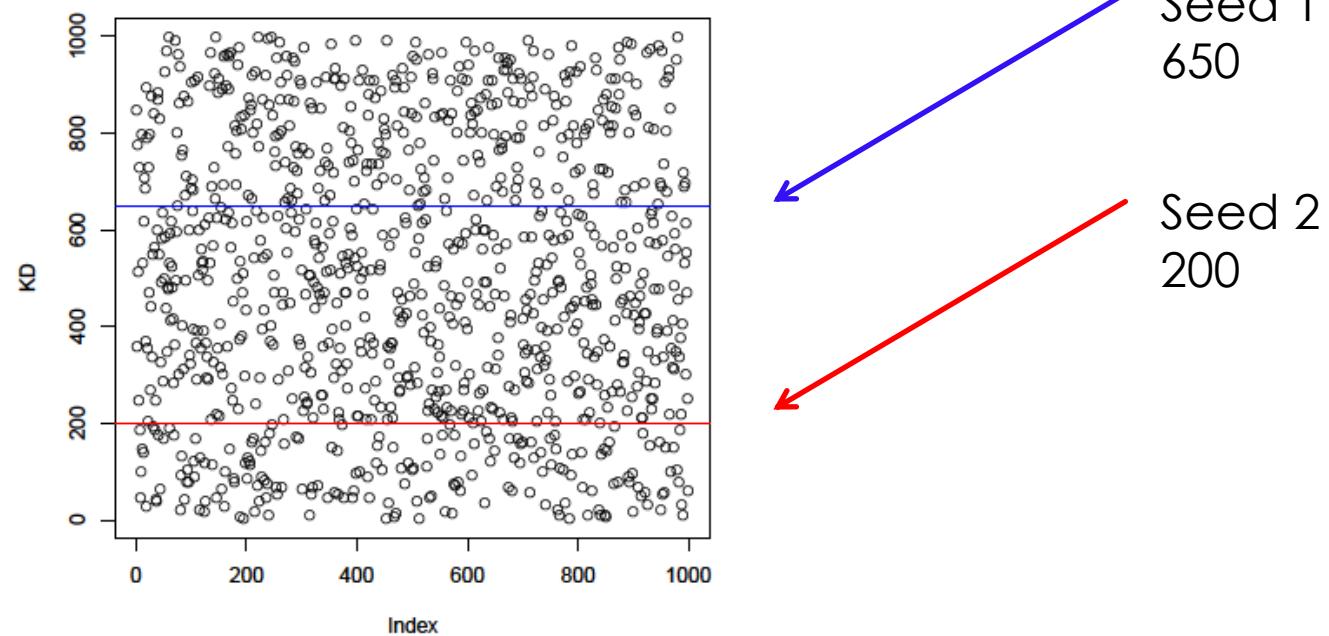
- ▶ Minimalan broj zamena da bi se jedan element promenio u drugi se može koristiti kao mera udaljenosti

# K-means

- ▶ Najpoznatiji i najjednostavniji algoritam klasterovanja (klasterizacije)
- ▶ Pripada tehnikama nenadgledanog učenja
- ▶ Sličnost instanci se može procenjivati primenom neke od mera za računanje:
  - ▶ Sličnosti (npr. kosinusna sličnost ili koeficijent korelacije)
  - ▶ Udaljenosti dve instance (npr. Euklidsko ili Menhetn rastojanje)

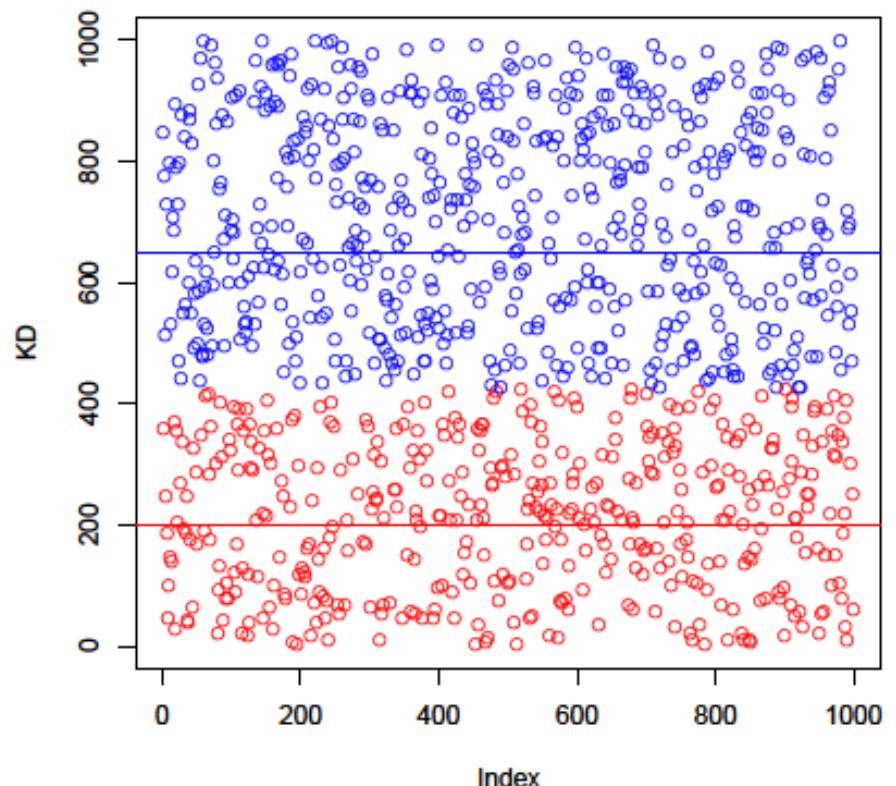
# K-means – Osnovna verzija

- ▶ Slučajan izbor K težišta klastera (centroida)



