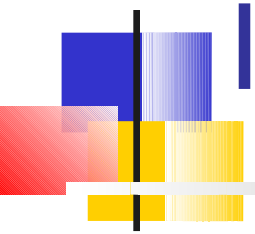

Índices

SCC-503 Algoritmos e Estruturas de Dados II

Thiago A. S. Pardo

Leandro C. Cintra

M.C.F. de Oliveira

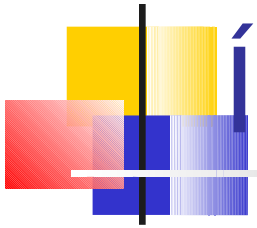

Índice

- Em geral, um índice fornece mecanismos para localizar informações
  - Índice de um livro ou catálogo de uma biblioteca
    - Facilitam muito o trabalho de busca!

- Em arquivos
  - Permite localizar registros rapidamente
  - Não é necessário ordenar arquivo de dados, nem quando novos registros são adicionados

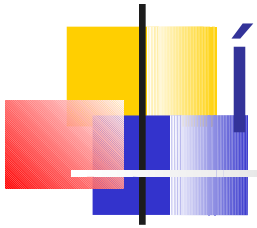

Índice simples

- Exemplo: uma enorme coleção de CDs
- Registros de tamanho variável
  - **ID Number:** Número de identificação
  - **Title**: Título
  - **Composer**: Compositor(es)
  - **Artist**: Artista(s)
  - **Label**: Rótulo (código da gravadora)
- Chave primária: combinação de Label e ID Number
  - Poderia ser qualquer outro campo ou combinação de campos que fosse única para cada registro

Arquivo de Dados: Exemplo

Rec. addr.	Label	ID number	Title	Composer(s)	Artist(s)
32†	LON	2312	Romeo and Juliet	Prokofiev	Maazel
77	RCA	2626	Quartet in C Sharp Minor	Beethoven	Julliard
132	WAR	23699	Touchstone	Corea	Corea
167	ANG	3795	Symphony No. 9	Beethoven	Giulini
211	COL	38358	Nebraska	Springsteen	Springsteen
256	DG	18807	Symphony No. 9	Beethoven	Karajan
300	MER	75016	Coq d'or Suite	Rimsky-Korsakov	Leinsdorf
353	COL	31809	Symphony No. 9	Dvorak	Bernstein
396	DG	139201	Violin Concerto	Beethoven	Ferras
442	FF	245	Good News	Sweet Honey in the Rock	Sweet Honey in the Rock

†Assume there is a header record that uses the first 32 bytes.

