

# Finding similar items

# Uvod

- Mnogi zadaci mogu da se definišu kao pronalaženje sličnih skupova
  - Najbliži susjed
- Primjeri
  - Dokumenti sa sličnim riječima, detekcija duplikata, klasifikacija po tematici
  - Klijenti koji kupuju slične proizvode, proizvodi sa zajedničkim kupcima
  - Korisnici koji posjete slične sajtove

# Distance measure

- Cilj, naći najbližeg susjeda u višedimenzionom prostoru
- Jakardovo rastojanje/sličnost
  - Za dva skupa definiše se kao količnik veličine presjeka i veličine unije ta dva skupa
  - $\text{similarity}(A, B) = 1 - \text{distance}(A, B)$

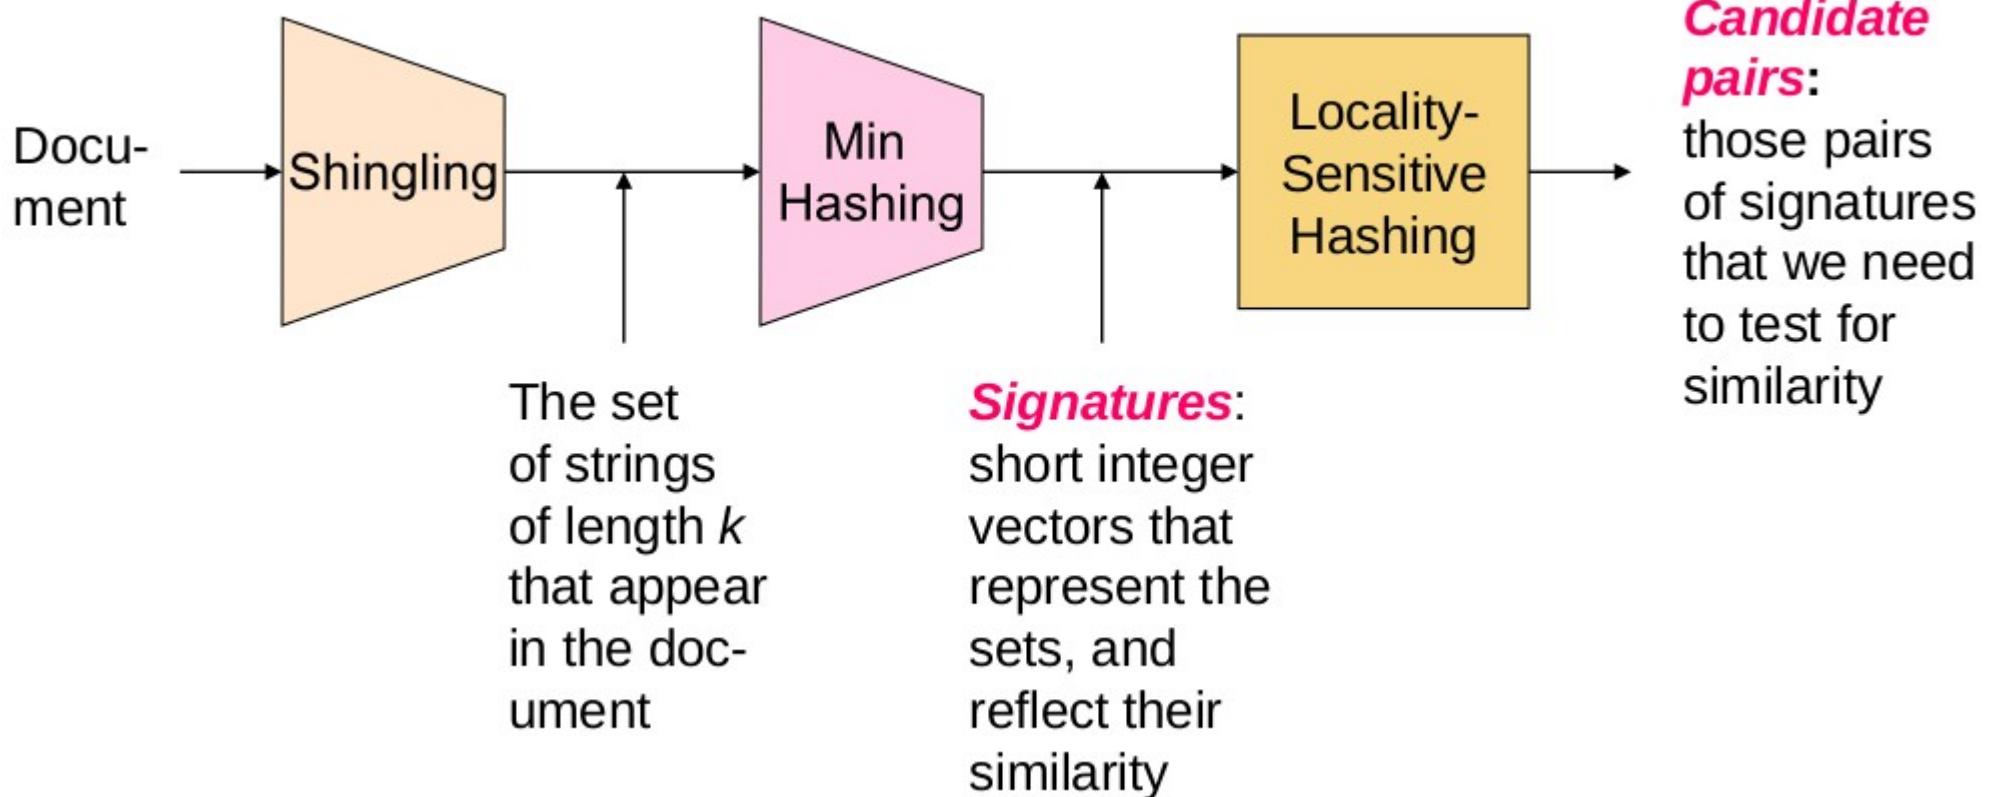
# Identifikovanje sličnih dokumenata

- Zadatak, za dati skup od  $N$  (nekoliko miliona) tekstualnih dokumenata pronaći parove koji su skoro duplikati - “near duplicates”
- Primjene
  - Mirror websites, ne prikazivati oba u rezultatima pretrage
  - Slični novinski članci, klasterisati članke po temi
- Problemi
  - Slučajne pojave dijelova jednog dokumenta u drugom
  - Previše parova za poređenje
  - Ograničenja operativne memorije (broj dokumenata ili veličina)

# Osnovni koraci rješenja

- Shingling – predstavljanje dokumenata u formi skupova
- Minhashing – konverzija velikih skupova u male *potpise*, uz zadržavanje sličnosti
- Locality-sensitive hashing – formiranje parova potpisa koji su sa velikom vjerovatnoćom iz sličnih skupova, kandidatski parovi

# Kompletna slika



# Shingling

- Konverzija dokumenata u skupove
- Pristupi
  - dokument = skup riječi koje se pojavljuju
  - dokument = skup “ključnih” riječi
  - Nijesu prihvatljiva rješenja, jer ne uzima u obzir redoslijed riječi
- Drugačiji pristup: shingling

# Definicija za shingles

- k-shingle je sekvenca k tokena koji se pojavljuju u dokumentu
  - Token je karakter, riječ ili nešto treće, zavisno od aplikacije, podrazumijevamo karakter
