MAC0439 – Laboratório de Bancos de Dados

Índices

Acelerando o acesso aos dados

Profa. Kelly Rosa Braghetto

O que são índices?

- Estruturas de armazenamento são compostas por *arquivos.*
- Por exemplo, um **arquivo de dados** pode ser usado para manter uma relação do BD.
- Um arquivo de dados pode ter um ou mais **arquivos de índice** associados a ele.
- Cada arquivo de índice associa valores da chave de busca a ponteiros para registros nos arquivos de dados que contém esses valores para o(s) atributo(s) da chave de busca.

Índices

- *Índice* = estrutura de dados usada para acelerar o acesso às tuplas de uma relação, dados valores para um ou mais atributos
- Índices evitam “table scans”
  - Tuplas são localizadas imediatamente
- Índices são mantidos pelos SGBDs e ficam armazenados nos seus respectivos bancos de dados

Tipos de Índices

- **Primários X Secundários**
  - Índice primário: é especificado sobre o(s) atributo(s) da chave de ordenação do arquivo de dados
  - Índice secundário: não determina a localização dos registros.
- Uma relação pode ter no máximo um índice primário (geralmente criado sobre a chave primária), mas pode ter vários índices secundários sobre outros atributos.
- Importante não confundir:

  chave primária

  chave de busca

  chave de ordenação

Tipos de Índices

- **Densos X Esparsos**
  - Índice denso: possui uma entrada no arquivo para cada registro no arquivo de dados
  - Índice esparso: possui entradas somente para alguns dos registros no arquivo de dados (geralmente, uma entrada no índice para cada bloco do arquivo de dados)
    - Só pode ser usado se o arquivo de dados estiver ordenado pela chave de busca

Índice Primário Denso

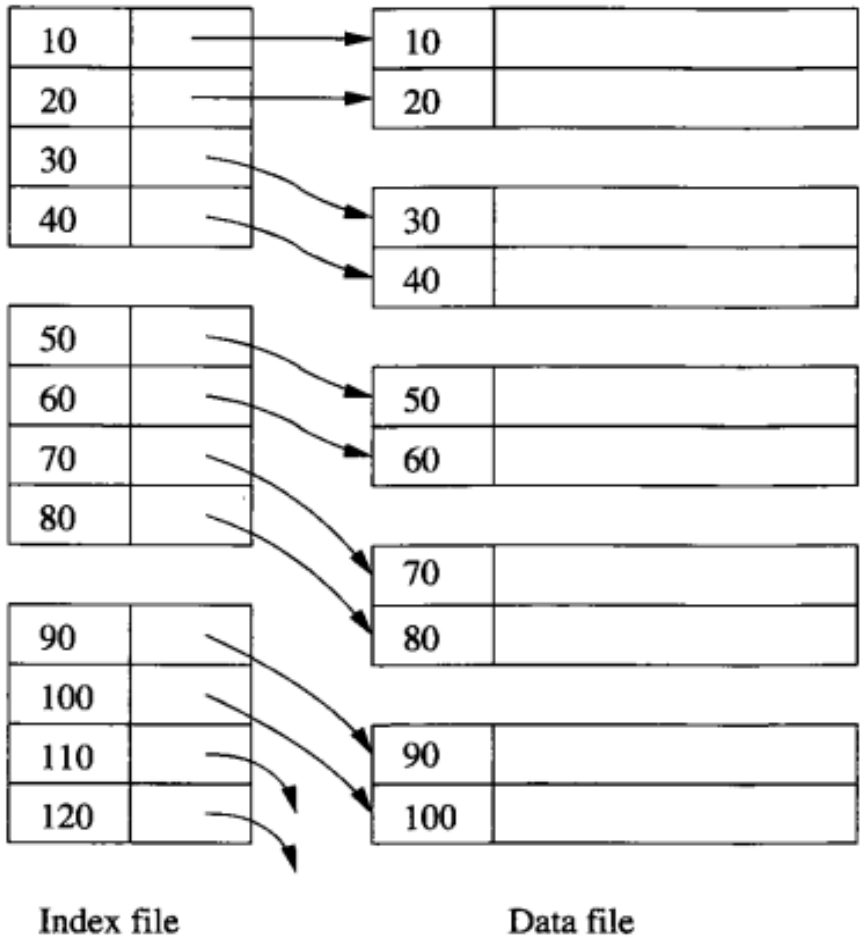

Figure 14.2: A dense index (left) on a sequential data file (right)