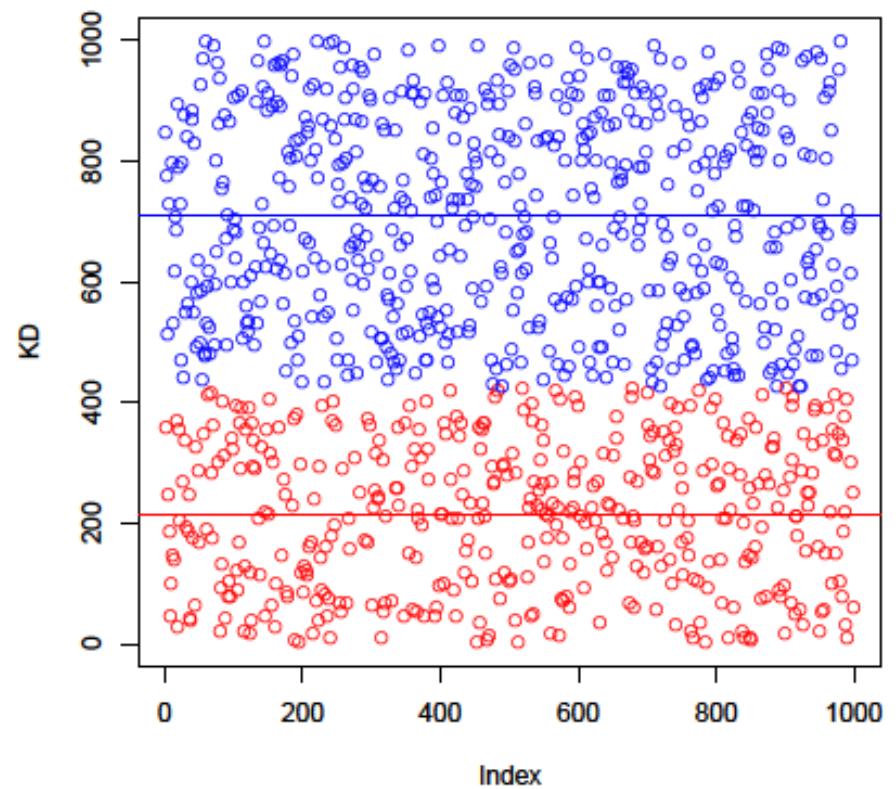
# K-means – Osnovna verzija

- ▶ Izračunati rastojanje svakog objekta od svakog klastera  
(Euklidsko rastojanje)
- ▶ Pridružiti svaki objekat najbližem klasteru (650, 200)



