

# Arquivos Indexados por Chaves Secundárias

Vanessa Braganholo

# Arquivos Indexados

---

- ▶ Até agora, as alternativas que vimos funcionam apenas para indexar arquivos por chaves primárias
- ▶ Isso otimiza a busca de um registro pelo valor da chave
- ▶ Em várias aplicações, é necessário buscar registros por atributos não chave

# Arquivos Indexados

---

- ▶ **Exemplo:** Recupere todos os registros de clientes que residem no estado de SP

CodCli	Nome	Cidade	Estado
01	MURILO	RIO DE JANEIRO	RJ
03	MARIA	RIO CLARO	SP
05	PEDRO	RIO DE JANEIRO	RJ
07	CAROLINA	SAO PAULO	SP
10	JOAO	RIO DE JANEIRO	RJ
15	CARLOS	BELO HORIZONTE	MG

- ▶ Neste cenário, arquivos indexados pela chave primária não resolvem o problema
- ▶ A consulta tem que ser respondida através de uma busca sequencial no arquivo

# Como evitar a busca sequencial?

---



# Solução:

Indexar o arquivo pelas chaves secundárias

---

CodCli	Nome	Cidade	Estado
01	MURILO	RIO DE JANEIRO	RJ
03	MARIA	RIO CLARO	SP
05	PEDRO	RIO DE JANEIRO	RJ
07	CAROLINA	SAO PAULO	SP
10	JOAO	RIO DE JANEIRO	RJ
15	CARLOS	BELO HORIZONTE	MG

- ▶ Pode-se usar um índice sobre o atributo Estado, outro sobre Cidade, e outro sobre Nome, se necessário
- ▶ Consultas podem ser respondidas por interseção ou união de conjuntos de listas

# Solução:

Indexar o arquivo pelas chaves secundárias

---

CodCli	Nome	Cidade	Estado
01	MURILO	RIO DE JANEIRO	RJ
03	MARIA	RIO CLARO	SP
05	PEDRO	RIO DE JANEIRO	RJ
		SAO PAULO	

## Arquivo Invertido

- ▶ Pode-se criar um índice invertido sobre Cidade, e então, é necessário
- ▶ Consultas podem ser respondidas por interseção ou união de conjuntos de listas

# Como funciona este índice?

---

## ▶ Arquivo invertido:

- ▶ A cada valor de chave secundária diferente que aparece no arquivo, está associado um conjunto de endereços que possuem aquele valor de chave

## ▶ De onde vem o nome Arquivo Invertido?


- ▶ Em um arquivo comum, ao fornecer um endereço, tem-se a lista dos valores dos atributos do registro armazenado naquele endereço
- ▶ Em um arquivo invertido, ao fornecer um valor de atributo, tem-se a lista de endereços dos registros que possuem aquele valor de atributo
- ▶ Funciona como se fosse uma inversão da “função” arquivo

# Exemplo: Arquivo Invertido para o Atributo Estado

## Arquivo Original

	CodCli	Nome	Cidade	Estado
1	10	JOAO	RIO DE JANEIRO	RJ
2	02	MARIA	RIO CLARO	SP
3	15	CARLOS	BELO HORIZONTE	MG
4	04	CAROLINA	SAO PAULO	SP
5	01	MURILO	ANGRA DOS REIS	RJ

## Arquivo Invertido para Estado



# Implementação de Arquivos Invertidos

Fonte de consulta: Ferraz, I. Programação com Arquivos, ed. Manole. Capítulo 7.

# Uso de Listas Encadeadas

## Arquivo de Índice (Estado)

Estado	PT	Q
MG	6	1
RJ	1	3
SP	2	2

## Arquivo de Dados

	CodCli	Nome	Cidade	Estado	Próximo Estado
1	01	MURILO	RIO DE JANEIRO	RJ	3
2	03	MARIA	RIO CLARO	SP	4
3	05	PEDRO	RIO DE JANEIRO	RJ	5
4	07	CAROLINA	SAO PAULO	SP	-1
5	10	JOAO	RIO DE JANEIRO	RJ	-1
6	15	CARLOS	BELO HORIZONTE	MG	-1

# Uso de Listas Encadeadas

## Arquivo de Índice (Estado)

Estado	PT	Q
MG	6	1
RJ	1	3
SP	2	2

O arquivo de índice tem o endereço do primeiro registro que possui aquele valor.  
O arquivo de índice é **ordenado** pelo valor do atributo que está indexando.