- Primjer:  $k = 2$ , dokument  $D_1 = \text{abcab}$ , skup 2 – shinglova:  $S(D_1) = \{\text{ab}, \text{bc}, \text{ca}\}$ 
  - Razmotriti varijantu sa multiskupom

# Kompresija shinglova

- Za kompresiju dugih šinglova koristi se heširanje
- Reprezentacija dokumenta skupom heš vrijednosti njegovih k-shinglova
  - Moguće je ( rijetko ) da dva dokumenta prividno dijele shinglove, dok se ustvari dijele samo heš vrijednosti
- Primjer:  $k = 2$ , dokument  $D_1 = \text{abcab}$ , skup 2 – shinglova:  
 $S(D_1) = \{\text{ab}, \text{bc}, \text{ca}\}$ , heširanje  $h(D_1) = \{1, 5, 7\}$

# Mjera sličnosti za shinglove

- Dokument  $D_1 = \text{skup } k\text{-shinglova } C_1 = S(D_1)$
- Ekvivalentno, svaki dokument je 0/1 vektor u prostoru k-shinglova
  - Svaki shingle je dimenzija
  - Vektori su rijetki (sa mnogo nula)
- Jakardova mjera za sličnost
  - $\text{SIM}(D_1, D_2) = |C_1 * C_2| / |C_1 + C_2|$

# Pretpostavka

- Dokumenti sa velikim brojem zajedničkih shinglova imaju sličan tekst, iako je poredak riječi eventualno različit
- Napomena: potrebno je izabrati k dovoljno veliko, inače će “većina” dokumenata sadržati većinu shinglova
  - $k = 5$  za kraće dokumente
  - $k = 10$  za duže dokumente

# Motivacija za LSH algoritam

- Zadatak: naći duplike među  $N = \text{milion}$  dokumenata
- Algoritam grube sile, za svaku par dokumenata izračunati Jakardovo rastojanje
  - $N*(N-1)/2 = 5 * 10^{11}$  poređenja
  - Za  $10^5$  sekundi/danu i  $10^6$  poređenja/sekundi, zadatak bi trajao 5 dana
- Za  $N = 10$  miliona, rješavanje je duže od godine dana

# Minhashing

- Reprezentacija skupova bit vektorima
  - Jedna dimenzija za svaki element
- Formalizacija problema: identifikovanje skupova sa “značajno velikim” presjekom
- Realizacija
  - Presjek je AND
  - Unija je OR
  - Primjer,  $C_1 = 10111$ ,  $C_2 = 10011$ , veličina presjeka = 3, veličina unije = 4, SIM =  $\frac{3}{4}$ , DISTANCE =  $1 - \frac{3}{4}$