# K-means – Osnovna verzija

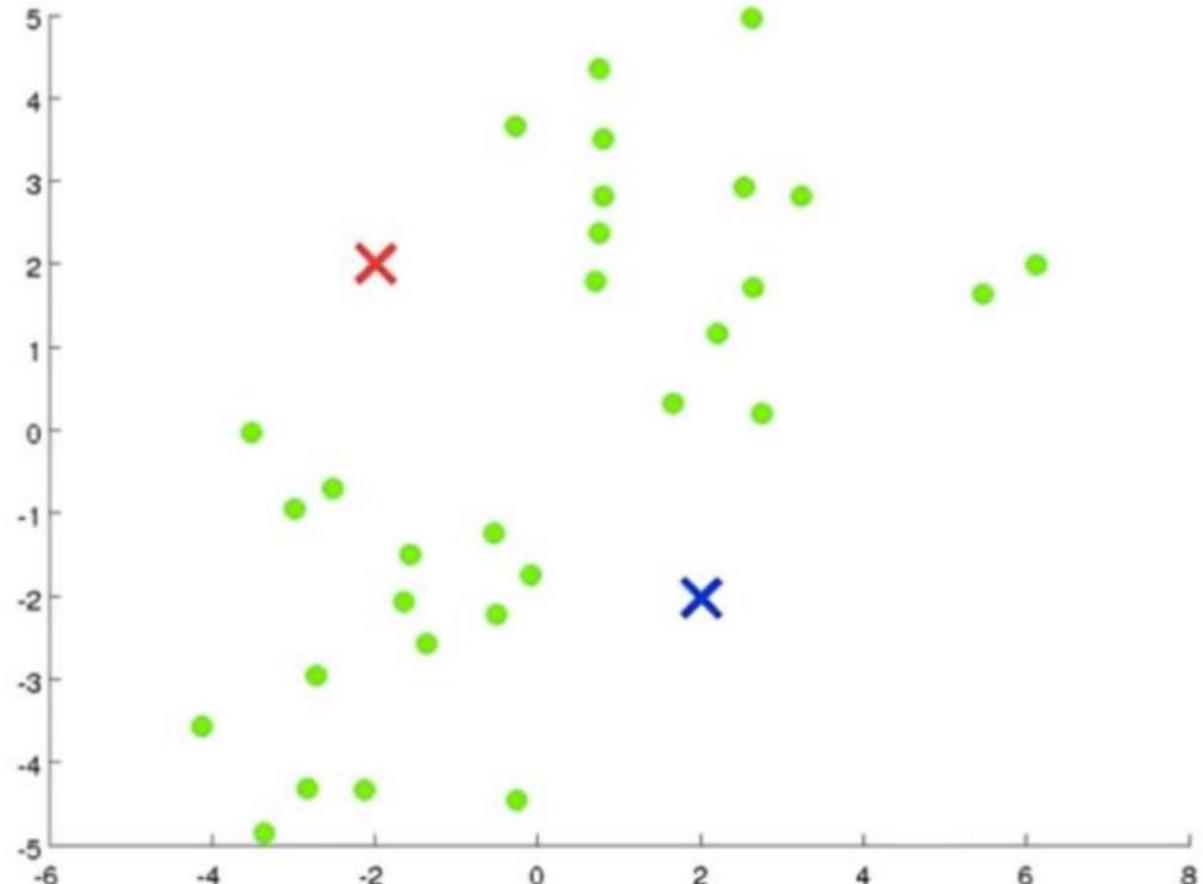
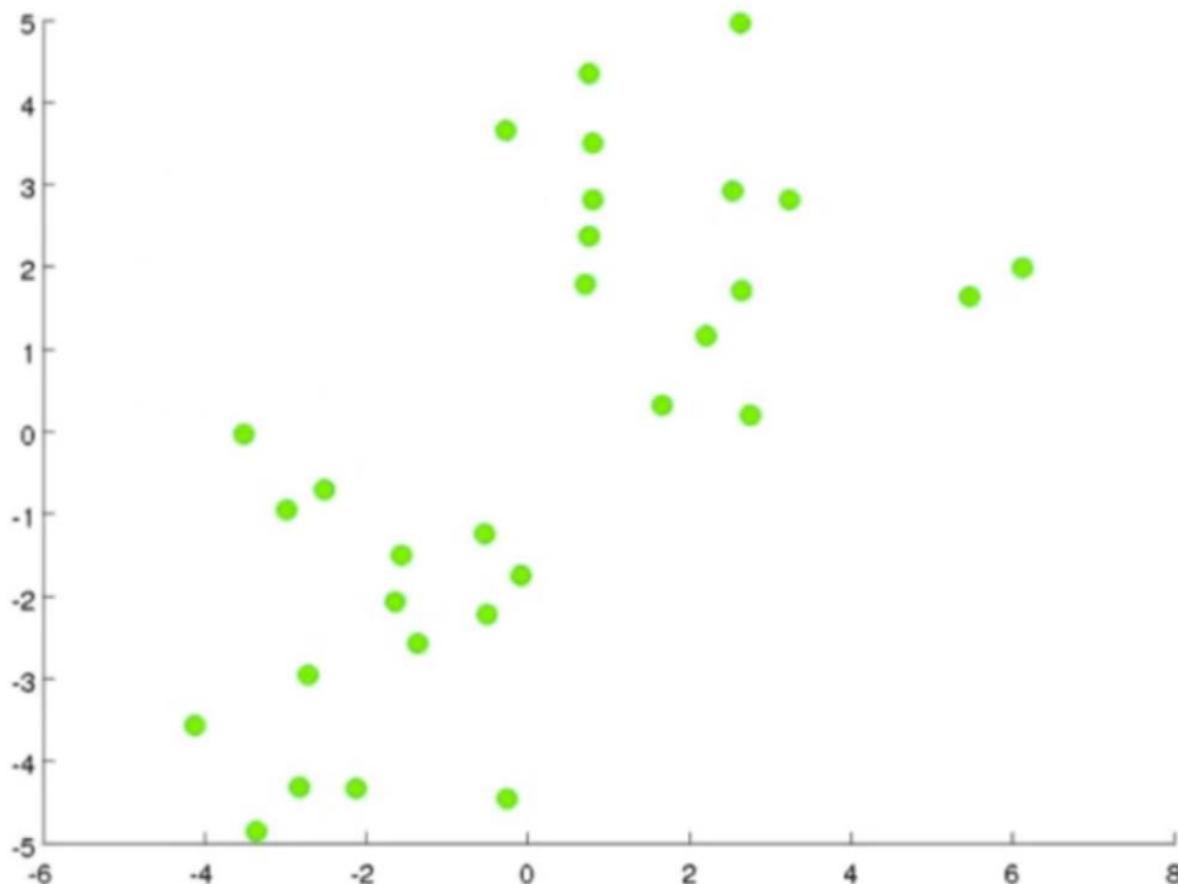
- ▶ Izračunati novi centroid za svaki klaster (708.9, 214.2)