Índice Simples

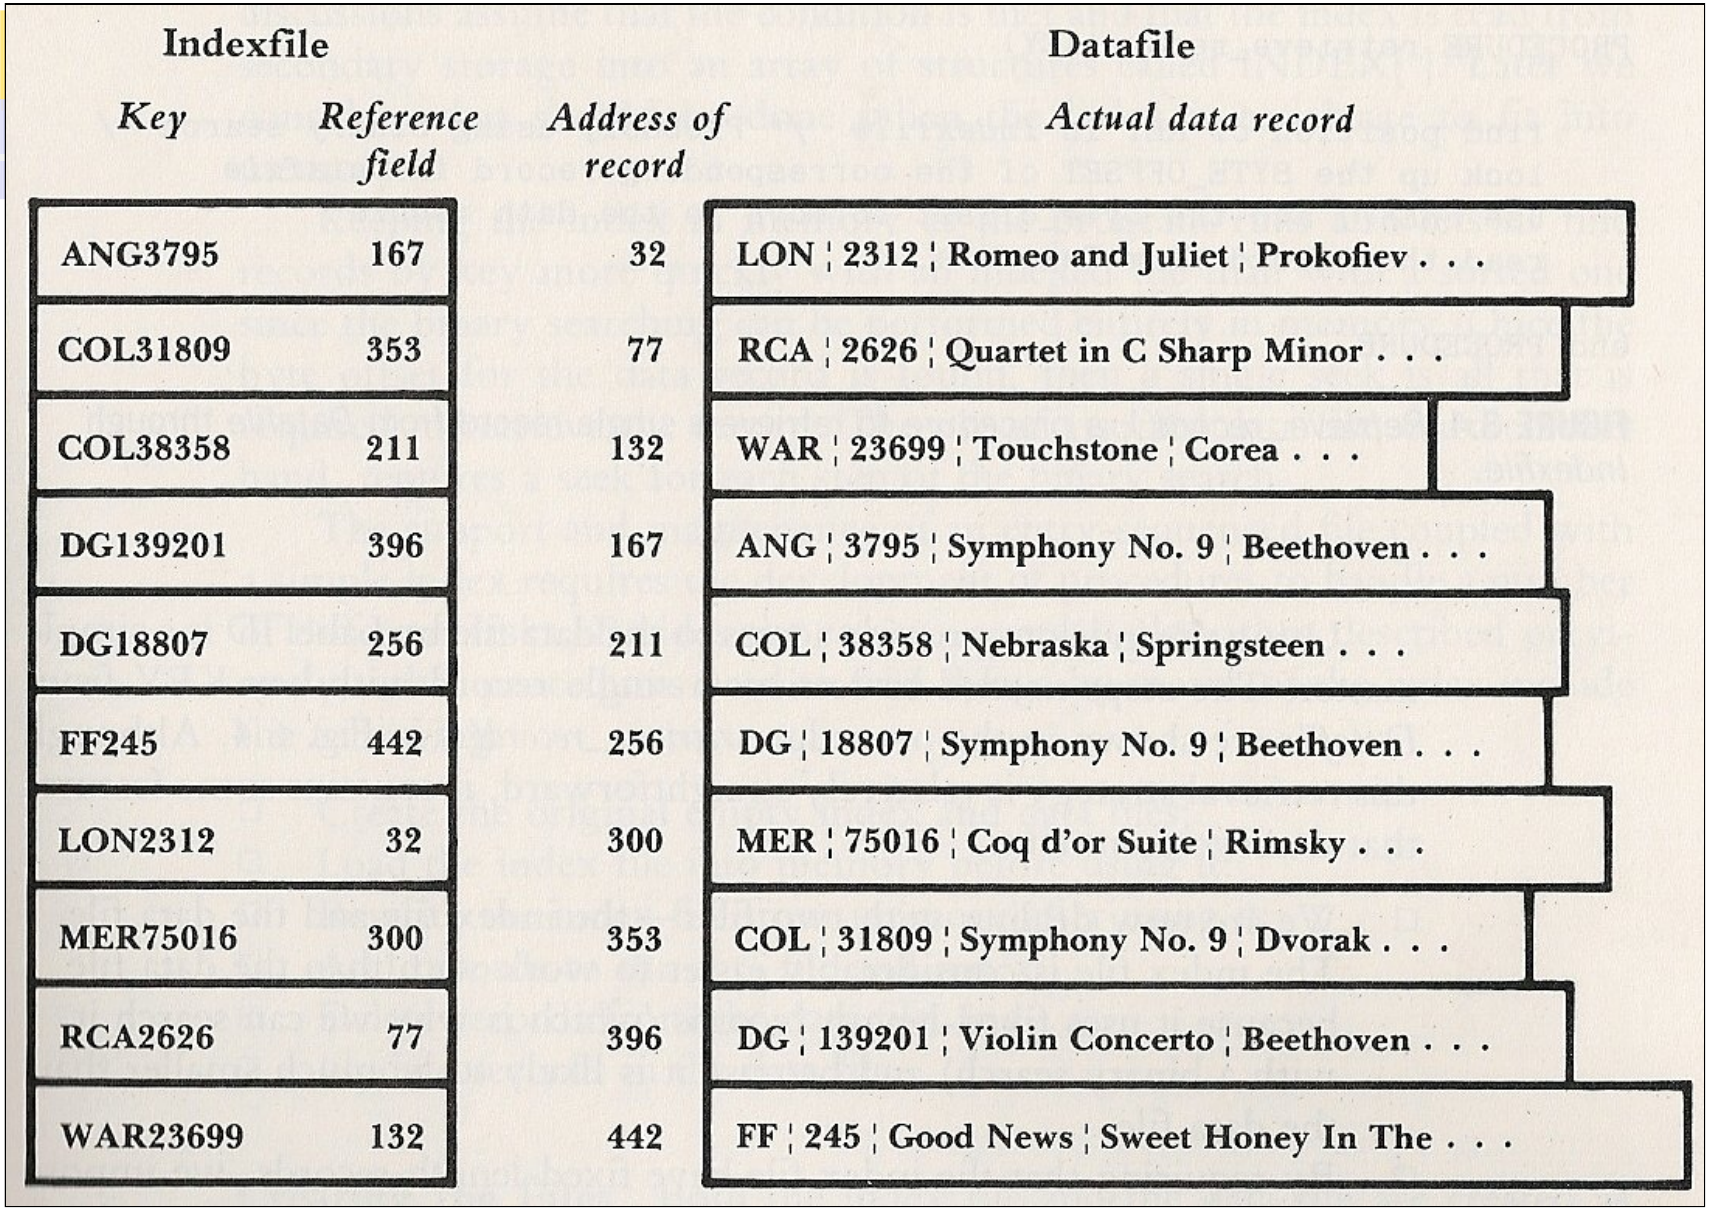

Indexfile		Address of record	Datafile
Key	*Reference field*		*Actual data record*
ANG3795	167	32	LON ¦ 2312 ¦ Romeo and Juliet ¦ Prokofiev . . .
COL31809	353	77	RCA ¦ 2626 ¦ Quartet in C Sharp Minor . . .
COL38358	211	132	WAR ¦ 23699 ¦ Touchstone ¦ Corea . . .
DG139201	396	167	ANG ¦ 3795 ¦ Symphony No. 9 ¦ Beethoven . . .
DG18807	256	211	COL ¦ 38358 ¦ Nebraska ¦ Springsteen . . .
FF245	442	256	DG ¦ 18807 ¦ Symphony No. 9 ¦ Beethoven . . .
LON2312	32	300	MER ¦ 75016 ¦ Coq d'or Suite ¦ Rimsky . . .
MER75016	300	353	COL ¦ 31809 ¦ Symphony No. 9 ¦ Dvorak . . .
RCA2626	77	396	DG ¦ 139201 ¦ Violin Concerto ¦ Beethoven . . .
WAR23699	132	442	FF ¦ 245 ¦ Good News ¦ Sweet Honey In The . . .

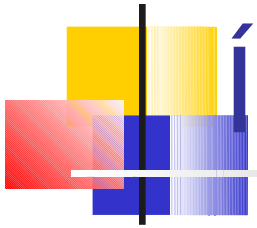

Índice simples

- O índice consiste, em geral, em um outro arquivo com registros de tamanho fixo
  - Mesmo que o arquivo principal com os dados não tenha registros de tamanho fixo
- Cada registro do índice contém pelo menos 2 campos de tamanho fixo
  - Chave
  - Posição inicial (*byte offset*) ou RRN do registro no arquivo de dados

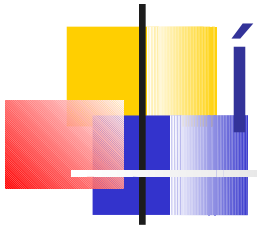

Índice simples

- A cada registro do arquivo de dados corresponde um registro no índice
- O índice está ordenado, apesar do arquivo de dados não estar
  - Em geral, o arquivo de dados está organizado segundo a ordem de entrada dos registros

Índice simples

- Vantagens do arquivo de índice sobre o de dados
  - Mais fácil de trabalhar, pois usa registros de tamanho fixo
  - Pode ser pesquisado com busca binária (em memória principal, inclusive, se valer a pena carregá-lo)
  - É muito menor do que o arquivo de dados
- Registros de tamanho fixo no arquivo de índice impõem um limite ao tamanho da chave primária
  - O que acontece se a chave primária extrapolar o limite imposto?
- Os registros do índice poderiam conter outros campos além da chave/*offset* (por exemplo, o tamanho do registro a que se referem)