# Formiranje matrice bita za skupove

- Redovi = elementi (shingles)
- Kolone = skupovi (dokumenti)
  - 1 u redu e i koloni s ako je e element s
  - SIM mjera za kolone je Jakardova mjera za sličnost odgovarajućih skupova (redovi sa 1)
  - Rijetka matrica
- Svaki dokument je predstavljen kolonom
  - Primjer:  $SIM(C_1, C_2) = ?$

1	1	1	0
1	1	0	1
0	1	0	1
0	0	0	1
1	0	0	1
1	1	1	0
1	0	1	0

# Identifikovanje sličnih kolona

- Do sada:
  - Dokumenti → skupovi shinglova
  - Skupovi → Bulovi vektori u matrici
- Sljedeći korak: identifikovati slične kolone
- Algoritam
  - Signatura kolone
  - Razmatranje signatura
  - Provjera da su kolone sa sličnim signaturama zaista slične
  - Poređenje signatura: LSH algoritam (potencijalno sa false negative i false positive)

# Heširanje kolona (signatura)

- Ideja: heširati kolonu C u signaturu  $h(C)$  tako da:
  - $h(C)$  je dovoljno malo zbog ograničenja RAMa
  - $SIM(C_1, C_2) = SIM(h(C_1), h(C_2))$
- Potrebno je naći funkciju  $h(*)$  tako da:
  - Ako je  $SIM(C_1, C_2)$  velika, onda je velika vjerovatnoća da  $h(C_1) = h(C_2)$  i obratno
- Heširamo dokumente u bakete i očekujemo da duplikati budu heširani u iste bakete

