Napredni algoritmi i strukture podataka

Probabilističke strukture podataka, Hash funkcije, Bloom filter

Univerzitet u Novom Sadu
Fakultet Tehničkih Nauka

Probabilističke strukture

- Probabilističke strukture podataka su klasa struktura podataka koja je izuzetno korisna za aplikacije velikih podataka (Big Data) i za striming
- Ove strukture podataka koriste *hash* funkcije za randomizaciju, i kompaktno predstavljanje skupa podataka
- Kolizije se zanemaruju, ali se greške mogu kontrolisati
- Nasuprot klasičnim (deterministčkim), ovi strukture koriste **znatno** manje memorije, i imaju konstantno vreme upita za proizvoljan skup podataka
- Obično podržavaju operacije spajanja i ukrštanja, pa se stoga mogu lako paralelizovati

- Uobičajen pristup je upotreba neke vrste determinističke strukture podataka poput HashSet—a ili Hashtable—a za aplikacije velikih podataka i za striming
- Ali kada skup podataka sa kojim se bavimo postane veoma veliki, takve strukture podataka jednostavno nisu upotrebljive jer su podaci preveliki da bi stali u memoriju
- Probabilističke strukture koristimo za proveru da li je element prisutan u skupu, izračunavanje kardinaliteta, izračunavanje frekfencije pojave nekog elementa, itd.
- Primeri ovih struktura su **BloomFilter**, Locality-sensitive hashing, **Count-min sketch**, **Skip list**, Cuckoo filter, **HyperLogLog**, Quotient filter, itd

Hash funkcije

- Jednosmerne funkcije (one-way) su zamišljene sa idejom da bude teško da na osnovu izlaza (outputa) možežemo dobiti originalni ulaz (input)
- Obično za ulaze **različite duzine daju izlaze uvek jednake dužine** – uniformno predstavljanje podatka
- Uvek za isti ulazi daje isti rezultat (izlaz)
- Dobar način da se proveri da li je neko komprovitovao ulazne (originalne) podatke
- *Mogu proizvesti kolizije - dva različita podataka imaju istu hash vrednost*
- Primeri: MD5, SHA-256, SHA-384, SHA-512, murmur itd

Problem 1

Potrebno je da proverimo da li je uneta e-mail adresa zauzeta, i pred nama su sledeća ograničenja:

- Treba da potrošimo izuzetno **malo** resursa
- Odgovor treba da dobijemo **brzo** (instant)
- Dopušteno je tolerisati **false-positive** odgovore, zarad brzine i male potrošnje resursa

Predlozi :) ?

Problem 2

Potrebno je da pretražimo **n** čvorova koji sadrže korisničke podatke. Svaki čvor sadrži 100TB podataka (Facebook, Twitter, Instagram, ...). Ako znamo da se podaci sigurno nalaze na bar **3** čvora, i dalje treba da pretražimo veliku količinu podataka. Pretragu treba da ubrzamo tako što nećemo vršiti pretragu ako znamo da **ključ** nije na tom čvoru. I pred nama su sledeća ograničenja:

- Treba da smanjimo broj pretraga
- Odgovor treba da dobijemo **brzo**
- Treba da potrošimo izuzetno **malo** resursa

Predlozi :) ?

Bloom filter - uvod

- Bloom filter je probabilistička struktura podataka dizajnirana da brzo i efikasno odredi da li je neki element prisutan u skupu
- Bloom filter je fikasna struktura u pogledu korišćenja memorijskog prostora
- Bloom filter sa 1% false positive rate zahteva **samo 9,6 bita po elementu bez obzira na veličinu elemenata**

- Cena koja se plaća za ovu efikasnost je ta da Bloom filter može da nam kaže da li element **sigurno nije** u skupu, ili je on **možda** u skupu
- Bloom filter podržava: dodavanje, i pretragu elemenata
- (osnovni) Bloom filter ne podržava **brisanje** elemenata
- (osnovni) Bloom filter ne podržava vraćanje **broja** elemenata koji je zapisan
- Neke naprednije izvedbe ove strukture omoguźavaju i ove funkcije
- Za većinu realnih primena, ove funkcije nam nisu preko potrebne

Bloom filter - parametri

Bloom filter zahteva nekoliko parametara za ispravan rad:

- Niz bitova veličine **m**, gde su svi bitovi inicijalno postavljeni na vrednost **0**
- **k** *hash* funkcija za izračunavanje heševa za dati ulaz
- Koristeći prethodne parametre, možemo odrediti poziciju bit-a koji treba da prebacimo sa **0** na **1** prilikom dodavanja elementa u filter

Bloom filter - dodavanje

Kada želimo da dodamo element u filter, koristimo par jednostavnih pravila:

- koristeći **k** hash funkcija $(h_1(x), h_2(x), \ldots h_k(x))$ izračunamo indekse u setu koje ćemo prebaciti sa **0** na **1**.
- ako se desi kolizija, tj. da je bit već postavljen na vrednost **1**, sve ok, nastavljamo dalje
- Za set veličine **m**, imamo **k** hash funkcija, onda je proces dobijanja indeksa sledeći:

$$h_1(\text{"key"}) \,\%\, m = i_1$$
$$h_2(\text{"key"}) \,\%\, m = i_2$$
$$\vdots$$
$$h_k(\text{"key"}) \,\%\, m = i_k$$

