

Otimização de Consultas Baseada em Custo

Cristina Dutra de Aguiar Ciferri

Estatísticas

- Informações aproximadas sobre
 - base de dados
 - cada tabela
 - cada atributo de cada tabela
 - cada índice
 - Coletadas
 - durante cada operação de consulta
 - pela execução de comandos específicos para coletá-las
-

Algoritmos e Funções Custo

- Seleção
 - busca linear (busca sequencial)
 - busca binária
 - índice primário
 - índice secundário
 - índice de agrupamento (cluster)
 - função *hash*
 - árvore-B e suas variações
-

Algoritmos e Funções Custo

- Projeção
 - recupera os registros e considera somente os atributos desejados
 - Ordenação
 - *sort-merge* externo
 - Produto Cartesiano
 - recupera e processa todos os registros
-

Algoritmos e Funções Custo

- Junção
 - junção de laço aninhado simples
 - junção de laço aninhado de blocos
 - junção de laço aninhado indexada
 - *sort-merge* junção
 - *hash* junção
 - União, Intersecção e Diferença
 - ordenação
 - função *hash*
-

Custo da Busca Linear

$$C_{\text{busca_linear}} = b$$

- b: número de blocos que contêm os registros
- todos os blocos são varridos

$$C_{\text{busca_linear}} = (b/2)$$

- igualdade na chave primária
 - metade dos blocos é varrido, em média
-

Custo da Busca Binária

$$C_{\text{busca_binária}} = \log_2(b) + \lceil s/bfr \rceil - 1$$

- $\log_2(b)$: custo para localizar o primeiro registro
- $\lceil s/bfr \rceil$: blocos ocupados pelos registros que satisfazem à condição de seleção
- 1: custo para recuperar o primeiro registro

$$C_{\text{busca_binária}} = \log_2(b)$$

- igualdade na chave primária
-

Custo com Índice Primário

igualdade

$$C_{\text{prim_igual}} = x + 1$$

- x: número de níveis no índice
- 1: bloco adicional recuperado

desigualdade

$$C_{\text{prim_des}} = x + (b/2)$$

- b/2: estimativa de que somente metade dos registros satisfazem à condição de seleção
-

Custo com Cluster

$$C_{\text{cluster}} = x + \lceil s/bfr \rceil$$

- x : número de níveis no índice
 - $\lceil s/bfr \rceil$: quantidade de blocos ocupada pelos registros que satisfazem à condição de seleção
-

Custo com Índice Secundário

igualdade

$$C_{\text{sec_igual}} = x + s$$

- x: número de níveis no índice
- s: cardinalidade de seleção do atributo indexado
 - s = 1 para atributo UNIQUE

desigualdade

$$C_{\text{sec_des}} = x + (b_{i_1}/2) + (r/2)$$

- $b_{i_1}/2$: metade dos blocos serão acessados
 - $r/2$: metade dos registros serão acessados
- (estimativas)
-

Relações

cliente (nro_cli, nome_cli, end_cli,
saldo, cod_vend)



vendedor (cod_vend, nome_vend)

Relação Cliente (Estatísticas)

- Número de registros (r) = 10.000
 - Número de blocos de disco (b) = 2.000
 - Fator de bloco de disco (bfr) = 5
 - Índice primário em `nro_cli` (chave primária)
 - número de níveis (x) = 4
 - número médio de registros que satisfazem à condição de igualdade (s) = 1
-

Relação Cliente (Estatísticas)

- Índice secundário em `cod_vend`
 - número de níveis $(x) = 2$
 - número de blocos no nível de folha $(b_{l_1}) = 4$
 - número de valores distintos $(d) = 125$
 - número médio de registros que satisfazem à condição de igualdade $(s) = 80$
 - Índice secundário em `saldo`
 - número de níveis $(x) = 3$
 - número de blocos no nível de folha $(b_{l_1}) = 4$
-

Consultas

Consulta	Busca
$\sigma_{\text{nro_cli} = 4}$ (cliente)	<ul style="list-style-type: none">• linear• binária• índice primário; igualdade na chave

- $C_{\text{busca_linear}} = (b/2) = 2.000/2 = 1.000$
- $C_{\text{busca_binária}} = \log_2(b) = \log_2(2.000) = 11$
- $C_{\text{prim_igual}} = x + 1 = 4 + 1 = 5$

escolha do otimizador
de consultas

Consultas

Consulta	Busca
$\sigma_{\text{nro_cli} > 4}$ (cliente)	<ul style="list-style-type: none">• linear• índice primário; desigualdade na chave