## Arquivo de Dados

	CodCli	Nome	Cidade	Estado	Próximo Estado
1	01	MURILO	RIO DE JANEIRO	RJ	3
2	03	MARIA	RIO CLARO	SP	4
3	05	PEDRO	RIO DE JANEIRO	RJ	5
4	07	CAROLINA	SAO PAULO	SP	-1
5	10	JOAO	RIO DE JANEIRO	RJ	-1
6	15	CARLOS	BELO HORIZONTE	MG	-1

# Pode-se ter várias listas encadeadas

---

- ▶ Uso de várias listas, uma para cada atributo que se deseja indexar
- ▶ Isso implica que serão usados vários arquivos de índice, um para cada atributo

# Arquivos Multilista

## Arquivo de Índice (Estado)

Estado	PT	Q
MG	6	1
RJ	1	3
SP	2	2

## Arquivo de Índice (Cidade)

Cidade	PT	Q
BELO HORIZONTE	6	1
RIO CLARO	2	1
RIO DE JANEIRO	1	3
SAO PAULO	4	1

## Arquivo de Dados

	CodCli	Nome	Cidade	Estado	Próx Estado	Próx Cidade
1	01	MURILO	RIO DE JANEIRO	RJ	3	3
2	03	MARIA	RIO CLARO	SP	4	-1
3	05	PEDRO	RIO DE JANEIRO	RJ	5	5
4	07	CAROLINA	SAO PAULO	SP	-1	-1
5	10	JOAO	RIO DE JANEIRO	RJ	-1	-1
6	15	CARLOS	BELO HORIZONTE	MG	-1	-1

# Método de Indexação

---

- ▶ Suponha que já existe um arquivo de dados, com vários registros
- ▶ Suponha que desejamos criar dois índices para este arquivo
- ▶ Como poderíamos implementar a criação destes índices?
  - ▶ Exige criação dos dois arquivos de índice
  - ▶ Exige adição de duas colunas no arquivo de dados

# Algoritmo de Lefkowitz

---

- ▶ Algoritmo em 6 passos que cria os índices e o arquivo de dados modificado
- ▶ Notação:
  - ▶ ED: Endereço de disco. Numeração dos registros a partir do início do arquivo
  - ▶ CP: Chave primária
  - ▶ CS: Chave secundária
  - ▶ Q: Quantidade de registros que possuem uma determinada chave secundária
  - ▶ PT: Ponteiro para registro que possui uma determinada chave secundária
  - ▶ AT: Atributo não chave
  - ▶ PROX: Ponteiro para o próximo registro que possui uma determinada chave secundária

# Algoritmo de Lefkowitz - Passo 1

---

- ▶ Arquivo de dados original, **ordenado pela chave primária**, é chamado A1
- ▶ Criar um novo arquivo A2
- ▶ Copiar para este arquivo a Chave Primária (CP) e todas as Chaves Secundárias (CSs) para as quais se deseja construir um índice
- ▶ Inserir também uma coluna ED (Endereço de Disco) para cada registro
- ▶ Estrutura Resultante do Arquivo A2



# Exemplo

---

- ▶ Arquivo Original
- ▶ Indexar por Cidade e Estado

## Arquivo de Dados AI

CodCli	Nome	Cidade	Estado
01	MURILO	RIO DE JANEIRO	RJ
03	MARIA	RIO CLARO	SP
05	PEDRO	RIO DE JANEIRO	RJ
07	CAROLINA	SAO PAULO	SP
10	JOAO	RIO DE JANEIRO	RJ
15	CARLOS	BELO HORIZONTE	MG

# Resultado do Passo 1

## Arquivo de Dados A1

CodCli	Nome	Cidade	Estado
01	MURILO	RIO DE JANEIRO	RJ
03	MARIA	RIO CLARO	SP
05	PEDRO	RIO DE JANEIRO	RJ
07	CAROLINA	SAO PAULO	SP
10	JOAO	RIO DE JANEIRO	RJ
15	CARLOS	BELO HORIZONTE	MG