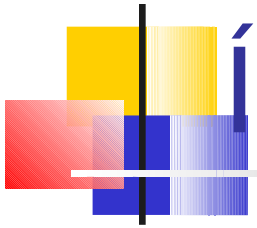

Índice simples

- Como são feitas as operações básicas?
  - Inserção de registros
  - Remoção de registros
  - Atualização de registros
  - Busca de registros

Operações básicas no índice

- Para índices que cabem em memória
  - Criar arquivos de índice e de dados
  - Carregar índice para memória
  - Inserir registro
    - Inserção deve ser feita no arquivo de dados...
    - e também no índice, que eventualmente será reorganizado
  - Eliminar registro
    - Remove do arquivo de dados (pode fazer compactação?)
    - Remove também do índice
      - Índice pode ser reorganizado ou se pode apenas marcar os registros excluídos

Operações básicas no índice

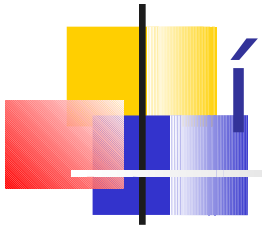

- Para índices que cabem em memória
  - Atualizar registro - duas categorias
    - Muda o valor da chave
      - Índice deve ser atualizado
    - Muda o conteúdo do registro
      - Pode ou não alterar o tamanho do registro, podendo exigir realocação do registro
  - Atualizar índice no disco: caso sua cópia em memória tenha sido alterada
    - É imperativo que o programa se proteja contra índices desatualizados
      - Possíveis estratégias?

Como evitar índices desatualizados

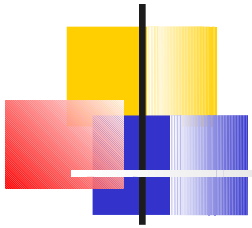

- Deve haver um mecanismo que permita saber se o índice está atualizado em relação ao arquivo de dados
  - Possibilidade: um *status flag* é setado no arquivo de índice mantido em disco assim que a sua cópia na memória é alterada
  - Esse *flag* pode ser mantido no registro *header* do arquivo índice, e atualizado sempre que o índice é reescrito no disco
    - Se um programa detecta que o índice está desatualizado, uma função deve ser ativada para reconstruir o índice a partir do arquivo de dados

Exercício em duplas

- Implementar em C uma sub-rotina que construa um índice a partir de um arquivo de dados de alunos e que, depois, percorra esse índice para encontrar um aluno (pelo número)

```
struct aluno {
    char nome[50];
    int nro_USP;
}
```

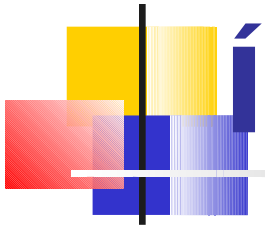

Índices muito grandes

- Se o índice não cabe inteiro na memória, o acesso e manutenção precisam ser feitos em memória secundária

- Não é mais aconselhável usar índices simples, uma vez que
  - A busca binária no índice pode exigir vários acessos a disco
  - A necessidade de deslocar registros nas inserções e remoções de registros tornaria a manutenção do índice excessivamente cara

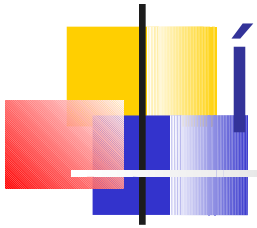

Índices muito grandes

- Utilizam-se <u>outras organizações</u>
  - *Hashing*, caso a velocidade de acesso seja a maior prioridade
    - Acesso direto apenas
  - Árvores-B, caso se deseje combinar acesso por chaves e acesso seqüencial eficientemente

Acesso por múltiplas chaves

- Como saber qual é a chave primária do registro que se quer acessar?