- $C_{\text{busca_linear}} = b = 2.000$
- $C_{\text{prim_des}} = x + (b/2) = 4 + (2.000/2) = 1.004$


escolha do otimizador
de consultas

Consultas

Consulta	Busca
$\sigma_{\text{cod_vend} = 5}$ (cliente)	<ul style="list-style-type: none">• linear• secundário; igualdade na chave

- $C_{\text{busca_linear}} = b = 2.000$
- $C_{\text{sec_igual}} = x + s = 2 + 80 = 82$

escolha do otimizador
de consultas



Consultas

Consulta	Busca
$\sigma_{\text{cod_vend} = 5 \wedge \text{saldo} > 100}$ (cliente)	<ul style="list-style-type: none">• linear• seleção conjuntiva – índice único

- $C_{\text{busca_linear}} = b = 2.000$
- $C_{\text{sec_igual}}^{\text{cod_vend}} = x + s = 2 + 80 = 82$
- $C_{\text{sec_des}}^{\text{saldo}} = x + (b_{i1}/2) + (r/2)$
 $= 3 + (4/2) + (2.000/2)$
 $= 3 + 2 + 1.000 = 1.005$

otimizador de
consultas busca
primeiro por
cod_vend = 5

Consultas

Consulta	Busca
$\sigma_{\text{nro_cli} = 4 \wedge \text{cod_vend} = 5}$ (cliente)	<ul style="list-style-type: none">• linear• seleção conjuntiva<ul style="list-style-type: none">– índice único

- $C_{\text{busca_linear}} = b = 2.000$
- $C_{\text{prim_igual}}^{\text{nro_cli}} = x + 1 = 4 + 1 = 5$
- $C_{\text{sec_igual}}^{\text{cod_vend}} = x + s = 82$

otimizador de
consultas busca
primeiro por
nro_cli = 4

Junção

$$R \bowtie_{\text{condição_junção}} S$$

- Concatena registros relacionados de R e S em registros únicos
 - Métodos
 - junção de laço aninhado
 - simples, **de blocos**, **indexada**
 - *sort-merge* junção
 - *hash* junção
-

Junção de Laço Aninhado de Blocos

- Característica
 - examina todos os pares de registros nas duas relações R e S, lendo bloco a bloco
 - Algoritmo (ideia)
 - para cada registro t_R na relação externa R
 - para cada registro t_S na relação interna S
 - selecione os pares de registros (t_R, t_S) que satisfaçam à condição de junção
-

Junção de Laço Aninhado de Blocos

$$C_{\text{laço_blocos}} = b_R + (b_R * b_S) + ((js * |R| * |S|) / bfr_{RS})$$

- b : número de blocos que contêm os registros
 - bfr_{RS} : fator de bloco de disco (arquivo resultante)
 - $(js * |R| * |S|) / bfr_{RS}$: custo de escrever o arquivo resultante em disco
-

Junção de Laço Aninhado Indexada

- Característica
 - índice no atributo de junção do laço interno
 - Melhoria
 - para cada registro t_R na relação externa R
 - selecione os registros de S que satisfaçam à condição de junção usando o índice
 - Pode ser utilizada tanto com índices já existentes, quanto com índices temporários
-

Junção de Laço Aninhado Indexada

- Índice secundário

$$C_{\text{laço_sec}} = b_R + (|R| * (x_B + s_B)) + ((js * |R| * |S|) / \text{bfr}_{RS})$$

- b : número de blocos que contêm os registros
 - $|R|$: número de registros de R
 - x : número de níveis do índice
 - s : cardinalidade de seleção
 - bfr_{RS} : fator de bloco de disco (arquivo resultante)
 - $(js * |R| * |S|) / \text{bfr}_{RS}$: custo de escrever o arquivo resultante em disco
-

Junção de Laço Aninhado Indexada

- Índice de cluster

$$C_{\text{laço_cluster}} = b_R + (|R| * (x_B + (s_B/bfr_B))) + ((js * |R| * |S|)/bfr_{RS})$$

- b: número de blocos que contêm os registros
 - |R|: número de registros de R
 - x: número de níveis do índice
 - s: cardinalidade de seleção
 - bfr: fator de bloco de disco
 - $(js * |R| * |S|)/bfr_{RS}$: custo de escrever o arquivo resultante em disco
-