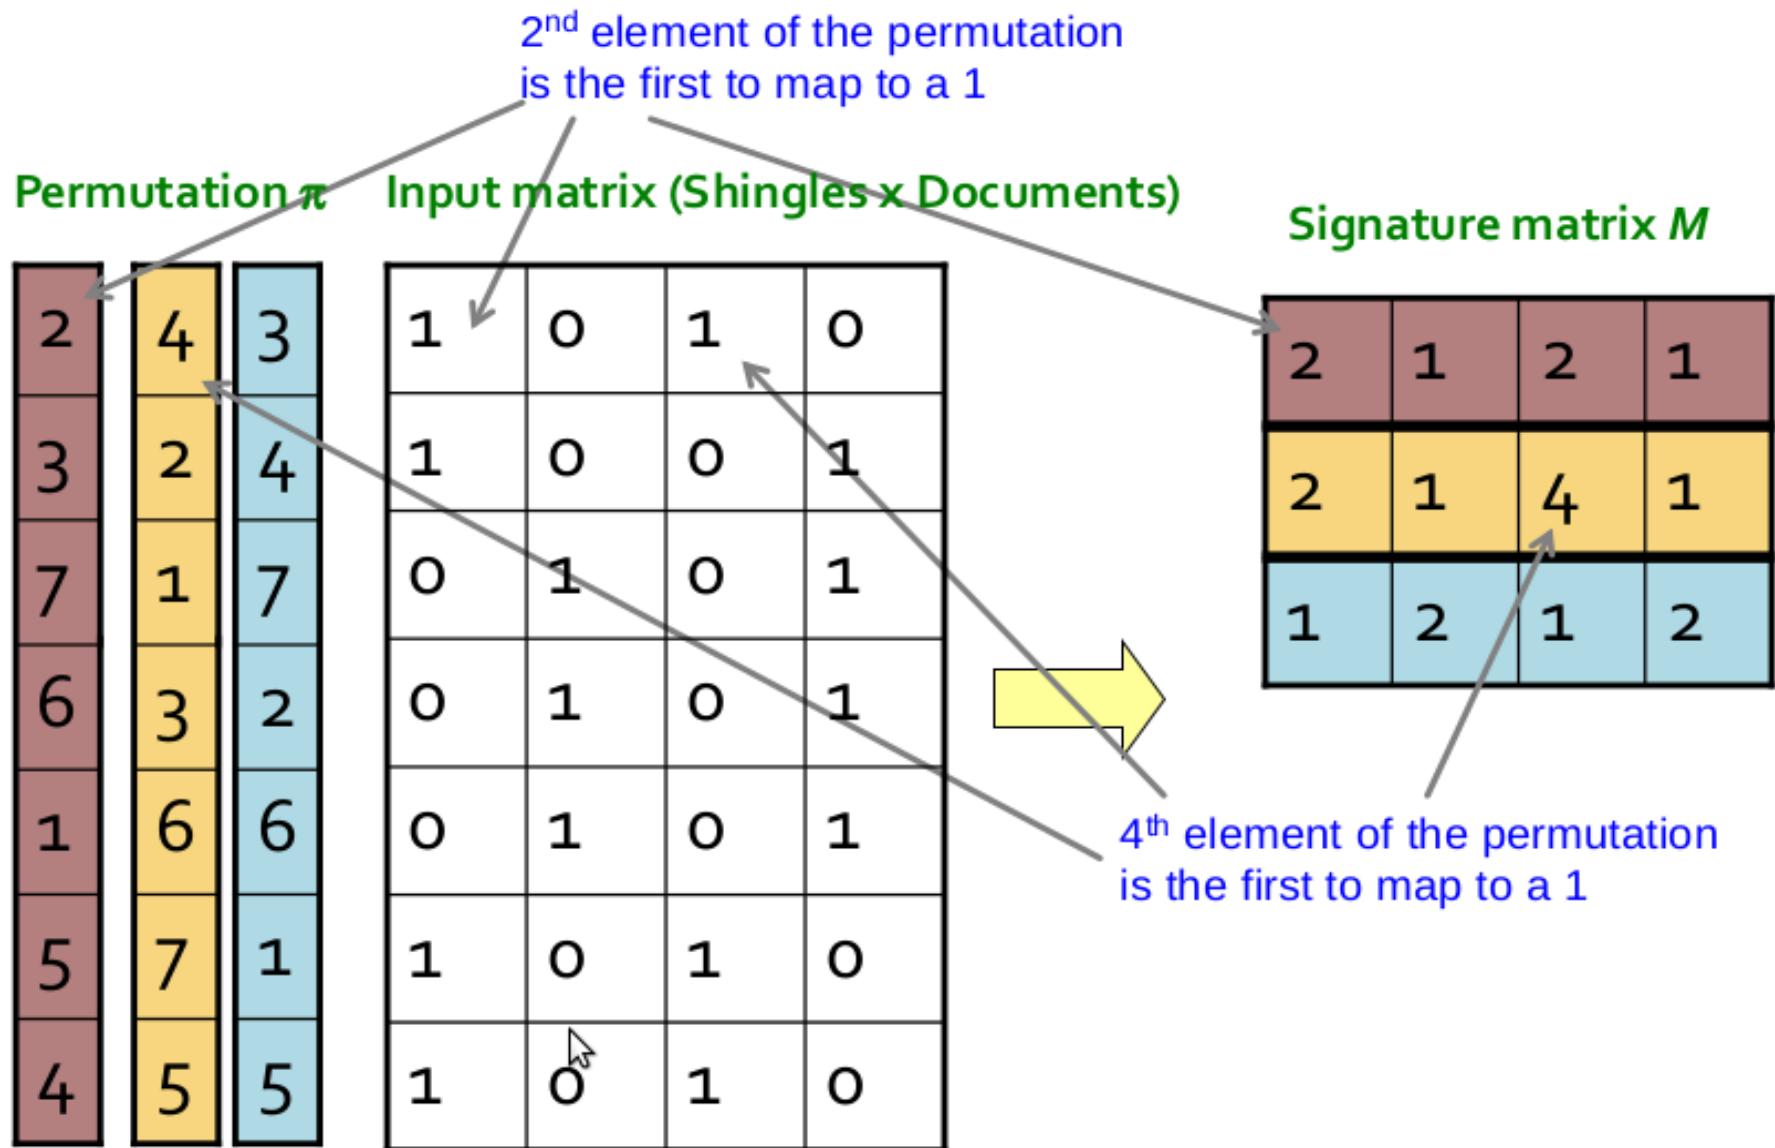
# Min-hashing

- Heš funkcija zavisi od izabrane mjere sličnosti
  - Postoje mјere za koje nije moguće definisati odgovarajuću heš funkciju
- Min-hašing je odgovarajuća za Jakardovu mjeru

# Min-hashing (2)

- Permutacija  $P$  redova u matrici dokumenata
- Definišimo  $h(C) =$  redni broj “prvog” reda u koloni  $C$  koji sadrži 1
- Koristimo nekoliko nezavisnih heš funkcija da formiramo signaturu kolone

# Primjer za Min-hashing



# Svojstvo

- $\Pr(h(C_1) = h(C_2)) = \text{SIM}(C_1, C_2)$
- Dokazati

# Četiri tipa za redove

- Date su kolone  $C_1$  i  $C_2$

	$\underline{C_1}$	$\underline{C_2}$
A	1	1
B	1	0
C	0	1
D	0	0

- $a =$  broj redova tipa A, itd.
- $SIM(C_1, C_2) = a / (a + b + c)$
- Važi:  $Pr[h(C_1) = h(C_2)] = SIM(C_1, C_2)$