Índice Primário Esparso

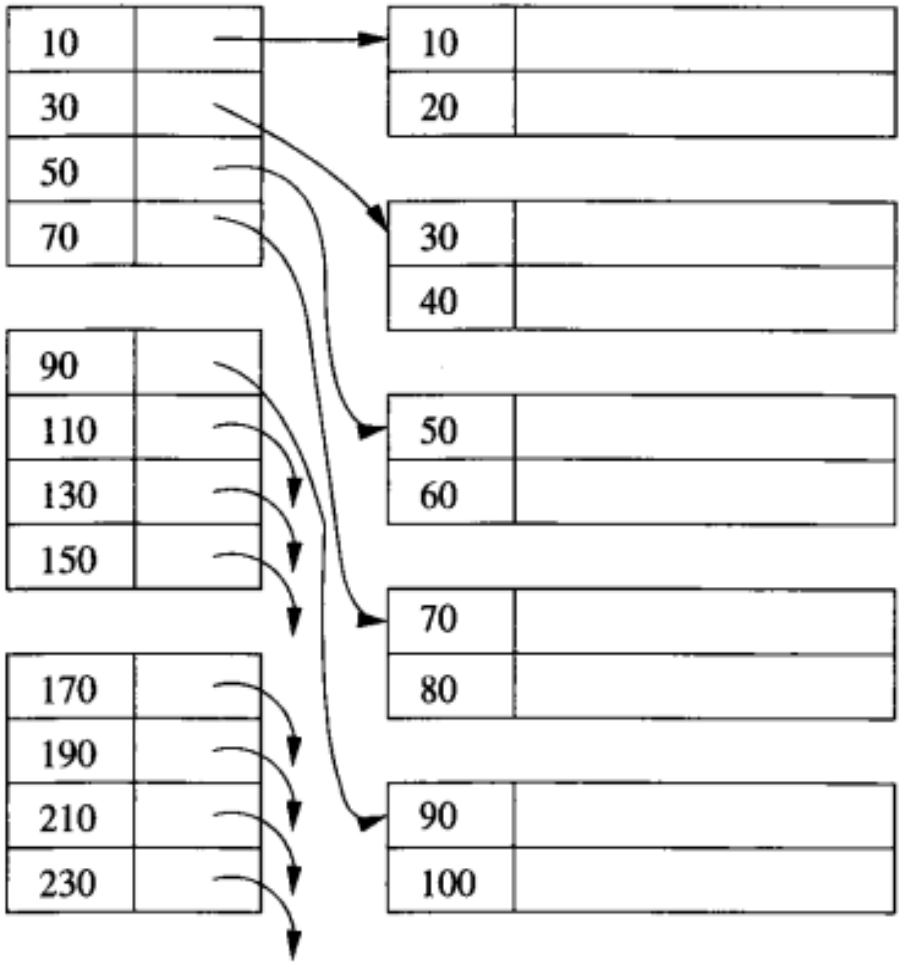

Figure 14.3: A sparse index on a sequential file

Índice Esparso Multinível

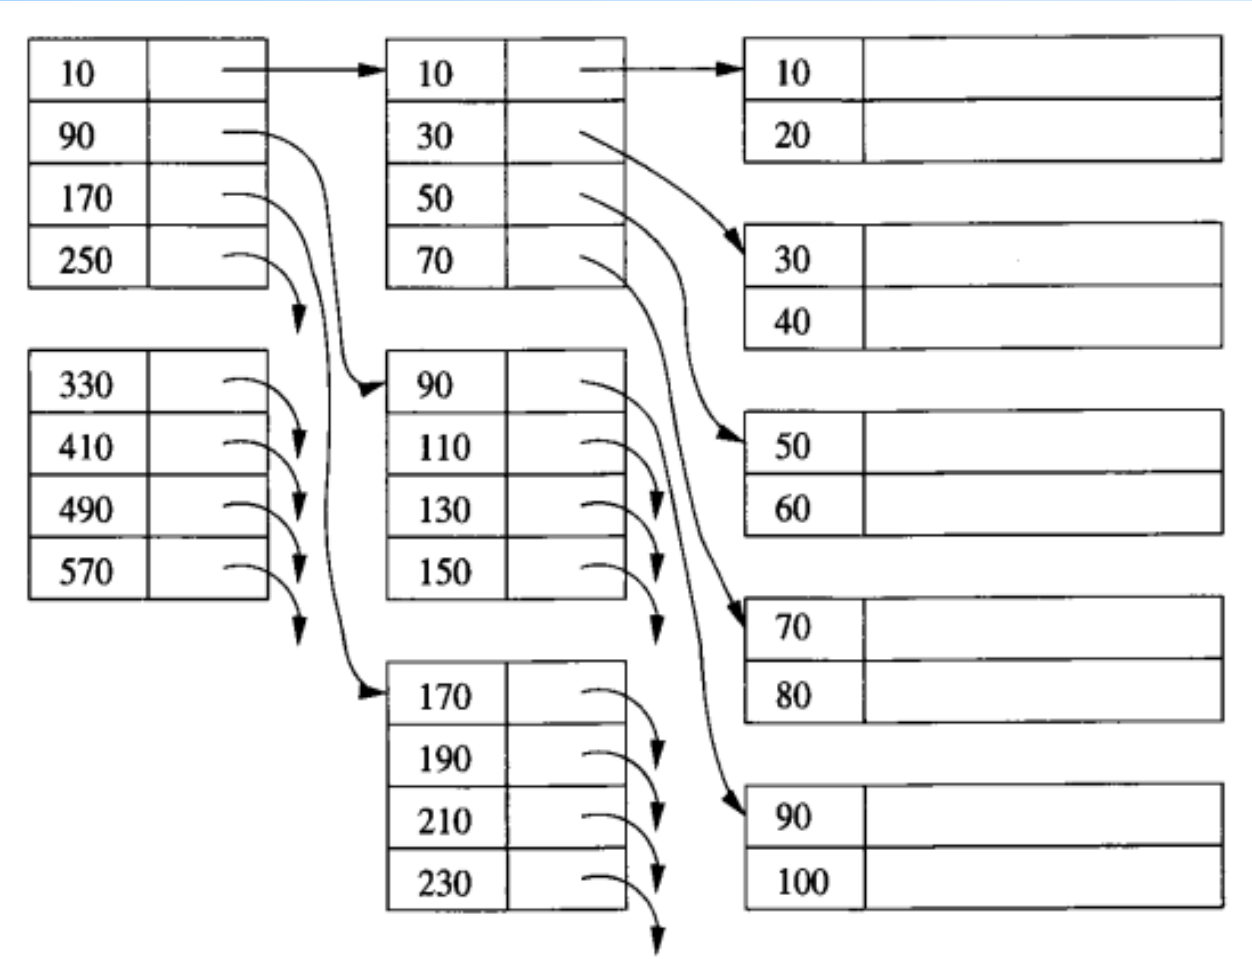

