

# Podaci za Data Mining

# Glava \_\_\_. Sadržaj

- Skupovi podataka
- Atributi i tipovi atributa
- Tipovi skupova podataka
- Kvalitet podataka
- Mjerenje sličnosti u skupu podataka
- Analiza na osnovu veza u podacima

# Skupovi podataka

- Skup podataka se sastoji od objekata (entiteta, slogova, tačaka itd.)
- Svaki objekat se opisuje skupom atributa (promjenljivih, dimenzija, svojstava itd.)

Atributi

Objekti

Tid	Refund	Marital Status	Taxable Income	Cheat
1	Yes	Single	125K	No
2	No	Married	100K	No
3	No	Single	70K	No
4	Yes	Married	120K	No
5	No	Divorced	95K	Yes
6	No	Married	60K	No
7	Yes	Divorced	220K	No
8	No	Single	85K	Yes
9	No	Married	75K	No
10	No	Single	90K	Yes

# Atributi

- Atribut je svojstvo ili karakteristika objekta koje može da ima različite vrijednosti za različite objekte ili trenutke vremena
- Mjera je funkcija koja atributu dodjeljuje numeričku ili simboličku vrijednost
  - Jednom atributu može biti dodijeljeno više različitih vrijednosti
  - Različiti atributi mogu da imaju vrijednosti iz istog skupa

# Tipovi atributa

- Podjela na osnovu svojstava vrijednosti koje se dodjeljuju atributima
- Nominalni ili imenički (engl. nominal)
  - boja očiju
- Redni (engl. ordinal)
  - ocjena na ispitu
- Intervalni (engl. interval)
  - period vremena
- Količnički (engl. ratio)
  - dužina

# Svojstva vrijednosti atributa

## ■ Svojstva ili operacije koje određuju podjelu

- Sličnost                $=, !=$
- Uređenje $<, >, <=, >=$
- Sabiranje i oduzimanje  $+, -$
- Množenje i dijeljenje  $*, /$
  
- Nominalni: sličnost
- Redni: sličnost i uređenje
- Intervalni: sličnost i uređenje i sabiranje i oduzimanje
- Količnički: sličnost i uređenje i sabiranje i oduzimanje i množenje i dijeljenje

Tip atributa	Opis	Primjeri	
Nominalni	Vrijednosti atributa su različita imena, tj. nominalni atributi obezbjeđuju samo dovoljno informacija za razlikovanje jednog objekta od drugog ( $=, \neq$ )	Boja očiju, pol, JMBG	
Redni	Na osnovu vrijednosti atributa moguće je sortirati objekte. ( $<, >$ )	visina iz skupa $\{nizak, prosječan, visok\}$ , ocjena, adresa	
Intervalni	Postoji jedinica mjere, razlika između vrijednosti je značajna. (+, -)	Datum, temperatura u stepenima Celzijusove skale	
Količnički	Razlika i odnos između vrijednosti je značajan. (*, /)	Dužina, temperatura u stepenima Kelvinove skale	

Atributi	Transformacija koja ne mijenja značenje atributa (S. Stevens)	Komentar
Nominalni	Svaka 1-1 funkcija	Ponovna dodjela brojeva indeksa ne mijenja značenje
Redni	Primjena monotone funkcije $new\_value = f(old\_value)$	Skup vrijednosti {1, 2, 3} može sa bude predstavljen skupom {0.5, 1, 10}.
Intervalni	$new\_value = a * old\_value + b$ gdje su $a$ i $b$ konstante	Prevodenje iz Celzijusove u Farenhajtovu temperturnu skalu
Količnički	$new\_value = a * old\_value$ gdje je $a$ konstanta	Mjerenje dužine metrima ili stopama.