# Sličnost za signature

- Mjera sličnosti za dvije signature je procenat heš funkcija koje se poklapaju na tim signaturama
- Sličnost za kolone je ista kao sličnost za signature

# Min-hashing signature

Permutation  $\pi$

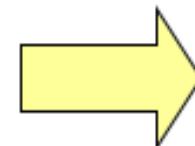
2	4	3
3	2	4
7	1	7
6	3	2
1	6	6
5	7	1
4	5	5

Input matrix (Shingles x Documents)

1	0	1	0
1	0	0	1
0	1	0	1
0	1	0	1
0	1	0	1
1	0	1	0
1	0	1	0

Signature matrix  $M$

2	1	2	1
2	1	4	1
1	2	1	2



Similarities:

Col/Col  
Sig/Sig

1-3	2-4	1-2	3-4
0.75	0.75	0	0
0.67	1.00	0	0

# Implementacija

- Bira se  $n=100$  permutacija redova, umjesto permutacija može se uzeti n heš funkcija
- Formira se matrica signatura  $SIG(i, c)$  – element matrice za heš funkciju  $i$ , a kolonu  $c$ , inicijalno su svi postavljeni na beskonačno
- Za svaki red  $r$ 
  - Ako red sadrži 1, za svako  $i=1, 2, \dots, n$  postavi  $SIG(i, c) = \min(SIG1(i, c), h_i(r))$