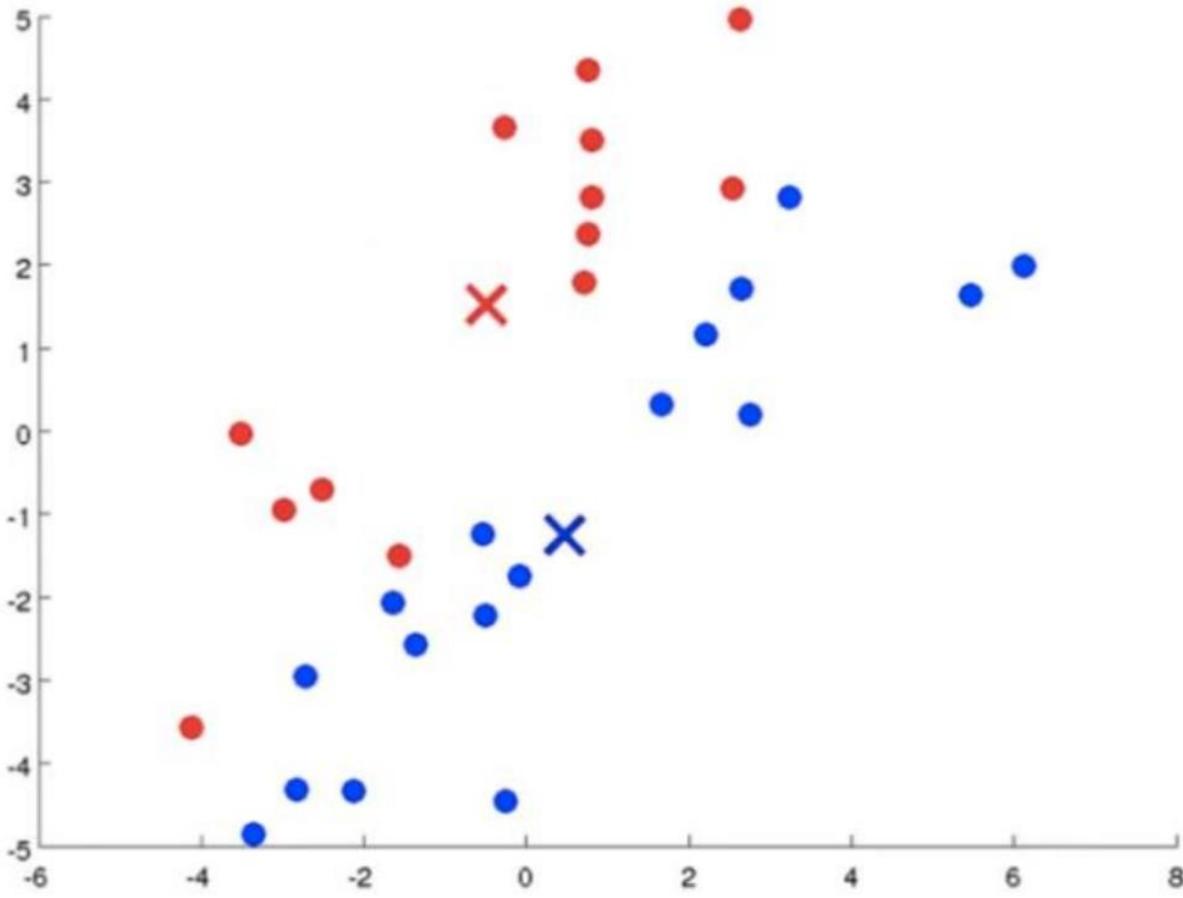
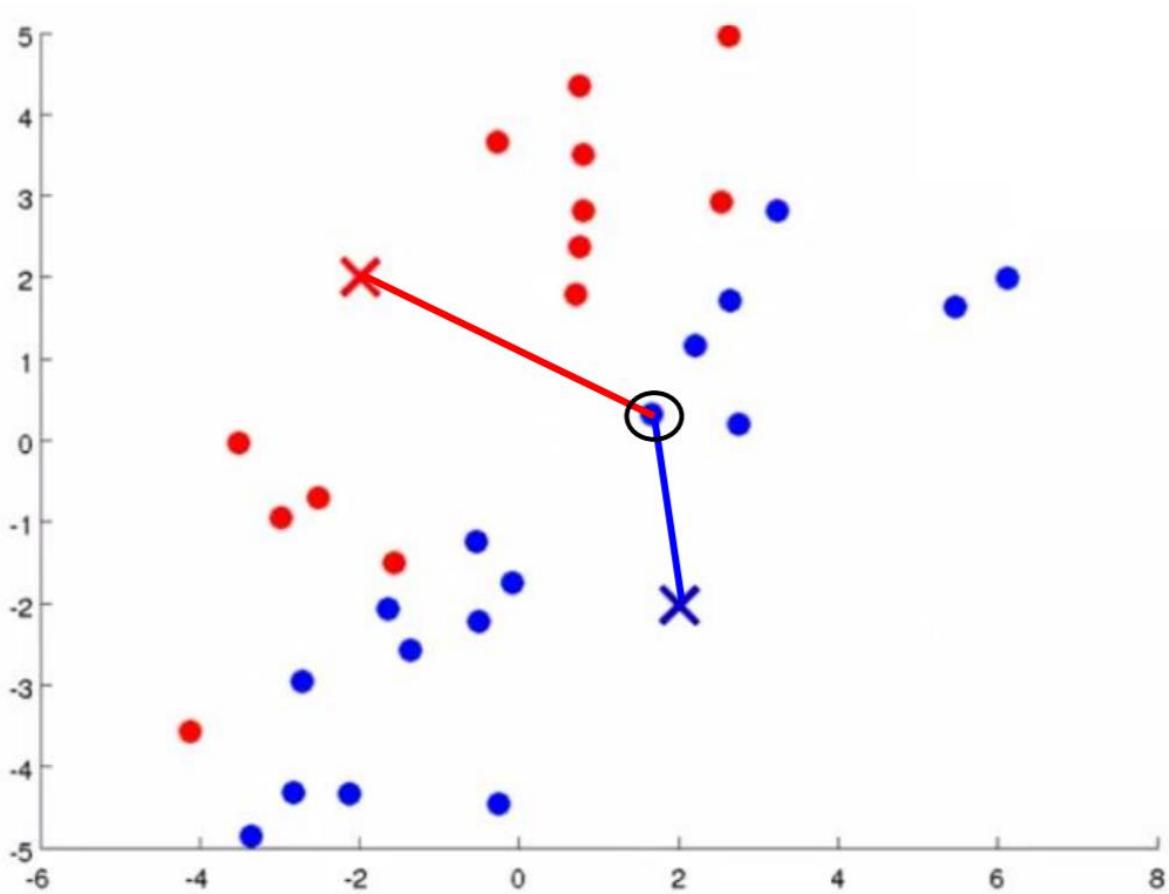
# K-means – Osnovna verzija