# Tipovi atributa prema broju vrijednosti

## ■ Diskretni atributi

- Konačan ili prebrojiv skup vrijednosti
- Često se predstavljaju cijelim brojevima
- Primjer: binarni atribut
- Obično su to nominalni i redni atributi

## ■ Kontinualni atributi

- Vrijednosti su iz skupa realnih brojeva
- Često se predstavljaju pokretnim zarezom (float tip)
- Primjer: temperatura, visina, težina
- Obično su to intervalni i količnički atributi

# Asimetrični atributi

- Samo su važne ne nula vrijednosti
- Binarni asimetrični atributi naročito važni za asocijativnu analizu
- Mogu da budu i asimetrični diskretni ili asimetrični kontinualni

# Tipovi skupova podataka

- Record data
  - Matrice podataka
  - Document data
  - Transakcione BP
- Graph-based data
  - Hemijski molekuli
  - WWW
- Oredred data
  - Temporal (sequential) data
  - Sequence data

# Karakteristike skupova podataka

## ■ Dimenzionalnost

- Broj atributa koje posjeduju objekti
- Curse of Dimensionality

## ■ Rijetkost

- Npr. manje od 1% ne nula vrijednosti

## ■ Stepen generalizacije

- Otkrivanje šablonu zavisi od stepena generalizacije na kojem su predstavljeni podaci

# Record data

- Skup podataka se sastoji od slogova, a svaki slog od fiksiranog broja polja (atributa)
- Čuvaju se u običnim datotekama ili relacionim BP

Tid	Refund	Marital Status	Taxable Income	Cheat
1	Yes	Single	125K	No
2	No	Married	100K	No
3	No	Single	70K	No
4	Yes	Married	120K	No
5	No	Divorced	95K	Yes
6	No	Married	60K	No
7	Yes	Divorced	220K	No
8	No	Single	85K	Yes
9	No	Married	75K	No
10	No	Single	90K	Yes

# Matrice podataka

- Svaki objekat se opisuje jednakim skupom numeričkih atributa i posmatra se kao vektor u više-dimenzionalnom prostoru gdje dimenzija predstavlja atribut
- Skup podataka se predstavlja matricom sa m vrsta i n kolona: jedna vrsta za jedan objekat, jedna kolona za jedan atribut

Projection of x Load	Projection of y load	Distance	Load	Thickness
10.23	5.27	15.22	2.7	1.2
12.65	6.25	16.22	2.2	1.1

# Rijetke matrice podataka

- Atributi su istog tipa i  
asimetrični su

	team	coach	pla y	ball	score	game	wi n	lost	timeout	season
Document 1	3	0	5	0	2	6	0	2	0	2
Document 2	0	7	0	2	1	0	0	3	0	0
Document 3	0	1	0	0	1	2	2	0	3	0

# Transakcione BP


- Slog predstavlja transakciju
  - Svaka transakcija sadrži skup objekata (item-a)
  - market basket data

<i>TID</i>	<i>Items</i>
1	Bread, Coke, Milk
2	Beer, Bread
3	Beer, Coke, Diaper, Milk
4	Beer, Bread, Diaper, Milk
5	Coke, Diaper, Milk


# Graph data

## ■ Dva tipa

- Grafom se predstavljaju relacije između objekata
- Sami objekti su grafovi



<a href="papers/papers.html#bbbb">  
Data Mining </a>  
<li>  
<a href="papers/papers.html#aaaa">  
Graph Partitioning </a>  
<li>  
<a href="papers/papers.html#aaaa">  
Parallel Solution of Sparse Linear System of Equations </a>  
<li>  
<a href="papers/papers.html#ffff">  
N-Body Computation and Dense Linear System Solvers



# Ordered data

## ■ Temporal data

Vrijeme	Kupac	Proizvodi
T1	C1	A, B
T2	C3	A, C
T2	C1	C, D
T3	C2	A, D
T4	C2	E
T5	C1	A, E



Kupac	Vrijeme + Proizvodi
C1	(t1 : A, B) (t2 : C, D) (t5 : A, E)
C2	(t3 : A, D) (t4 : E)
C3	(t2 : A, C)