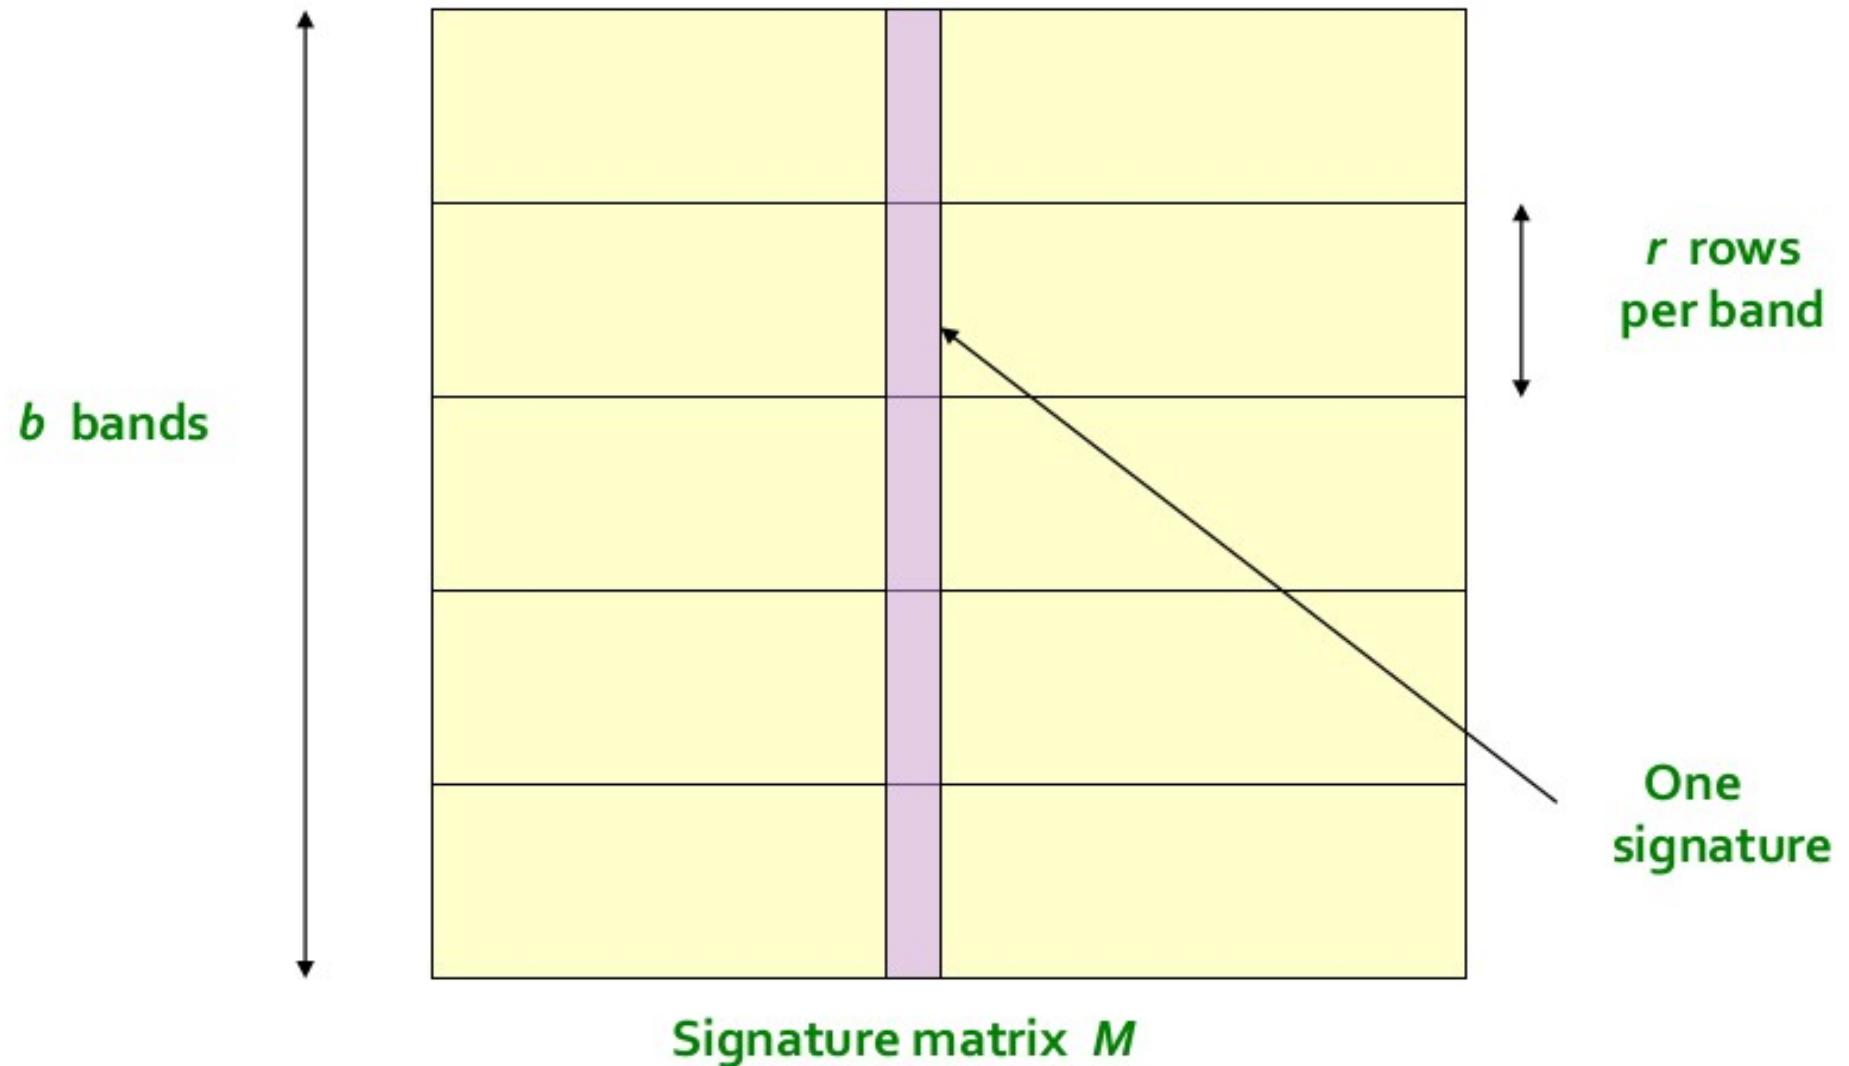
# LSH

- Ostvareno je predstavljanje dokumenata sa “malim” signaturama
- Dalji cilj je naći dokumente sa  $\text{SIM} > s$ ,  $s$  je ulazni parametar
- LSH ideja, koristi se funkcija  $f(x, y)$  koja određuje da li su  $x$  i  $y$  kandidatski par
  - Heširaju se kolone matrice sa signaturama, dokumenti koji pripadaju istim baketima formiraju kandidatske parove

# Kandidati

- Izabere se  $s$ ,  $0 < s < 1$
- Kolone  $x, y$  iz matrice signatura su kandidatski par ako se poklapaju u  $s\%$
- Očekuje se da sličnost originalnih dokumenata bude ista kao sličnost signatura