- ▶ Nastaviti iteracije:
  - ▶ Izračunati rastojanje od objekata do centroida klastera
  - ▶ Pridružiti objekte najbližim klasterima
  - ▶ Reizračunati nove centroide
- ▶ Završetak iteracija se zasniva na kriterijumu konvergencije
  - ▶ Nema promene u klasterima
  - ▶ Maksimalan broj iteracija

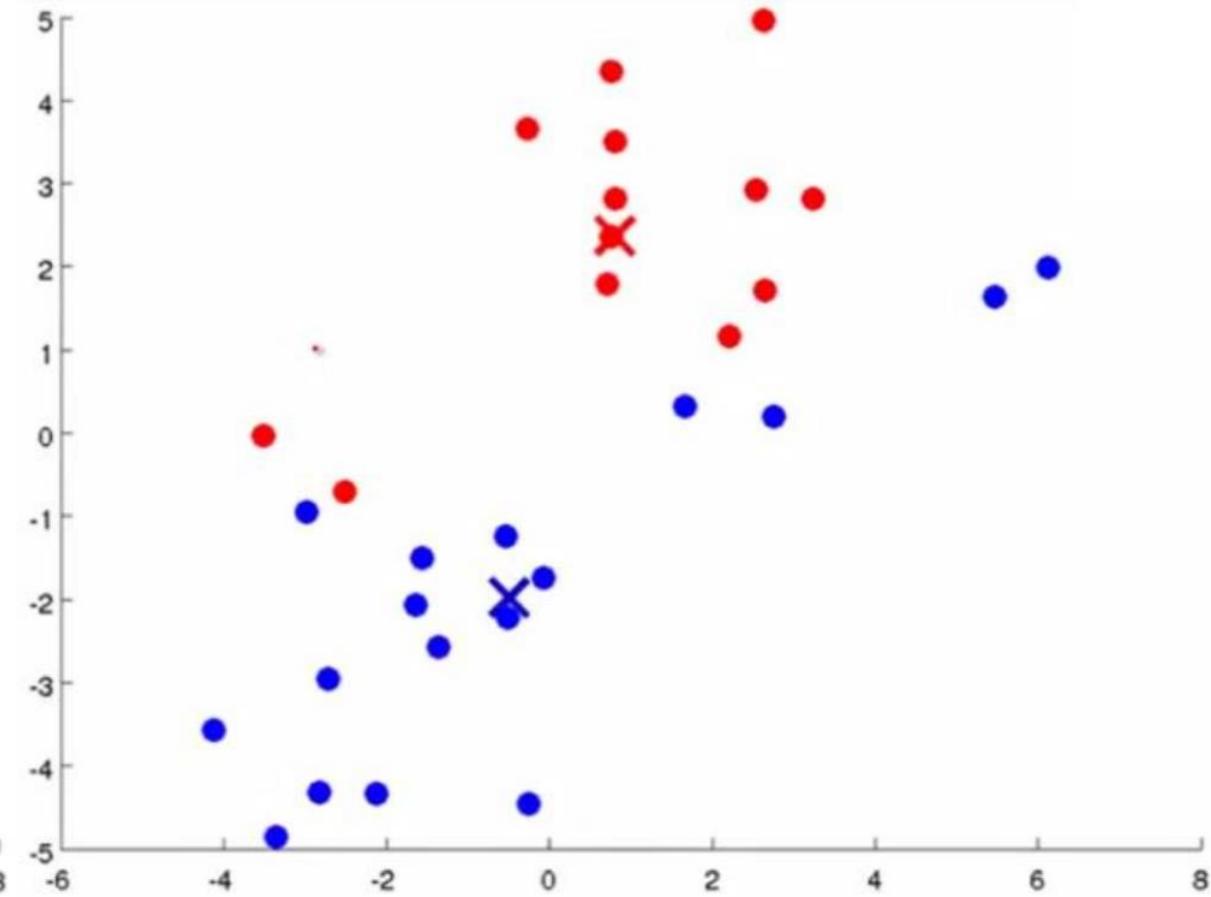
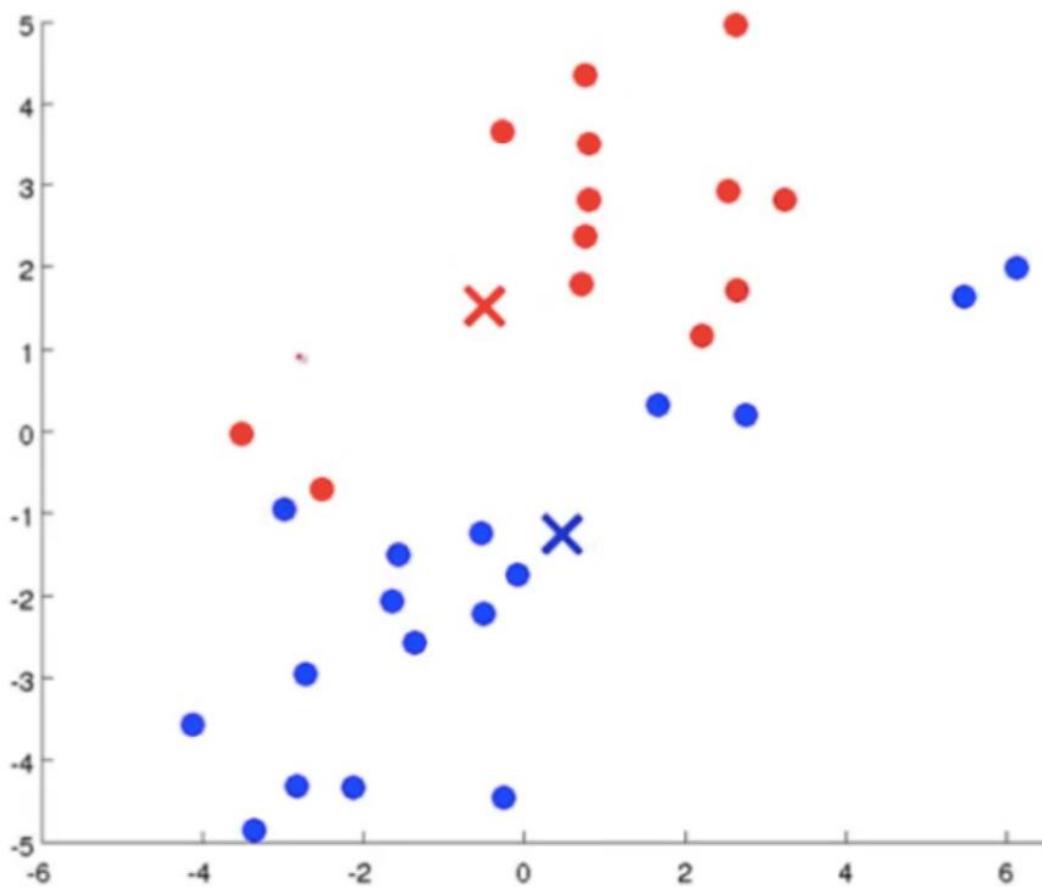
# K-means (1) - Inicialno