Figure 14.4: Adding a second level of sparse index

Índice Secundário

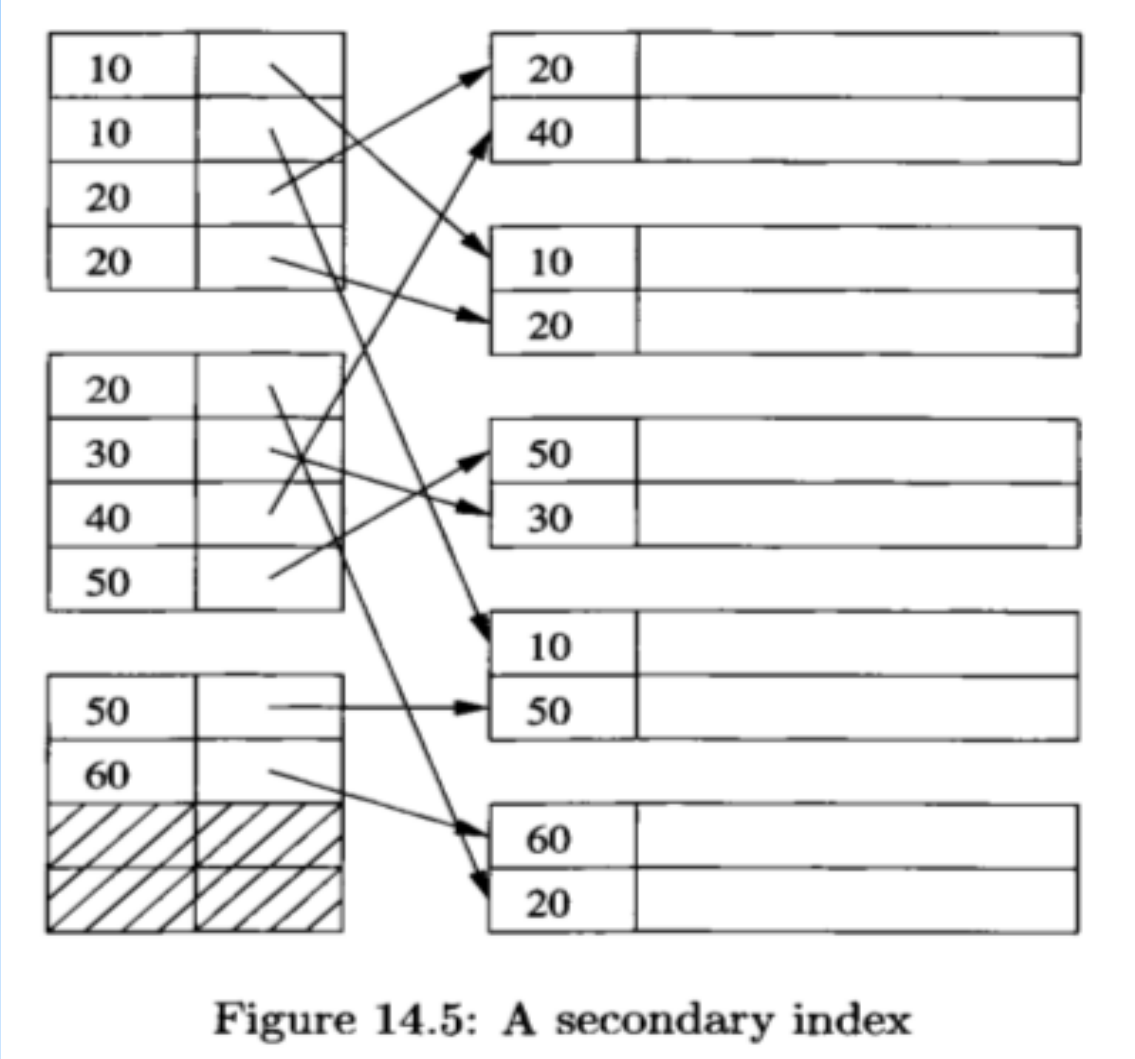

Figure 14.5: A secondary index

Índices secundários são sempre densos! Por quê?