# Ordered data (2)

- Sequence data
  - Nema vremenske odrednice
  - Položaj u uređenoj sekvenci



GGTTCCGCCTTCAGCCCCGCGCC  
CGCAGGGCCCGCCCGCGCCGTC  
GAGAAGGGCCCCTGGCGGGCG  
GGGGGAGGCAGGGCCGCCCCGAGC  
CCAACCGAGTCCGACCAGGTGCC  
CCCTCTGCTCGGCCTAGACCTGA  
GCTCATTAGGCAGGCGACAG  
GCCAAGTAGAACACGCGAAGCGC  
TGGGCTGCCTGCTGCGACCAGGG

# Kvalitet podataka

- Problemi vezani za kvalitet podataka
  - Greške u mjerenuju
    - šum u podacima
  - Greške u sakupljanju podataka
    - izuzeci (outliers)
    - nedostajuće i nekonzistentne vrijednosti
    - duplikati
- Otkrivanje i ispravljanje problema kvaliteta je čišćenje podataka (data cleaning)

# Šum u podacima

- Šum je slučajna greška mjerena podataka
  - Primjer: ljudski glas preko telefonske žice ili sniježenje slike




# Bias i preciznost u skupu podataka

- Pretpostavka je da je izvršeno više mjerena jednog objekta i srednja (prosječna) vrijednost se uzima kao stvarna mjera
- Bias =  $\text{abs}(\text{mean} - \text{stvarna vrijednost})$
- Preciznost = uzoračka disperzija
- Primjer: testira se vaga tako što se 5 puta mjeri 1g. Rezultati mjerena su {1.015, 0.99, 1.013, 1.001, 0.986}, pa je
  - mean = 1.001
  - bias = 0.001
  - preciznost = 0.013

# Izuzeci

## ■ Izuzeci su

- Objekti koji su po karakteristikama jako različiti od ostalih objekata u skupu podataka
- Vrijednosti atributa koje su neočekivane za taj atribut u skupu podataka



# Nedostajuće vrijednosti

## ■ Razlozi

- Vrijednosti nijesu unijete
- Vrijednosti nijesu odgovarajuće za sve objekte

## ■ Strategije

- Eliminacija objekata
- Eliminacija atributa
- Ignorisanje nedostajućih vrijednosti tokom analize
- Procjena nedostajućih vrijednosti

# Duplikati

- Skupovi podataka mogu da sadrže duplike ili “skoro” duplike
- Detekcija duplikata
  - Ako u skupu podataka postoje dva objekta koja u stvari predstavljaju jedan, vrijednosti odgovarajućih atributa mogu da se razlikuju (nekonzistentnost)
  - Slični objekti nijesu uvijek duplikati

# Mjerenje sličnosti u skupu podataka

- Sličnost objekata u skupu podataka je važna za veliki broj algoritama
- Sličnost
  - Broj koji pokazuje koliko su slična dva objekta, često iz segmenta  $[0,1]$
- Različitost (ili rastojanje)
  - Broj koji pokazuje koliko su različita dva objekta
  - Minimalna različitost je 0, gornja granica često 1 ili beskonačno
- Proximity: sličnost ili različitost

# Transformacije

- Transforacijama se
  - mjera sličnosti prevodi u mjeru različitosti
  - proximity mjera prevodi u željeni interval
- Transformacija različitosti u sličnost ma kojom monotono opadajućom funkcijom
  - $s=-d$  ili  $s=1/(d+1)$  ili  $s=\exp(-d)$
- Transformacija u  $[0,1]$ :  $s1=(s-\text{min}_s)/(\text{max}_s-\text{min}_s)$

# Sličnost među objektima sa jednim atributom


- $p$  i  $q$  su vrijednosti atributa za dva objekta

Attribute Type	Dissimilarity	Similarity
Nominal	$d = \begin{cases} 0 & \text{if } p = q \\ 1 & \text{if } p \neq q \end{cases}$	$s = \begin{cases} 1 & \text{if } p = q \\ 0 & \text{if } p \neq q \end{cases}$
Ordinal	$d = \frac{ p-q }{n-1}$ (values mapped to integers 0 to $n-1$ , where $n$ is the number of values)	$s = 1 - \frac{ p-q }{n-1}$
Interval or Ratio	$d =  p - q $	$s = -d, s = \frac{1}{1+d}$ or $s = 1 - \frac{d - \min_d}{\max_d - \min_d}$