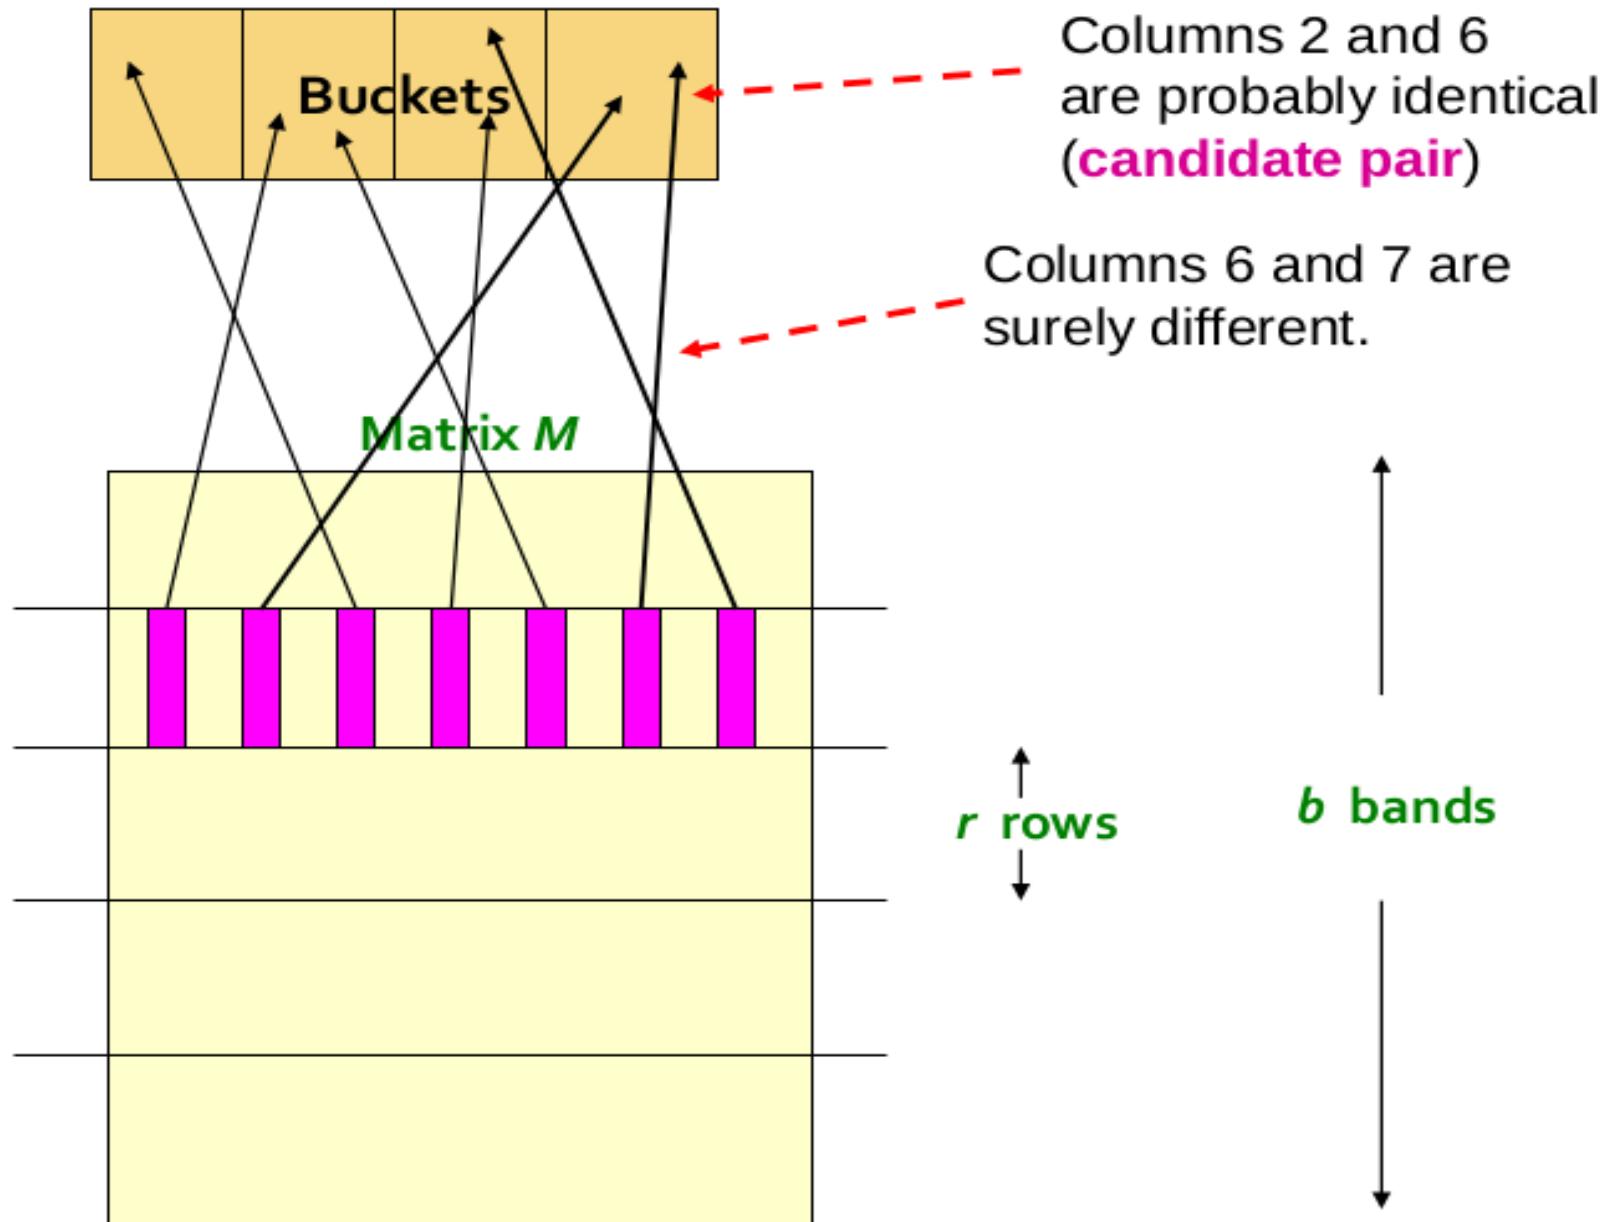
# LSH za matricu signatura



# Objašnjenje

- Matrica signatura  $M$  podijeli se na  $b$  baketa sa po  $r$  redova
- Za svaki baket se sprovodi heširanje po dijelu kolone koji pripada tom baketu ( $r$  redova)
- Kandidati su oni koji imaju istu vrijednost heš funkcije u makar jednom baketu