Índice Secundário com Indireção

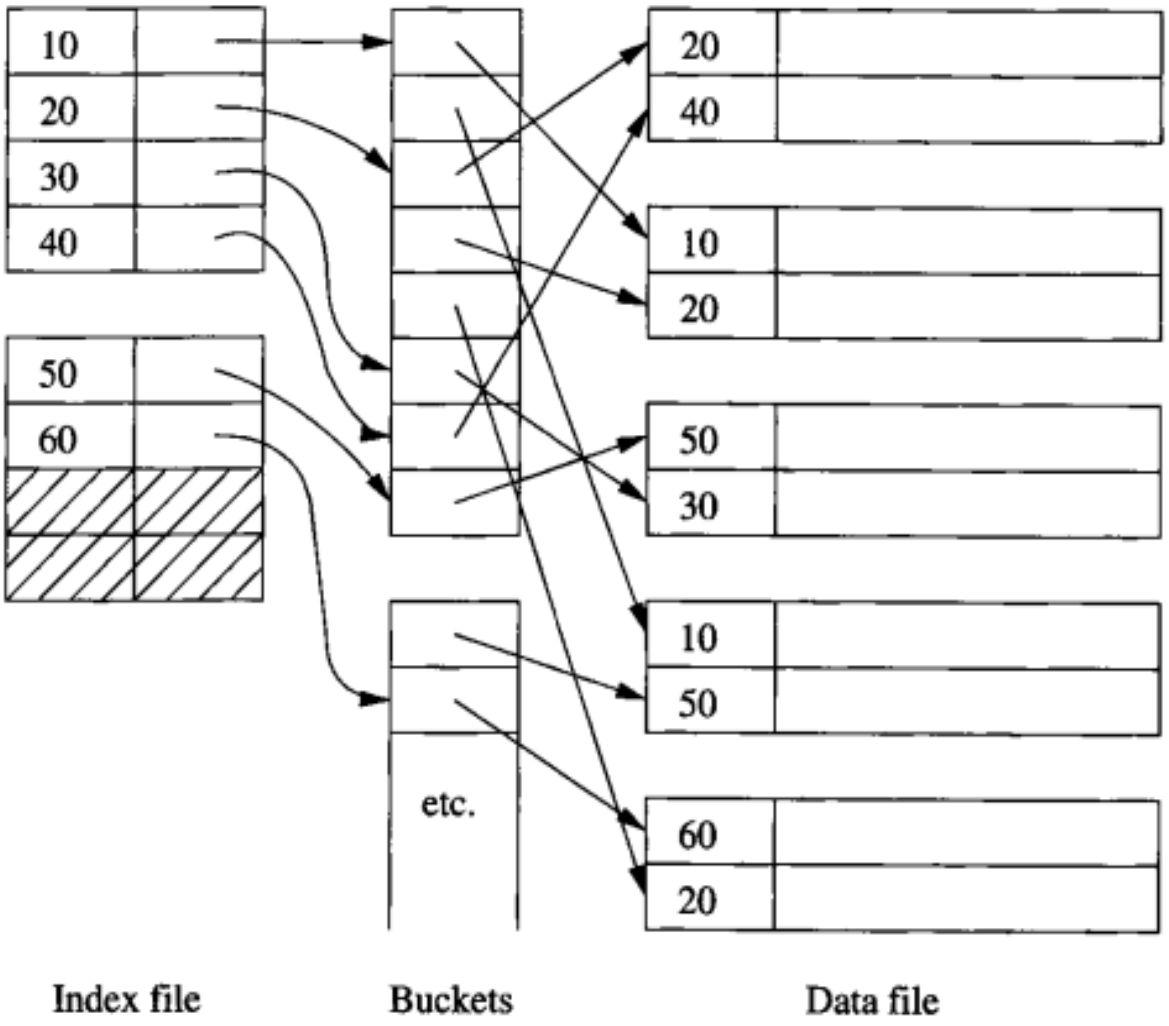

Figure 14.7: Saving space by using indirection in a secondary index

Estruturas de Dados Usadas para Implementar Índices

- Tabela *hash*
  - Tempo de acesso: constante
  - Úteis para condições envolvendo comparações de igualdade
- Árvore balanceada de busca, com nós “gigantes” (uma página inteira do disco)
  - *árvore-B (B-tree)*
  - Tempo de acesso: logarítmico
  - Úteis para condições envolvendo comparações feitas com os operadores **=, >, >=, <, <=**