Junção de Laço Aninhado Indexada

- Índice primário

$$C_{\text{laço_prim}} = b_R + (|R| * (x_B + 1)) + ((js * |R| * |S|) / \text{bfr}_{RS})$$

- b : número de blocos que contêm os registros
 - $|R|$: número de registros de R
 - x : número de níveis do índice
 - bfr_{RS} : fator de bloco de disco (arquivo resultante)
 - $(js * |R| * |S|) / \text{bfr}_{RS}$: custo de escrever o arquivo resultante em disco
-

Algoritmos de Junção

- Fatores determinantes de desempenho
 - espaço disponível em memória principal
 - tamanho da relação externa em uma junção de laço aninhado
 - menor número de blocos
 - fator de seleção de junção
 - porcentagem de registros de uma relação a ser concatenado com os registros da outra relação
-

Relações

cliente (nro_cli, nome_cli, end_cli,
saldo, cod_vend)



vendedor (cod_vend, nome_vend)

Relação Cliente (Estatísticas)

- Número de registros (r) = 10.000
 - Número de blocos de disco (b) = 2.000
 - Fator de bloco de disco (bfr) = 5
 - Índice primário em `nro_cli`
 - número de níveis (x) = 4
 - número médio de registros que satisfazem à condição de igualdade (s) = 1
-

Relação Cliente (Estatísticas)

- Índice secundário em `cod_vend`
 - número de níveis $(x) = 2$
 - número de blocos no nível de folha $(b_{l_1}) = 4$
 - número de valores distintos $(d) = 125$
 - número médio de registros que satisfazem à condição de igualdade $(s) = 80$
 - Índice secundário em `saldo`
 - número de níveis $(x) = 3$
 - número de blocos no nível de folha $(b_{l_1}) = 4$
-

Relação Vendedor (Estatísticas)

- Número de registros (r) = 125
 - Número de blocos de disco (b) = 13
 - Índice primário em `cod_vend`
 - número de níveis (x) = 1
 - número médio de registros que satisfazem à condição de igualdade (s) = 1
-

Demais Estatísticas

- Seletividade de junção
 - $js = (1 / | \text{vendedor} |) = 1/125 = 0,008$
 - Fator de bloco de disco do arquivo resultante
 - $bfr_{\text{ClienteVendedor}} = 4$
 - Custo de escrever em disco o arquivo resultante
 - $(js * r_{\text{cliente}} * r_{\text{vendedor}}) / bfr_{\text{ClienteVendedor}} = 2.500$
-

Consulta

cliente ⋈_{cliente.cod_vend = vendedor.cod_vend} vendedor

- Junção de laço aninhado de blocos
 - cliente: relação externa

$$\begin{aligned}C_{\text{laço_blocos}} &= b_{\text{cliente}} + (b_{\text{cliente}} * b_{\text{vendedor}}) + 2.500 \\ &= 2.000 + (2.000 * 13) + 2.500 \\ &= 30.500\end{aligned}$$

Consulta

cliente ⋈_{cliente.cod_vend = vendedor.cod_vend} vendedor

- Junção de laço aninhado de blocos
 - vendedor: relação externa

$$\begin{aligned}C_{\text{laço_blocos}} &= b_{\text{vendedor}} + (b_{\text{vendedor}} * b_{\text{cliente}}) + 2.500 \\ &= 13 + (13 * 2.000) + 2.500 \\ &= 28.513\end{aligned}$$

Consulta

cliente ⋈_{cliente.cod_vend = vendedor.cod_vend} vendedor

- Junção de laço aninhado indexado
 - cliente: relação externa

$$\begin{aligned}C_{\text{laço_sec}} &= b_{\text{cliente}} + (r_{\text{cliente}} * (x_{\text{cod_vend}} + 1)) + 2.500 \\ &= 2.000 + (10.000 * (1 + 1)) + 2.500 \\ &= 24.500\end{aligned}$$

índice primário em
cod_vend de vendedor

Consulta

cliente ⋈_{cliente.cod_vend = vendedor.cod_vend} vendedor

- Junção de laço aninhado indexado
 - vendedor: relação externa

$$\begin{aligned} C_{\text{laço_sec}} &= b_{\text{vendedor}} + (r_{\text{vendedor}} * \\ &\quad (x_{\text{cod_vend}} + s_{\text{cod_vend}})) + 2.500 \\ &= 13 + (125 * (2 + 80)) + 2.500 \\ &= 12.763 \end{aligned}$$

índice secundário em
cod_vend de cliente