# Primjer



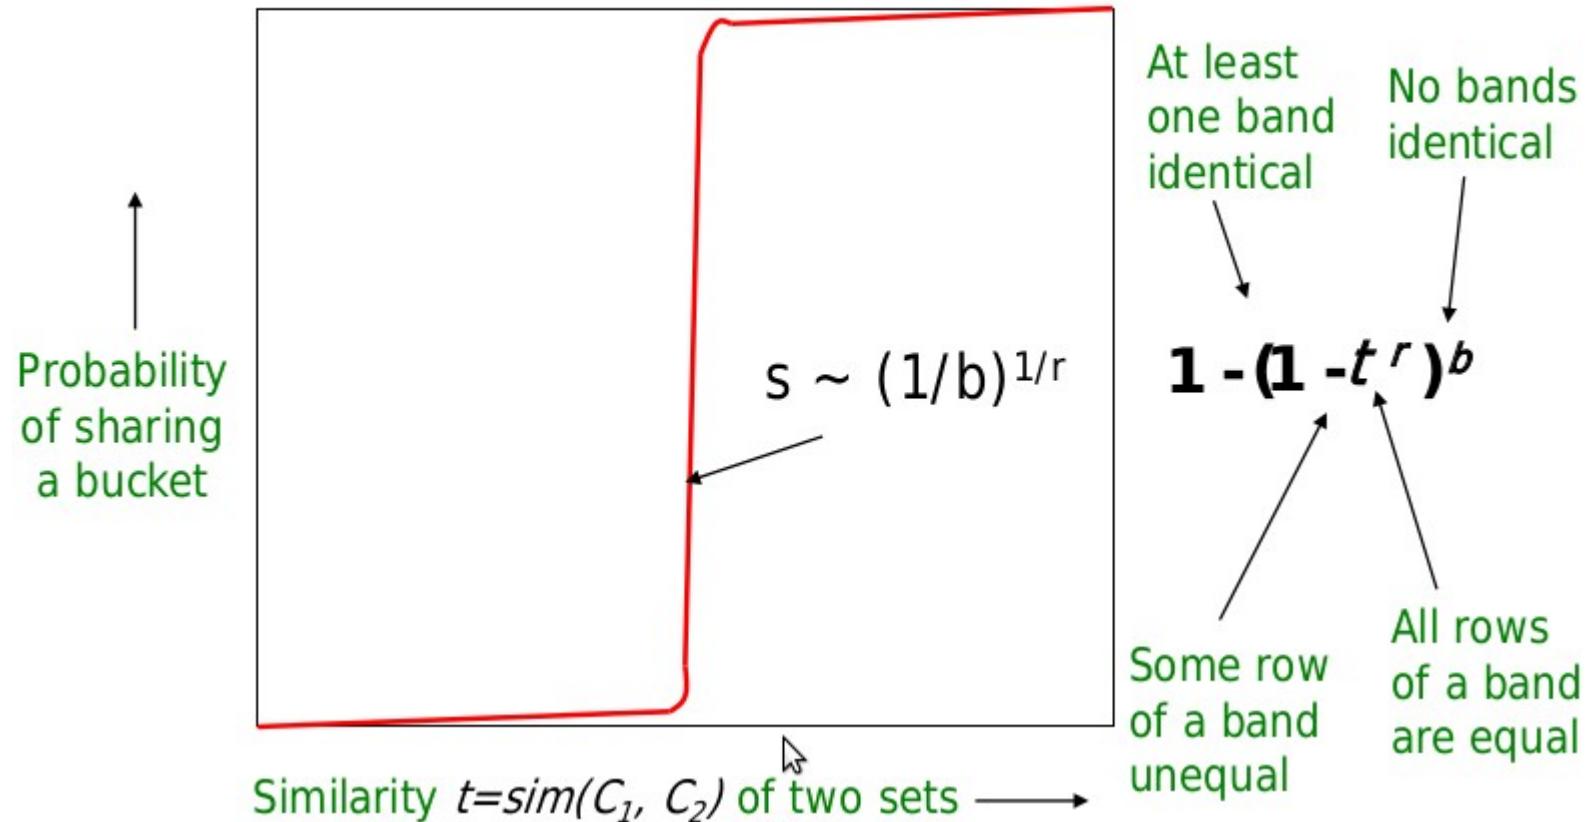
# Pretpostavka

- Postoji dovoljan broj baketa tako da se kolone dodjeljuju istom baketu samo ako se poklapaju na r redova koji pripadaju posmatranom baketu

# Primjer

- Neka je  $b=20$ ,  $r=5$ , tražimo parove sa  $s>=0.8$
- Ako je  $SIM(C_1, C_2) = 80\%$ , oni treba da budu kandidatski par, tada  $C_1$  i  $C_2$  moraju da se poklapaju u bar jednom od 20 baketa
- Vjerovatnoća da se  $C_1, C_2$  poklapaju u jednom baketu je  $(0.8)^5 = 0.328$
- Vjerovatnoća da se  $C_1, C_2$  ne poklapaju ni u jednom baketu  $(1-0.328)^{20}$

# Kako se biraju b i r?



# Određivanje praga sličnosti

- Skupovi  $C_1$  i  $C_2$  imaju sličnost  $t$
- Za proizvoljni baket sa  $r$  redova
  - Vjerovatnoća da su svi redovi u baketu isti =  $t^r$
  - Vjerovatnoća da je bar jedan red različit =  $1 - t^r$
- Vjerovatnoća da ne postoji dva ista baketa  
 $= (1 - t^r)^b$
- Vjerovatnoća da su je bar jedan baket identičan  
 $= 1 - (1 - t^r)^b$
- Prag je  $(1/b)^{1/r}$

# Algoritam

- Shingling, predstavljanje dokumenata skupovi, heširanje da svaki shingle dobije cjelobrojni ID
- Minhashing, predstavljanje velikih skupova preko malih signatura uz zadržavanje sličnosti polaznih dokumenata
- Locality-sensitive hashing, formiraju se parovi kandidatskih signatura koje potiču iz dokumenata sa sličnosti većom od zadatog praga