Recordar é Viver:
Estrutura de Índice B+ Tree

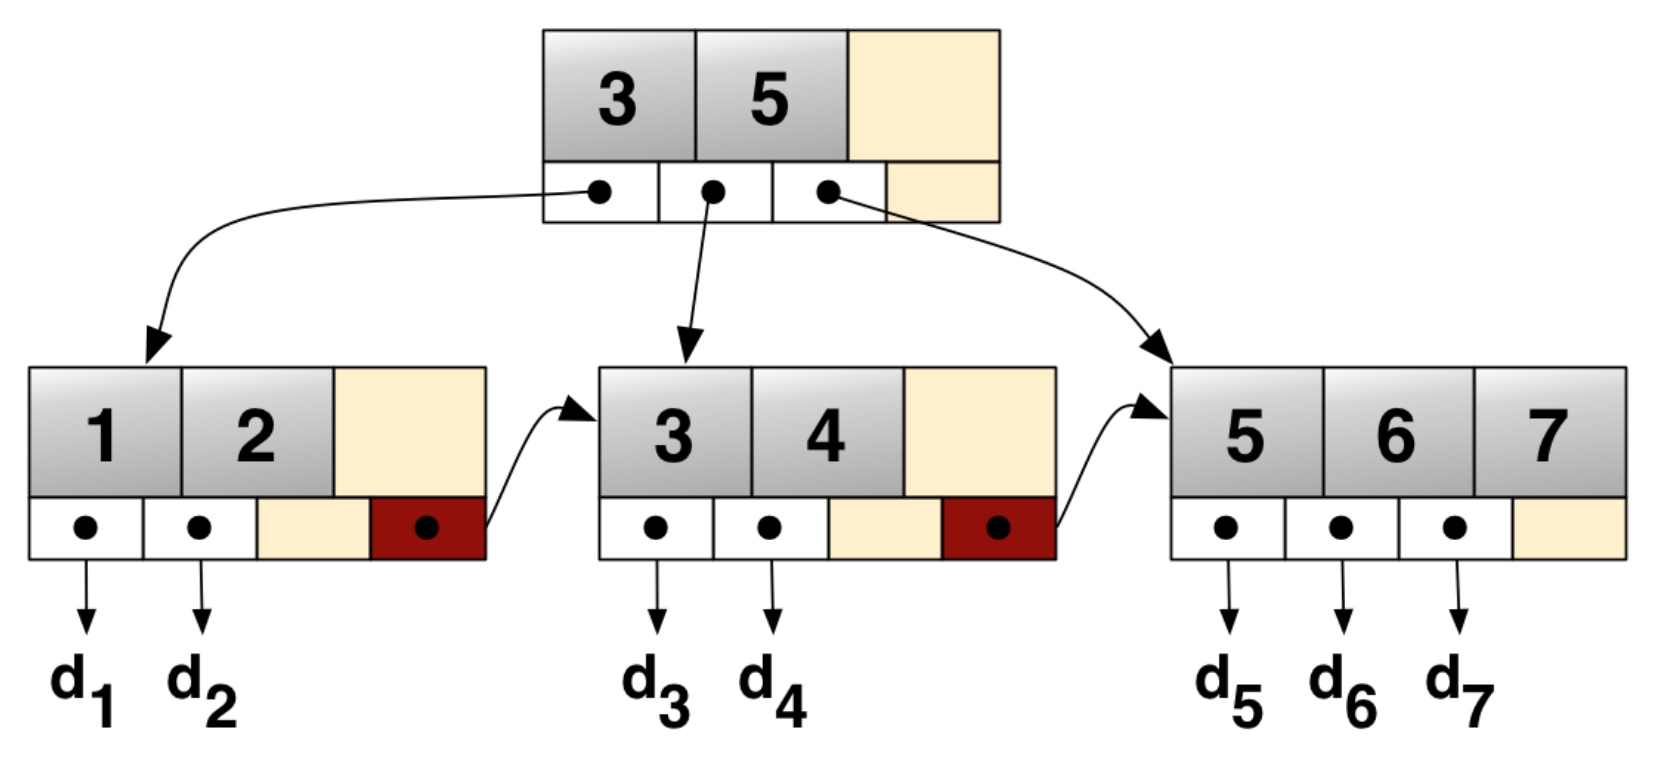

Fonte: http://en.wikipedia.org/wiki/B+_tree