## Arquivo A2

ED	CodCli	Cidade	Estado
1	01	RIO DE JANEIRO	RJ
2	03	RIO CLARO	SP
3	05	RIO DE JANEIRO	RJ
4	07	SAO PAULO	SP
5	10	RIO DE JANEIRO	RJ
6	15	BELO HORIZONTE	MG

## Algoritmo de Lefkowitz - Passo 2

---

- ▶ Decompor o arquivo A2 em vários arquivos A3, um para cada atributo que será indexado
- ▶ Cada arquivo A3 terá a seguinte estrutura:

ED	CP	CS <sub>i</sub>
----	----	-----------------

# Resultado do Passo 2

**Arquivo A2**

ED	CodCli	Cidade	Estado
1	01	RIO DE JANEIRO	RJ
2	03	RIO CLARO	SP
3	05	RIO DE JANEIRO	RJ
4	07	SAO PAULO	SP
5	10	RIO DE JANEIRO	RJ
6	15	BELO HORIZONTE	MG

**Arquivo A3-Estado**

ED	CodCli	Estado
1	01	RJ
2	03	SP
3	05	RJ
4	07	SP
5	10	RJ
6	15	MG

**Arquivo A3-Cidade**

ED	CodCli	Cidade
1	01	RIO DE JANEIRO
2	03	RIO CLARO
3	05	RIO DE JANEIRO
4	07	SAO PAULO
5	10	RIO DE JANEIRO
6	15	BELO HORIZONTE



## Algoritmo de Lefkowitz - Passo 3

---

- ▶ Ordenar os arquivos A3 por chave secundária, gerando arquivos A4

# Resultado do Passo 3

## Arquivo A3-Estado

ED	CodCli	Estado
1	01	RJ
2	03	SP
3	05	RJ
4	07	SP
5	10	RJ
6	15	MG

## Arquivo A3-Cidade

ED	CodCli	Cidade
1	01	RIO DE JANEIRO
2	03	RIO CLARO
3	05	RIO DE JANEIRO
4	07	SAO PAULO
5	10	RIO DE JANEIRO
6	15	BELO HORIZONTE

## Arquivo A4-Estado

ED	CodCli	Estado
6	15	MG
1	01	RJ
3	05	RJ
5	10	RJ
2	03	SP
4	07	SP

## Arquivo A4-Cidade

ED	CodCli	Cidade
6	15	BELO HORIZONTE
2	03	RIO CLARO
1	01	RIO DE JANEIRO
3	05	RIO DE JANEIRO
5	10	RIO DE JANEIRO
4	07	SAO PAULO

# Algoritmo de Lefkowitz - Passo 4

---

- ▶ Cada arquivo A4 é processado para adicionar a quantidade de registros que possuem a Chave Secundária  $CS_i$ , e o endereço do primeiro registro que possui  $CS_i$ , gerando vários arquivos A5 (um para cada arquivo A4)
- ▶ Cada arquivo A4 é processado para adicionar o endereço do próximo registro que contém a Chave Secundária  $CS_i$ , gerando vários arquivos A6 (um para cada arquivo A4)

A5 

$CS_i$	PT	Q
--------	----	---

A6 

ED	CP	$CS_i$	PROX
----	----	--------	------

# Resultado do Passo 4

---

## Arquivo A4-Estado

ED	CodCli	Estado
6	15	MG
1	01	RJ
3	05	RJ
5	10	RJ
2	03	SP
4	07	SP

## Arquivo A5-Estado

Estado	PT	Q
MG	6	1
RJ	1	3
SP	2	2

## Arquivo A6-Estado

ED	CodCli	Estado	PROX
6	15	MG	-1
1	01	RJ	3
3	05	RJ	5
5	10	RJ	-1
2	03	SP	4
4	07	SP	-1



# Resultado do Passo 4

## Arquivo A4-Cidade

ED	CodCli	Cidade
6	15	BELO HORIZONTE
2	03	RIO CLARO
1	01	RIO DE JANEIRO
3	05	RIO DE JANEIRO
5	10	RIO DE JANEIRO
4	07	SAO PAULO