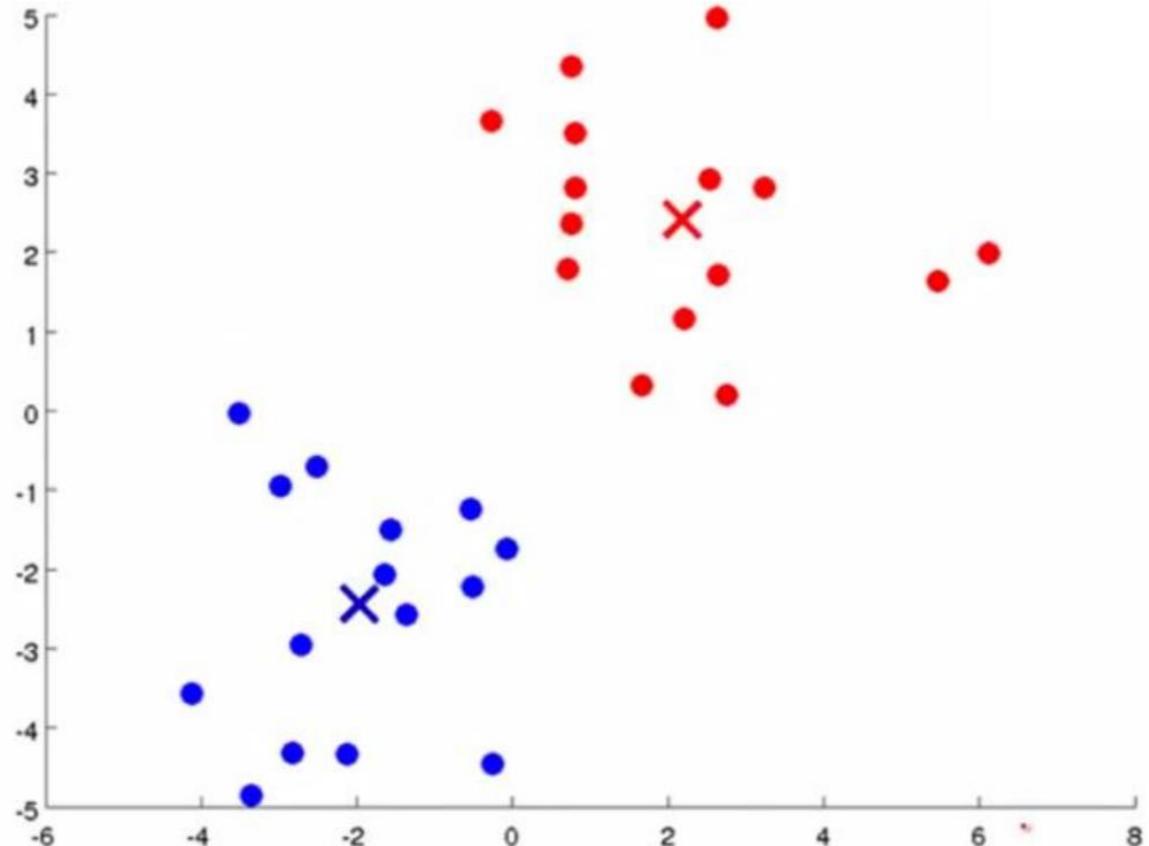
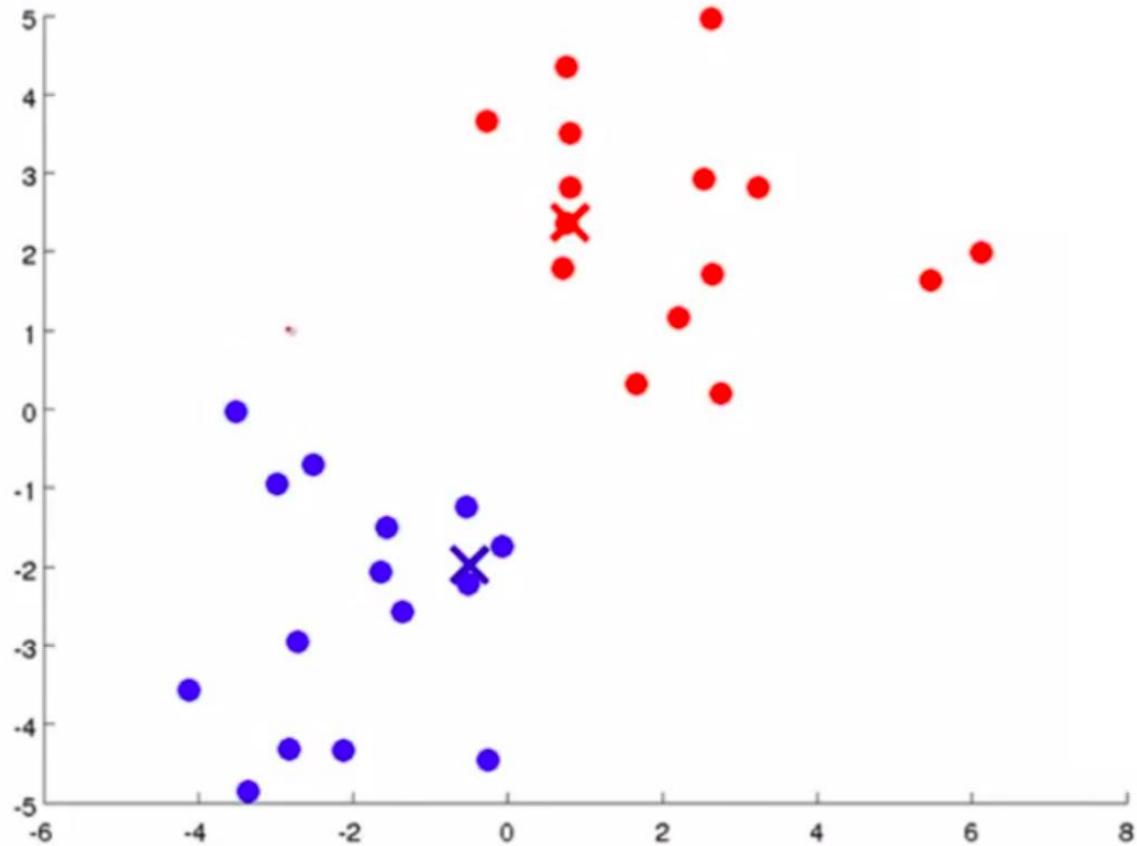
## K-means (2) – Iteracija br. 1