Recordar é Viver: Estrutura de um Índice Hash

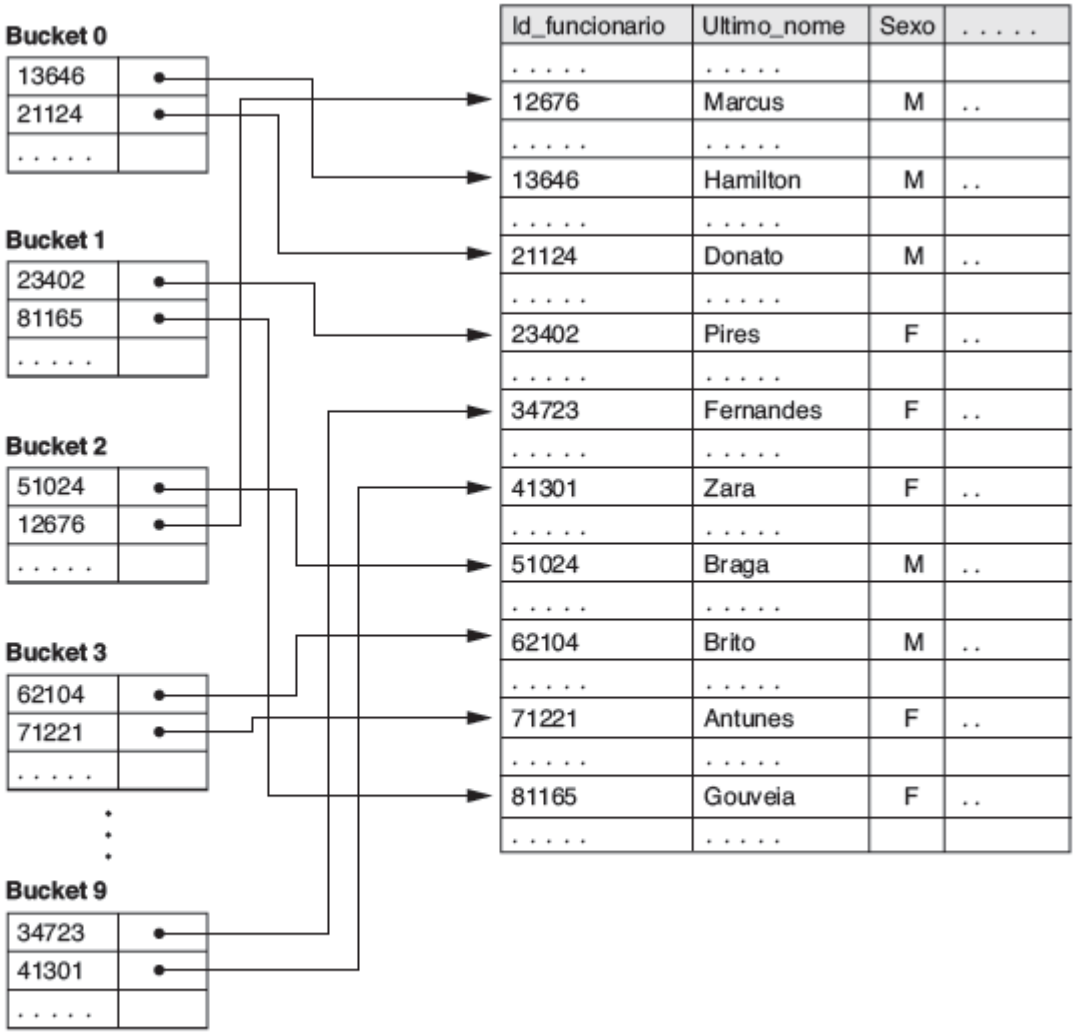

Figura 18.15
Indexação baseada em hash.