## Arquivo A5-Cidade

Cidade	PT	Q
BELO HORIZONTE	6	1
RIO CLARO	2	1
RIO DE JANEIRO	1	3
SAO PAULO	4	1

## Arquivo A6-Cidade

ED	CodCli	Cidade	PROX
6	15	BELO HORIZONTE	-1
2	03	RIO CLARO	-1
1	01	RIO DE JANEIRO	3
3	05	RIO DE JANEIRO	5
5	10	RIO DE JANEIRO	-1
4	07	SAO PAULO	-1



# Algoritmo de Lefkowitz - Passo 5

---

- ▶ Ordenar os arquivos A6 por chave primária, gerando arquivos A7

# Resultado do Passo 5

---

## Arquivo A6-Estado

ED	CodCli	Estado	PROX
6	15	MG	-1
1	01	RJ	3
3	05	RJ	5
5	10	RJ	-1
2	03	SP	4
4	07	SP	-1

## Arquivo A7-Estado

ED	CodCli	Estado	PROX
1	01	RJ	3
2	03	SP	4
3	05	RJ	5
4	07	SP	-1
5	10	RJ	-1
6	15	MG	-1

# Resultado do Passo 5

---

## Arquivo A6-Cidade

ED	CodCli	Cidade	PROX
6	15	BELO HORIZONTE	-1
2	03	RIO CLARO	-1
1	01	RIO DE JANEIRO	3
3	05	RIO DE JANEIRO	5
5	10	RIO DE JANEIRO	-1
4	07	SAO PAULO	-1

## Arquivo A7-Cidade

ED	CodCli	Cidade	PROX
1	01	RIO DE JANEIRO	3
2	03	RIO CLARO	-1
3	05	RIO DE JANEIRO	5
4	07	SAO PAULO	-1
5	10	RIO DE JANEIRO	-1
6	15	BELO HORIZONTE	-1

## Algoritmo de Lefkowitz – Passo 6

---

- ▶ Juntar o arquivo A1 com todos os arquivos A7, gerando um arquivo A8 (no arquivo A8, a coluna ED não deve estar presente)
- ▶ Os arquivos de índice são os arquivos A5

# Resultado do Passo 6

## Arquivo de Dados A1

CodCli	Nome	Cidade	Estado
01	MURILO	RIO DE JANEIRO	RJ
03	MARIA	RIO CLARO	SP
05	PEDRO	RIO DE JANEIRO	RJ
07	CAROLINA	SAO PAULO	SP
10	JOAO	RIO DE JANEIRO	RJ
15	CARLOS	BELO HORIZONTE	MG

## Arquivo A8

CodCli	Nome	Cidade	Estado	PROXEstado	PROXCidade
01	MURILO	RIO DE JANEIRO	RJ	3	3
03	MARIA	RIO CLARO	SP	4	-1
05	PEDRO	RIO DE JANEIRO	RJ	5	5
07	CAROLINA	SAO PAULO	SP	-1	-1
10	JOAO	RIO DE JANEIRO	RJ	-1	-1
15	CARLOS	BELO HORIZONTE	MG	-1	-1

## Arquivo A7-Estado

ED	CodCli	Estado	PROX
1	01	RJ	3
2	03	SP	4
3	05	RJ	5
4	07	SP	-1
5	10	RJ	-1
6	15	MG	-1

## Arquivo A7-Cidade

ED	CodCli	Cidade	PROX
1	01	RIO DE JANEIRO	3
2	03	RIO CLARO	-1
3	05	RIO DE JANEIRO	5
4	07	SAO PAULO	-1
5	10	RIO DE JANEIRO	-1
6	15	BELO HORIZONTE	-1

# Resultado Final

---

## Arquivo A8 – Arquivo de Dados

CodCli	Nome	Cidade	Estado	PROXEstado	PROXCidade
01	MURILO	RIO DE JANEIRO	RJ	3	3
03	MARIA	RIO CLARO	SP	4	-1
05	PEDRO	RIO DE JANEIRO	RJ	5	5
07	CAROLINA	SAO PAULO	SP	-1	-1
10	JOAO	RIO DE JANEIRO	RJ	-1	-1
15	CARLOS	BELO HORIZONTE	MG	-1	-1

