

Analitička obrada podataka, I kolokvijum, 19. 4. 2021.

1. (20 bodova) Dato je 100 item-a. Označeni su brojevima od 1 do 100. Baza se sastoji od 100 transakcija. Označene su brojevima od 1 do 100. Item i pripada transakciji b akko je i djelilac b . Na primjer, 1 pripada svakoj transakciji a transakcija sa rednim brojem 12 sastoji se od 1, 2, 3, 4, 6 i 12.
 - a. Ako je $\text{min_support} = 5$ koji su item-i frekventni?
 - b. Ako je $\text{min_support} = 5$ koji su parovi item-a frekventni?
 - c. Kolika je suma $|t_1| + |t_2| + \dots + |t_{100}|$, gdje $|t|$ označava broj item-a u transakciji?
 - d. Koja transakcija sadrži najveći broj elemenata?
 - e. Koliko iznosi confidence za pravila $\{5, 7\} \rightarrow 2$ i $\{2, 3, 4\} \rightarrow 5$?
 - f. Opisati sva asocijativna pravila sa confidence = 100%.
2. (20 bodova) Za korak spajanja u Apriori algoritmu predlaže se metoda $C_k = F_{k-1} \bowtie F_1$ po kojoj kandidatski k -skup nastaje proširivanjem frekventnog $(k-1)$ -skupa sa frekventnim 1-skupom. Na primjer, ako je $k = 3$, spajanjem $\{2, 3\} \in F_2$ i $\{1\} \in F_1$ formira se $\{2, 3, 1\} \in C_3$.
 - a) Ako je $F_3 = \{123, 124, 125, 134, 135, 234, 235, 345\}$ napisati skup $C_4 = F_3 \bowtie F_1$. Obrazložiti odgovor.
 - b) Dokazati da je prethodna metoda kompletna.
3. (20 bodova) Data je šema relacione baze podataka:
time(time_key, day, day_of_week, month, quarter, year)
item(item_key, item_name, brand, type, supplier_type)
branch(branch_key, branch_name, branch_type)
location(location_key, street, city, province_or_state, country)
sales(time_key, item_key, branch_key, location_key, number_of_units_sold, price)
 - a) Nacrtati odgovarajuću šemu zvijezda koja sadrži dvije mjere: dollars_sold i units_sold
 - b) Nacrtati mrežu kuboida koja čini 4-D kocku podataka za dimenzije: time, item, branch i location
 - c) Napisati MDX upit koji generiše osnovni kuboid za 4-D kocku podataka iz zadatka pod b)
 - d) Napisati MDX upit da se napravi lista sa ukupnom zaradom za svaku prodavnicu iz Dalasa za godinu 2021.
4. (20 bodova) Data su dva binarna vektora $X=0101010001$ i $Y=0100011000$. Izračunati Hamingovo i Jakardovo rastojanje između ova dva vektora.
 - a) Napisati vezu između Hamingovog rastojanja i SMC;
 - b) Izračunati kosinus mjeru sličnosti za vektore X i Y . Objasniti šta je zajedničko za Jakardovo rastojanje i kosinus mjeru sličnosti.
5. (20 bodova) Dokazata da važi $\text{Pr}(\text{minhash}(C1) = \text{minhash}(C2)) = \text{JACCARDSIM}(C1, C2)$, gdje su $C1$ i $C2$ proizvoljne dvije kolone u karakterističnoj matrici.