Fonte: livro “Sistemas de Bancos de Dados”, Elmasri e Navathe

Declaração de Índices

- Sintaxe típica na SQL

CREATE INDEX <nome_indice> ON <nome_tabela>(<lista de atributos>);

- Exemplos:

```
CREATE INDEX IdxFabRefri ON
  Refrigerantes(fabricante);
CREATE UNIQUE INDEX IdxRefri ON
  Refrigerantes(nome);
CREATE INDEX IdxVenda ON
  Vendas(nome_lanch,nome_refri);
```

O Uso de Índices

- Dado um valor *v*, o índice nos leva apenas às tuplas que possuem *v* como valor para o(s) atributos(s) do índice
- Exemplo: use IdxFabRefri e IdxVendas para encontrar o preço dos refris produzidos pela 'Cola-Coca' e vendidos no 'Sujinhos'. (próximo slide)

O Uso de Índices (2)

```
SELECT price FROM
                Refrigerantes, Vendas
WHERE fabricante = ’Cola-Coca’ AND
    Refrigerante.nome =
    Vendas.nome_refri AND
    nome_lanch = ’Sujinhos’;
```

1. Usa IdxFabRefri para obter todos os refris feitos pela 'Cola-coca'.
2. Depois, usa IdxVendas para obter os preços desses refris no Sujinhos

Sintonia Fina (*Tuning*) de BDs

- Uma das principais dificuldades relacionadas a acelerar o acesso a um BD é decidir quais índices criar
- Pró: Um índice melhora o desempenho de consultas que podem usá-los
- Contra: Um índice piora o desempenho das modificações feitas sobre sua relação (porque uma modificação na relação pode fazer com que o índice precise ser atualizado também)

Efeitos “Colaterais” do Uso de Índices

- Mais consumo de espaço de armazenamento (problema pequeno)
- Custo para a criação do índice (problema médio)
- Custo para a manutenção do índice (problema grave)
  - Os benefícios do uso de um índice para melhorar o tempo de execução das consultas podem ser mitigados por esse custo de manutenção

Exemplo: Sintonia Fina

- Suponha que as únicas coisas que fazemos sobre o nosso BD de refri são:
  1. Inserir novos fatos em uma relação (10%).
  2. Encontrar o preço de um dado refri em uma dada lanchonete (90%).
- Nesse caso, IdxVendas em Vendas(nome_lanch, nome_refri) realmente ajudaria em um melhor desempenho, mas IdxRefri sobre Refrigerantes(fabricante) somente atrapalharia .

Benefícios de um Índice Dependem de:

- Tamanho da tabela (e possivelmente de seu layout)
- Distribuição dos valores das colunas indexadas
- Frequência de consultas X frequência de modificações

Softwares “Conselheiros” para Sintonia Fina *(Tuning Advisors)*

- Subárea de pesquisa muito importante
  - Fazer a sintonia de um BD de forma manual é uma tarefa muito árdua
- Um conselheiro obtém um conjunto de consultas que serão usadas como carga de trabalho para avaliar o desempenho do BD. Para constituir essa carga, o conselheiro:
  1. Escolhe consultas de forma aleatória, a partir de um histórico de consultas executadas sobre o BD ou
  2. Usa consultas de exemplo fornecidas por um projetista do BD

Software “Conselheiros” para Sintonia Fina *(Tuning Advisors)* (2)

- O conselheiro gera índices candidatos e avalia cada um deles usando a carga de trabalho (= consultas) selecionada:
  - Cada consulta da carga é submetida ao otimizador de consulta, que assume que somente o índice em avaliação está disponível
  - A melhora/degradação no tempo médio de execução das consultas é medida

Criação de Índices no PostgreSQL

- Estrutura geral (bem simplificada!):

CREATE [UNIQUE] INDEX [CONCURRENTLY]

<nome do índice> **ON** < nome da tabela >

[**USING** <método>] ({ coluna } [**ASC** | **DESC**] [, ...]);

- **UNIQUE** cria uma restrição de unicidade sobre a(s) coluna(s) do índice.
- **CONCURRENTLY** permite o PostgreSQL construir o índice sem bloquear a tabela para modificações concorrentes (inserts, updates ou deletes) → **isso pode ser perigoso!**

Criação de Índices no PostgreSQL

- O índice também pode ser construído para valores computados a partir de uma expressão envolvendo um ou mais atributos de uma tabela. Ex:

  CREATE INDEX idx_maiuscula ON

  Lanchonete(upper(nome)) ;

- Além de índices para tabelas, podemos também criar índices para visões materializadas.

Métodos (Tipos) para Índices no PostgreSQL

Métodos existentes no PostgreSQL:

Btree (padrão), **Hash**, **GiST, SP-GiST** e **GIN**

- Somente o método **Btree** pode ser usado para índices do tipo **UNIQUE**.
- Somente os métodos **Btree, GiST** e **GIN** suportam índices com várias colunas.
- Índices com mais de um campo somente serão utilizados para agilizar consultas se as cláusulas envolvendo os campos indexados forem ligadas por AND.
- Quando indicamos atributos como chave primária em uma tabela, automaticamente é criado um índice Btree sobre eles.