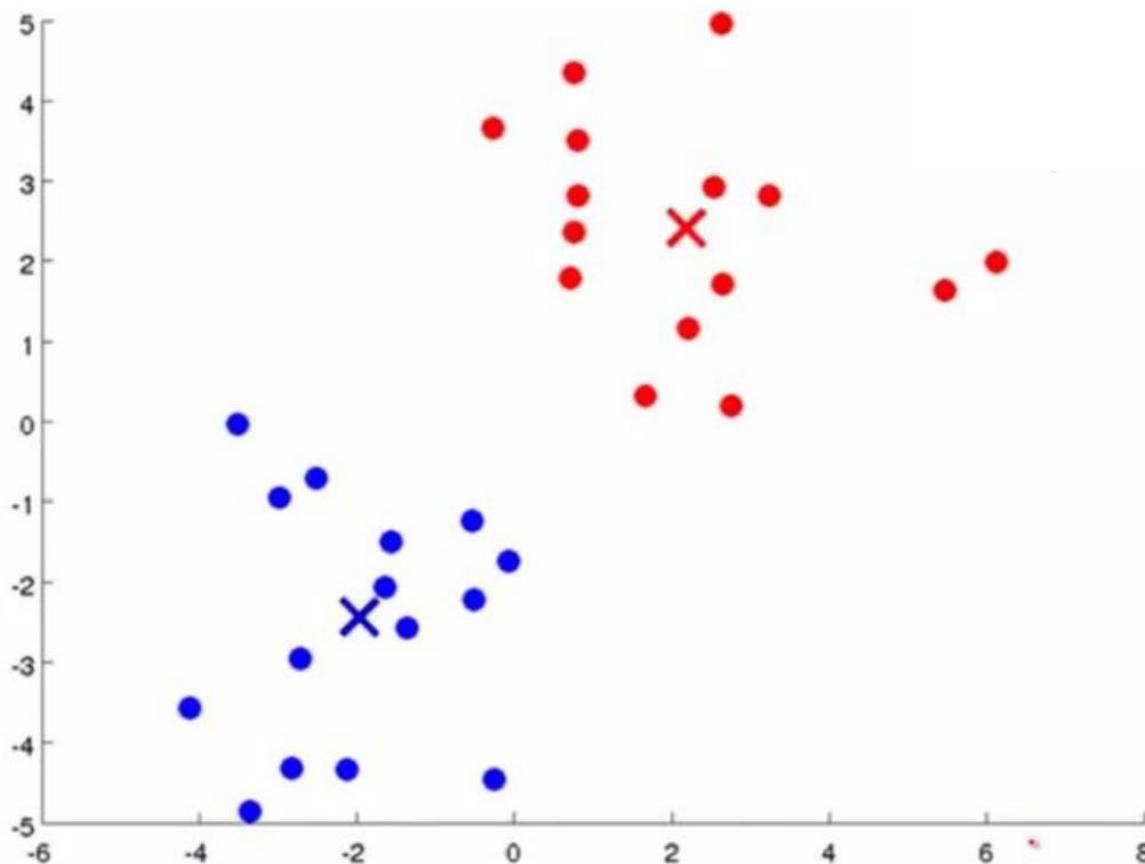
## K-means (3) – Iteracija br. 2



## K-means (4) – Iteracija br. 3



# K-means (5) - Završetak



# K-means – Koraci algoritma

- ▶ 1) Slučajan odabir K težišta klastera (centroida)
- ▶ 2) Grupisanje po klasterima - svaki uzorak (instancu) dodeljujemo najbližem centroidu (najbliže težište na osnovu odabrane metrike)
- ▶ 3) Pomeranje težišta (centroida) ka centru svih uzoraka u klasteru – za svaki klaster se izračuna novo težište uzimajući prosek instanci koje su dodeljene tom klasteru
- ▶ Koraci 2) i 3) se ponavljaju sve dok algoritam ne konvergira ili broj iteracija ne dostigne MAX

# K-means - Ulazni podaci

- ▶ Ulaz:
  - ▶ K – broj klastera
  - ▶ skup za trening sa m uzoraka (instanci), a svaki uzorak u skupu je vektor opisan sa n atributa ( $x_1, x_2, \dots, x_n$ )
  - ▶ Opciono: maksimalan broj iteracija koji se izvršava (max)

# K-means - Funkcija koštanja/distorzije

- ▶ Smisao K-means algoritma je minimizacija funkcije koštanja J (eng. cost function):

$$J(c^{(1)}, \dots, c^{(m)}, \mu_{(1)}, \dots, \mu_K) = \frac{1}{m} \sum_{i=1}^m \|x^{(i)} - \mu_{c^{(i)}}\|^2$$

$x^{(i)}$  – i-ta instanca u skupu podataka za trening,  $i = 1, \dots, m$

$c^{(i)}$  – indeks klastera u koji je instanca  $x^{(i)}$  trenutno raspoređena

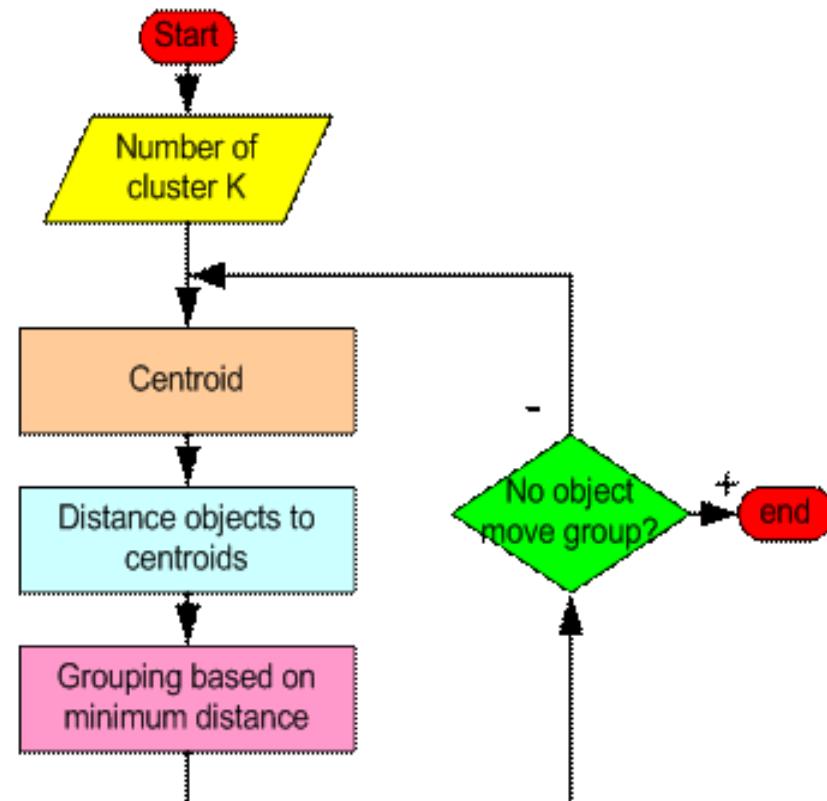
$\mu_j$  – težište klastera  $j$ ,  $j = 1, \dots, K$ , gde je  $K$  ukupan broj klastera

$\mu_{c(i)}$  – težište klastera u koji je instanca  $x^{(i)}$  trenutno raspoređena