Gde $i_{ith} \in \{0, 1, \ldots m-1\}$

Bloom filter - pretraga

Kada želimo da proverimo da li je element prisutan u filteru, koristimo par sledećih pravila:

- koristeći **k** hash funkcija $(h_1(x), h_2(x), \ldots h_k(x))$ potrebno je da izračunamo indekse u setu gde treba da proverimo da li je vrednost **0**
- Da bi smatrali da je element u setu, svih **k** indeksa treba da vrate vrednost **1**
- Ova operacija može da dovede do **false-positive** resultata zbog kolizije *hesh* funkcija
- Zbog prethodne tvrdnje Bloom filter ne može da garantuje da je element **sigurno** prisutan u skupu
- Ali **sigurno** može da nam kaže ako on nije prisutan u skupu – vrlo korisna stvar

Bloom filter - primer

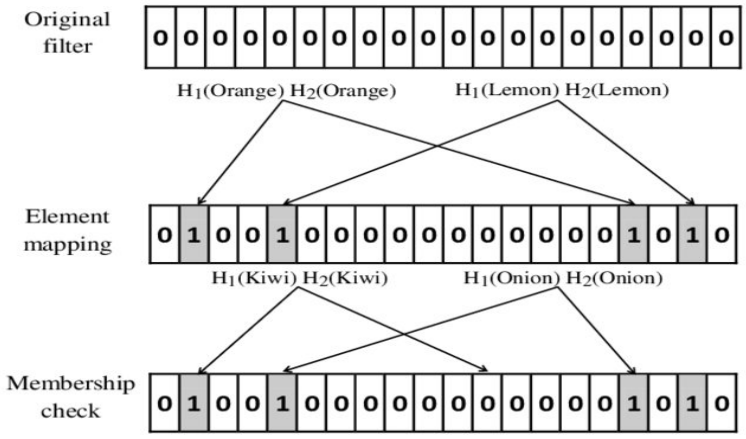

(Shubbar, Ro'aa and Ahmadi, Mahmood. (2019). A Filter-Based Design of Pending Interest Table in Named Data Networking. Journal of Network and Systems Management. 27. 10.1007/s10922-019-09495-y.)

Bloom filter - formule

- Parametre **m** i **k** nećemo nasumično birati
- Njih biramo shodno tome koju verovatnoću **false-positive** dopuštamo u sistemu
- Ako pretpostavimo da će set sadržati **n** elemenata, onda verovatnoću **p** možemo izračuanti sa: $p = (1 - [1 - \frac{1}{m}]^{kn})^k$
- Veličinu bit seta **m** možemo izračunati na sledeći način: $m = -\frac{n \ln p}{(\ln 2)^2}$
- Optimalan broj hash funkcija **k**, možemo izračunati na sledeći način: $k = \frac{m}{n} \ln 2$

Bloom filter - nedostaci

Bloom filter ima nekoliko nedostataka:

- Veličina Bloom filtera mora biti poznata unapred, što nije uvek moguće lako odrediti (Scalable Bloom Filter rešava taj problem)
- Bloom filter ne može da nam vrati listu elemenata koji su uneti
- Bloom filter ne može sa sigurnošću da nam vrati da li je element u setu
- Brisanje elemenata nije moguće (Counting Bloom Filter omogućava brisanje)

Bloom filter - pitanja

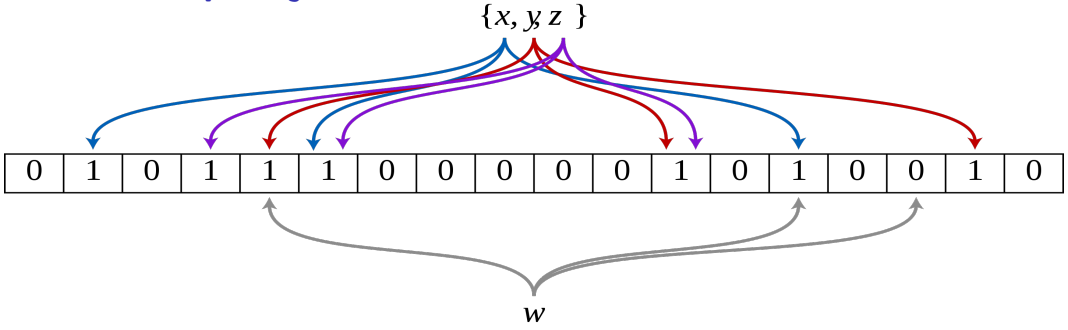

(Image by David Eppstein)

Pitanja :) ?

Bloom filter - dodatni materijali

- Theory and Practice of Bloom Filters for Distributed Systems
- Network Applications of Bloom Filters: A Survey
- Scalable Bloom Filters
- The Deletable Bloom filter - A new member of the Bloom family
- Bloom Filters A Tutorial, Analysis, and Survey
- Applications of Bloom Filter
- Probabilistic Data Structures and Algorithms for Big Data Applications