Métodos para a Criação de Índices no PostgreSQL

- **Btree** – Árvores-B podem ser usadas em consultas com condições de seleção baseadas em igualdade de valores ou em intervalos, sobre dados que podem estar armazenados ordenadamente

- O planejador de consultas do PostgreSQL considerará o uso de um índice do tipo **Btree** sempre que uma coluna indexada estiver envolvida em uma comparação usando um ou mais dos seguintes operadores:
  - **<, <= , =, >= e >**
  - **like** (se o padrão for uma constante e estiver ancorado no início da string, como em coluna like 'MAC%')

Métodos para a Criação de Índices no PostgreSQL

- **Hash** – só pode ser usado em consultas envolvendo condições de seleção baseadas em simples comparações de igualdade

- O planejador de consultas do PostgreSQL considerará o uso de um índice do tipo **Hash** sempre que uma coluna indexada estiver envolvida em uma comparação usando o operador “=”

- Nota: por problemas na forma como ele é implementado no gerenciador, o uso desse tipo de índice no PostgreSQL atualmente é desencorajado

GiSTs
(*Generalized Search Trees*)

- **GiSTs** não são um tipo único de índice, mas sim uma infraestrutura dentro da qual muitas estratégias de indexação diferentes podem ser implementadas para diferentes tipos de dados.
- São baseados em árvores de busca balanceadas.
- A distribuição padrão do PostgreSQL inclui classes de operações para vários tipos de dados bidimensionais e geométricos, que suportam consultas indexadas usando os seguintes operadores:
  - <<, &<, &>, >>, <<|, &<|, |&>, |>>, @>, <@, ~=, &&
  - O significado desses operadores está em:

    http://www.postgresql.org/docs/9.3/static/functions-geometry.html

GiSTs
(*Generalized Search Trees*)

- Índices do tipo GiST também são capazes de otimizar consultas do tipo "vizinhos-mais próximos", como em:

  SELECT * FROM lugares

  ORDER BY localizacao <-> point '(101,456)'

  LIMIT 10;

  que encontra os 10 lugares mais próximos de um dado ponto alvo.
- O operador <-> calcula a distância entre pontos.

SP-GiSTs
(Space-partitioned GiSTs)

- **Assim como os GiSTs, os SP-GiSTS são** uma infraestrutura dentro da qual diferentes estratégias de indexação podem ser implementadas.
- Permitem a implementação de estruturas de dados em disco **não balanceadas**, como as **árvores de prefixo** (*tries*) e as **árvores k-d**
- Suportam consultas indexadas usando os seguintes operadores:
  - <<, >>, ~=, <@, <^, >^
  - O significado desses operadores está em:

    http://www.postgresql.org/docs/9.3/static/functions-geometry.html

GIN
(Generalized Inverted Index)

- **GINs** são índices invertidos que podem lidar com valores que contêm mais de uma chave, como um vetor, por exemplo.
- Assim como GiST, GIN pode suportar diferentes estratégias de indexação.
- Os operadores com os quais um índice GIN pode ser usado variam dependendo da estratégia de indexação.
- A distribuição do PostgreSQL inclui classes de operadores GIN para vetores unidimensionais (tipo *array*), que suportam consultas usando os seguintes operadores:
  - <@ (está contido em?), @> (contém?), =, && (sobrepõe?)
  - http://www.postgresql.org/docs/9.3/static/functions-array.html

Plano de Execução de uma Consulta

- Para ver qual é o plano de execução que um SGBD usa para uma dada consulta, usamos o comando **EXPLAIN**.
- Exemplo:

```
EXPLAIN SELECT price FROM Refrigerantes, Vendas
WHERE fabricante = 'Cola-Coca' AND
   Refrigerante.nome = Vendas.nome_refri AND
   nome_lanch = 'Sujinhos';
```

Para mais Detalhes sobre Índices no PostgreSQL

- Livro: “Sistemas de Bancos de Dados”, 6ª Edição, Elmasri e Navathe – Capítulo 18
- Livro: “Database Systems – The complete book”, 2nd edition, Garcia Molina, Ullman, Widom – Seções 8.3, 8.4 e Capítulo 14
- http://www.postgresql.org/docs/9.3/static/sql-createindex.html
- http://www.postgresql.org/docs/9.3/static/indexes.html
- http://www.postgresql.org/docs/9.3/static/gist.html
- http://www.postgresql.org/docs/9.3/static/spgist-intro.html
- http://www.postgresql.org/docs/9.3/static/gin-intro.html

Referências Bibliográficas

- Capítulo 6 do livro “Database Systems – The Complete Book” (1ª edição), Garcia-Molina, Ullman e Widom