# Minimizacija funkcije koštanja

- ▶ Minimizacija funkcije koštanja  $J$  kroz K-means algoritam:
  - ▶ Faza Grupisanja po klasterima (korak 2) minimizuje  $J$  po parametrima  $c^1, c^2, \dots, c^m$ , držeći  $\mu_1, \mu_2, \dots, \mu_k$  fiksnim
  - ▶ Faza Pomeranja težišta minimizuje  $J$  po parametrima  $\mu_1, \mu_2, \dots, \mu_k$ , držeći  $c^1, c^2, \dots, c^m$ , fiksnim

# K-mean algoritam

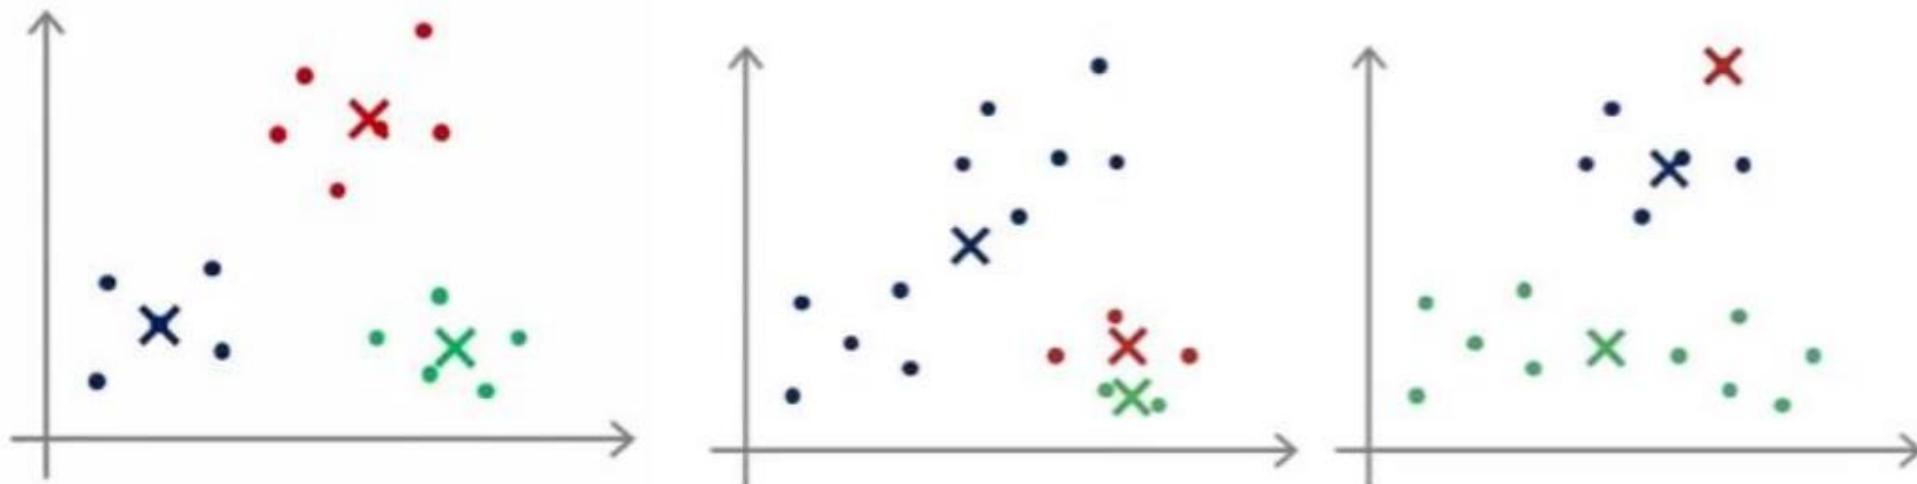


# K-means evaluacija

- ▶ Da li imamo tačno rešenje?
- ▶ Kriterijumi za procenu kvaliteta kreiranih klastera
  - ▶ Međusobna udaljenost težišta
  - ▶ Standardna devijacija pojedinačnih instanci u odnosu na težište
  - ▶ Suma kvadrata unutar klastera

# Problem inicijalnog izbora težišta

- ▶ U zavisnosti od inicijalnog izbora težišta:
  - ▶ K-means algoritam može konvergirati brže ili sporije
  - ▶ Može se doći do lokalnog minimuma i time imamo loše rešenje (lokalni minimum funkcije koštanja)



# K-means - višestrukna nasumična inic.

- ▶ Omogućava da se izbegne ulazak u lokalni minimum
- ▶ Sastoji se u sledećim koracima:

```
for i = 1 to N { // N obično ima vrednosti izmedju 50 i 1000
    Nasumično odabratи inicijalni skup težišta
    Izvršiti K-means algoritam
    Izračunati funkciju koštanja
}
```

Izabrati instancu algoritma koja daje najmanju vrednost funkcije koštanja.
- ▶ Ovaj pristup daje dobre rezultate ukoliko je broj klastera relativno mali (između 2 i 10), za veći broj klastera ne treba da se koristi.

# K-means: Kako odrediti K?

- ▶ Kako odrediti broj klastera K?
  - ▶ Ukoliko imamo znanje o oblasti/pojavi koju podaci opisuju
    - ▶ Prepostaviti broj K na osnovu domenskog znanja
    - ▶ Testirati model sa K-1, K i K+1 klastera i uporediti grešku
  - ▶ Ukoliko ne posedujemo znanje o oblasti/pojavi koju podaci opisuju
    - ▶ Krenuti od malog broja iteracija i u više iteracija testirati model uvek sa jednim klasterom više
    - ▶ U svakoj iteraciji uporediti grešku (nekom metodom) tekućeg i prethodnog modela i kad smanjenje greške postane zanemarljivo, prekinuti postupak

# K-means

- ▶ Prednosti
  - ▶ Jednostavan iterativni metod
  - ▶ Korisnik određuje „K“
- ▶ Mane
  - ▶ Suviše jednostavno – loši rezultati
  - ▶ Ponekada je teško odrediti korektnu vrednost za „K“



# Hvala na pažnji

Kontakt: [drazen.draskovic@etf.bg.ac.rs](mailto:drazen.draskovic@etf.bg.ac.rs)

[bosko.nikolic@etf.bg.ac.rs](mailto:bosko.nikolic@etf.bg.ac.rs)