# Rastojanje

## Euklidsko rastojanje

$$dist = \sqrt{\sum_{k=1}^n (p_k - q_k)^2}$$



point	x	y
p1	0	2
p2	2	0
p3	3	1
p4	5	1

	p1	p2	p3	p4
p1	0	2.828	3.162	5.099
p2	2.828	0	1.414	3.162
p3	3.162	1.414	0	2
p4	5.099	3.162	2	0

# Rastojanje (2)

- Minkowski rastojanje  $dist = \left( \sum_{k=1}^n |p_k - q_k|^r \right)^{\frac{1}{r}}$
- $r=1$ , city block distance. Primjer je Hamingovo rastojanje između binarnih vektora
- $r=2$ , Euklidsko rastojanje
- $r \rightarrow \infty$ , maksimalno rastojanje između atributa dva objekta
- City block distance, Euklidovo i maksimalno rastojanje su definisani za sve vrijednosti n

# Rastojanje (3)

point	x	y
p1	0	2
p2	2	0
p3	3	1
p4	5	1

L1	p1	p2	p3	p4
p1	0	4	4	6
p2	4	0	2	4
p3	4	2	0	2
p4	6	4	2	0

L2	p1	p2	p3	p4
p1	0	2.828	3.162	5.099
p2	2.828	0	1.414	3.162
p3	3.162	1.414	0	2
p4	5.099	3.162	2	0

L $\infty$	p1	p2	p3	p4
p1	0	2	3	5
p2	2	0	1	3
p3	3	1	0	2
p4	5	3	2	0

# Svojstva rastojanja

- Rastojanje je mjera različitosti koja zadovoljava uslove (zove se i metrika)
  1.  $d(p, q) \geq 0$  za sve  $p$  i  $q$
  2.  $d(p, q) = 0$  samo ako je  $p = q$
  3.  $d(p, q) = d(q, p)$  za sve  $p$  i  $q$
  4.  $d(p, r) \leq d(p, q) + d(q, r)$  za sve  $p, q$  i  $r$
- Mjere za različitost koje nijesu metrike
  - Razlika skupova

# Sličnost

- Uobičajena svojstva mjere sličnosti  $s(x, y)$  su
  1.  $s(p, q) = 1$  (poklapanje) samo ako je  $p = q$
  2.  $s(p, q) = s(q, p)$  za sve  $p$  i  $q$

# Sličnost za binarne vektore

- Objekti  $x$  i  $y$  imaju  $n$  binarnih atributa
- Sličnost se računa na osnovu
  - $M_{01}$  = broj atributa koji su 0 za  $x$  a 1 za  $y$
  - $M_{10}$  = broj atributa koji su 1 za  $x$  a 0 za  $y$
  - $M_{00}$  = broj atributa koji su 0 za  $x$  i 0 za  $y$
  - $M_{11}$  = broj atributa koji su 1 za  $x$  i 1 za  $y$
- Simple matching coefficient (SMC) =  $(M_{11} + M_{00}) / (M_{01} + M_{10} + M_{11} + M_{00})$
- Jaccard coefficient =  $(M_{11}) / (M_{01} + M_{10} + M_{11})$

# Sličnost za binarne atribute, primjer

$p = 1 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0$

$q = 0 \ 0 \ 0 \ 0 \ 0 \ 1 \ 0 \ 0 \ 1$

$M_{01} = 2$  (the number of attributes where p was 0 and q was 1)

$M_{10} = 1$  (the number of attributes where p was 1 and q was 0)

$M_{00} = 7$  (the number of attributes where p was 0 and q was 0)

