

Filtros de Bloom

Certo.

Para essa ideia fazer sentido, é preciso que o acesso ao filtro seja muito rápido.

E a melhor maneira de conseguir isso é usar um filtro imperfeito.

Quer dizer, vão haver casos em que o filtro vai dizer SIM mas o elemento não está na base de dados.

Nesses casos, a base de dados terá que ser consultada para verificar que o elemento realmente não está lá.

Por outro lado, quando o filtro responde NÃO é porque o elemento não está lá mesmo.

Legal.


Mas como é que a coisa funciona?

Bom, a ideia é simples.

Quer dizer, nós vamos usar k funções de dispersão

$$h_1(.), \quad h_2(.), \quad \dots, \quad h_k(.)$$

E um vetor de bits com tamanho m , que vai fazer o papel de filtro




Agora imagine que nós fazemos a inserção do elemento x na base de dados.

Daí, para registrar esse fato no filtro, nós calculamos as posições,

$$i_1 \leftarrow h_1(x), \quad i_2 \leftarrow h_2(x), \quad \dots \quad i_k \leftarrow h_k(x),$$

e ajustamos os bits nas posições $i_1, \dots, i_k$ para o valor 1 — *(no início, todos os bits tem o valor 0)*



E a mesma coisa acontece com todos os elementos que são inseridos na base de dados.

Agora, imagine que ocorre uma consulta pelo elemento z .

Daí, nós calculamos as posições

$$j_1 \leftarrow h_1(z), \quad j_2 \leftarrow h_2(z), \quad \dots \quad j_k \leftarrow h_k(z),$$

e examinamos os bits nessas posições do filtro.

Caso ao menos um desses bits seja igual a zero, nós temos a certeza de que o elemento z não está na base de dados — *(porque?)*

Por outro lado, se todos os bits são 1, então existem dois casos

- 1. pode ser que o elemento z tenha sido inserido na base de dados
— *(o que fez com que os bits recebessem o valor 1)*
- 2. ou pode ser que z não esteja lá, e que os bits tenham recebido o valor 1 na inserção de outros elementos

E é assim que surge a possibilidade de um falso positivo.