## Arquivo A5-Estado

Estado	PT	Q
MG	6	1
RJ	1	3
SP	2	2

## Arquivo A5-Cidade

Cidade	PT	Q
BELO HORIZONTE	6	1
RIO CLARO	2	1
RIO DE JANEIRO	1	3
SAO PAULO	4	1

# Curiosidade

---

- ▶ Arquivos invertidos são muito utilizados em máquinas de busca (ex. Google) para saber quais documentos contêm uma determinada palavra

# Exemplo de Documentos a serem indexados

---

Doc1	A casa amarela é bonita
Doc2	O carro amarelo está amassado
Doc3	Os carros são velozes
Doc4	A febre amarela é uma doença



# Passo 1

---

- ▶ Palavras que não possuem significado (artigos, preposições) são eliminadas (**remoção de stop words**)
- ▶ Isso ajuda a diminuir o tamanho do índice

Doc1	casa amarela é bonita
Doc2	carro amarelo está amassado
Doc3	carros são velozes
Doc4	febre amarela é doença

## Passo 2

---

- ▶ As palavras precisam passar por um processo de radicalização, para garantir que variações da mesma palavra sejam indexadas juntas
- ▶ Cada palavra é reduzida ao seu radical
- ▶ Se não fizermos isso, ao procurar pela palavra “carro”, o usuário não encontraria o Doc3

Doc1	casa amarela é bonita
Doc2	carro amarelo está amassado
Doc3	carros são velozes
Doc4	febre amarela é doença

# Depois da radicalização (exemplo simplificado)

---

Doc1	casa amarel ser bonit
Doc2	carro amarel estar amassad
Doc3	carro ser veloz
Doc4	febre amarel ser doença

# Passo 3

## ► Construir o arquivo invertido

Doc1	casa amarel ser bonit
Doc2	carro amarel estar amassad
Doc3	carro ser veloz
Doc4	febre amarel ser doença

amarel	3	(Doc1) (Doc2) (Doc 4)
amassad	1	(Doc 2)
bonit	1	(Doc1)
casa	1	(Doc1)
carro	2	(Doc2) (Doc3)
doença	1	(Doc4)
estar	1	(Doc2)
febre	1	(Doc4)
ser	3	(Doc1) (Doc3) (Doc4)
veloz	1	(Doc3)

# Consultas

---

- ▶ As consultas passam pelo mesmo processo de eliminação de stop words e radicalização
- ▶ Depois, basta ir direto ao índice
  
- ▶ Consultas com AND: intersecção das listas de resultado
- ▶ Consultas com OR: união das listas de resultado

# Exemplo

- ▶ Consulta: “carros AND amarelos”
- ▶ Resultado: Doc2

amarel	3	(Doc1) (Doc2) (Doc 4)
amassad	1	(Doc 2)
bonit	1	(Doc1)
casa	1	(Doc1)
carro	2	(Doc2) (Doc3)
doença	1	(Doc4)
estar	1	(Doc2)
febre	1	(Doc4)
ser	3	(Doc1) (Doc3) (Doc4)
veloz	1	(Doc3)

Doc1	casa amarel ser bonit
Doc2	carro amarel estar amassad
Doc3	carro ser veloz
Doc4	febre amarel ser doença

# Exercício

---

- ▶ Aplicar o algoritmo de Lefkowitz para indexar o arquivo abaixo por País

CodCli	Nome	País
01	MURILO	BRASIL
03	MARIA	EUA
05	PEDRO	MÉXICO
07	CAROLINA	BRASIL
10	JOAO	BRASIL
15	CARLOS	EUA
21	VANESSA	BRASIL
35	LEO	MÉXICO
42	BRUNA	CANADÁ

# Implementar o Algoritmo de Lefkowitz

---

- ▶ Entrada: arquivo binário com a seguinte estrutura (COD, NOME, IDADE), onde COD é a chave primária, e IDADE é o atributo que será indexado
- ▶ Saída: arquivo de índice