$M_{11} = 0$  (the number of attributes where p was 1 and q was 1)

$$SMC = (M_{11} + M_{00}) / (M_{01} + M_{10} + M_{11} + M_{00}) = (0+7) / (2+1+0+7) = 0.7$$

$$J = (M_{11}) / (M_{01} + M_{10} + M_{11}) = 0 / (2 + 1 + 0) = 0$$

# Kosinus kao mjera sličnosti

## ■ Karakteristike

- Ignoriše 0-0 sličnost
- Primjenljiva ne samo za binarne atributе
- Najčešće se koristi za sličnost dokumenata

■ Ako su  $x$  i  $y$  dokument predstavljeni vektorima, tada je  $\cos(x,y) = x^*y / \|x\| \|y\|$ , gdje je  $x^*y$  skalarni proizvod a  $\|x\|^2 = x^*x$

# Kosinus kao mjera sličnosti (2)

## ■ Primjer

$$d_1 = 3 \ 2 \ 0 \ 5 \ 0 \ 0 \ 0 \ 2 \ 0 \ 0$$

$$d_2 = 1 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 1 \ 0 \ 2$$

$$d_1 \bullet d_2 = 3*1 + 2*0 + 0*0 + 5*0 + 0*0 + 0*0 + 0*0 + 2*1 + 0*0 + 0*2 = 5$$

$$\|d_1\| = (3^2 + 2^2 + 0^2 + 5^2 + 0^2 + 0^2 + 0^2 + 2^2 + 0^2 + 0^2)^{0.5} = \\ (42)^{0.5} = 6.481$$

$$\|d_2\| = (1^2 + 0^2 + 0^2 + 0^2 + 0^2 + 0^2 + 0^2 + 1^2 + 0^2 + 2^2)^{0.5} = (6)^{0.5} = 2.245$$

$$\cos(d_1, d_2) = .3150$$

# Proširenji Jaccard koeficijent

- Može da se primjeni na sličnost dokumenata,
- U slučaju binarnih atributa svodi se na Jaccard koeficijent
- Naziva se i Tanimoto koeficijent

$$T(p, q) = \frac{p \bullet q}{\|p\|^2 + \|q\|^2 - p \bullet q},$$

# Korelacija

- Korelacija između dva objekta je linearna mjera veza između njihovih atributa (binarnih ili kontinualnih)
- Korelacija je iz  $[-1, 1]$ , ako je 1 (-1) onda je savršena pozitivna (negativna) linearna veza između x i y, ako je 0 nema linearne veze

$$\text{Correlation}(x, y) = \text{cov}(x, y) / \text{std}(x) * \text{std}(y)$$

# Računanje sličnosti ako su atributi različitih tipova

1. For the  $k^{th}$  attribute, compute a similarity,  $s_k$ , in the range  $[0, 1]$ .
2. Define an indicator variable,  $\delta_k$ , for the  $k_{th}$  attribute as follows:

$$\delta_k = \begin{cases} 0 & \text{if the } k^{th} \text{ attribute is a binary asymmetric attribute and both objects have} \\ & \text{a value of 0, or if one of the objects has a missing values for the } k^{th} \text{ attribute} \\ 1 & \text{otherwise} \end{cases}$$

3. Compute the overall similarity between the two objects using the following formula:

$$similarity(p, q) = \frac{\sum_{k=1}^n \delta_k s_k}{\sum_{k=1}^n \delta_k}$$

# Rečunanje sličnosti sa težinama

- Težina atributa je njegov značaj za određivanje sličnosti
  - Težine su između 0 i 1, a njihova suma je 1

$$\text{similarity}(p, q) = \frac{\sum_{k=1}^n w_k \delta_k s_k}{\sum_{k=1}^n \delta_k}$$

$$\text{distance}(p, q) = \left( \sum_{k=1}^n w_k |p_k - q_k|^r \right)^{1/r}$$

# Gustina kao mјera sličnosti

- Density-based klasterizacija prepoznaјe klastere kao regije sa velikom gustinom
- Euklidska gustina za objekat je broj objekata u krugu zadatog poluprečnika