Acesso por múltiplas chaves

- Como saber qual é a chave primária do registro que se quer acessar?
- Normalmente, o acesso a registros não se faz por chave primária, e sim por chaves secundárias
  - Quando se procura por um livro em uma biblioteca, começa-se pelo seu número ou pelo título/autor?
- Solução: cria-se um índice que relaciona uma chave secundária à chave primária (e não diretamente ao registro)
  - Índice secundário

Acesso por múltiplas chaves

- Índices permitem muito mais do que simplesmente melhorar o tempo de busca por um registro

- Múltiplos índices secundários
  - Permitem manter diferentes visões dos registros em um arquivo de dados
  - Permitem combinar chaves associadas e, deste modo, fazer buscas que combinam visões particulares

Acesso por múltiplas chaves

Composer index

Secondary key	*Primary key*
BEETHOVEN	ANG3795
BEETHOVEN	DG139201
BEETHOVEN	DG18807
BEETHOVEN	RCA2626
COREA	WAR23699
DVORAK	COL31809
PROKOFIEV	LON2312
RIMSKY-KORSAKOV	MER75016
SPRINGSTEEN	COL38358
SWEET HONEY IN THE R	FF245

Title index

Secondary key	*Primary key*
COQ D'OR SUITE	MER75016
GOOD NEWS	FF245
NEBRASKA	COL38358
QUARTET IN C SHARP M	RCA2626
ROMEO AND JULIET	LON2312
SYMPHONY NO. 9	ANG3795
SYMPHONY NO. 9	COL31809
SYMPHONY NO. 9	DG18807
TOUCHSTONE	WAR23699
VIOLIN CONCERTO	DG139201

Alterações nas operações básicas

- **Inserir registro**
  - Quando um novo registro é inserido no arquivo, devem ser inseridas as entradas correspondentes no índice primário e nos índices secundários
  - Campo chave deve ser armazenado em sua forma canônica no índice secundário
    - O valor pode ser truncado, porque o tamanho da chave deve ser mantido fixo
  - Diferença importante entre os índices primário e os secundários: nesses últimos pode ocorrer duplicação de chaves
    - Chaves duplicadas devem ser mantidas agrupadas e ordenadas

Alterações nas operações básicas

- **Eliminar registro**
  - Implica em remover o registro do arquivo de dados e de todos os índices
  - Se índices mantidos ordenados, rearranjo dos registros remanescentes para não deixar espaços vagos
    - **Alternativa:** atualizar apenas o índice primário, sem eliminar a entrada correspondente ao registro no índice secundário

Alterações nas operações básicas

- **Vantagem:** economia de tempo substancial quando vários índices secundários estão associados ao arquivo, principalmente se esses índices são mantidos em disco

- **Custo:** espaço ocupado por registros inválidos
  - Pode-se fazer "coletas de lixo" periódicas nos índices secundários
  - Ainda será um problema se o arquivo é muito volátil
    - Outra solução: árvore-B

Alterações nas operações básicas

- **Atualizar registro -** 3 situações
  - Alterou uma chave secundária: o índice secundário para esta chave precisa ser reordenado
  - Alterou a chave primária: reordenar o índice primário e corrigir os campos de referência dos índices secundários
    - Vantagem: atualização dos índices secundários não requer reorganização
  - Alterou outros campos: não afeta nenhum dos índices
    - E se o tamanho do registro mudar?

Busca usando múltiplas chaves

- Uma das aplicações mais importantes das chaves secundárias é localizar conjuntos de registros do arquivo de dados usando uma ou mais chaves
- Pode-se fazer uma busca em vários índices e combinar (AND,OR,NOT) os resultados
- Exemplo: encontre todos os registros de dados tal que
  - composer = "BEETHOVEN" AND title = "SYMPHONY NO. 9"

Busca usando múltiplas chaves

Composer index

Secondary key	*Primary key*
BEETHOVEN	ANG3795
BEETHOVEN	DG139201
BEETHOVEN	DG18807
BEETHOVEN	RCA2626
COREA	WAR23699
DVORAK	COL31809
PROKOFIEV	LON2312
RIMSKY-KORSAKOV	MER75016
SPRINGSTEEN	COL38358
SWEET HONEY IN THE R	FF245

Title index

Secondary key	*Primary key*
COQ D'OR SUITE	MER75016
GOOD NEWS	FF245
NEBRASKA	COL38358
QUARTET IN C SHARP M	RCA2626
ROMEO AND JULIET	LON2312
SYMPHONY NO. 9	ANG3795
SYMPHONY NO. 9	COL31809
SYMPHONY NO. 9	DG18807
TOUCHSTONE	WAR23699
VIOLIN CONCERTO	DG139201

Busca usando múltiplas chaves

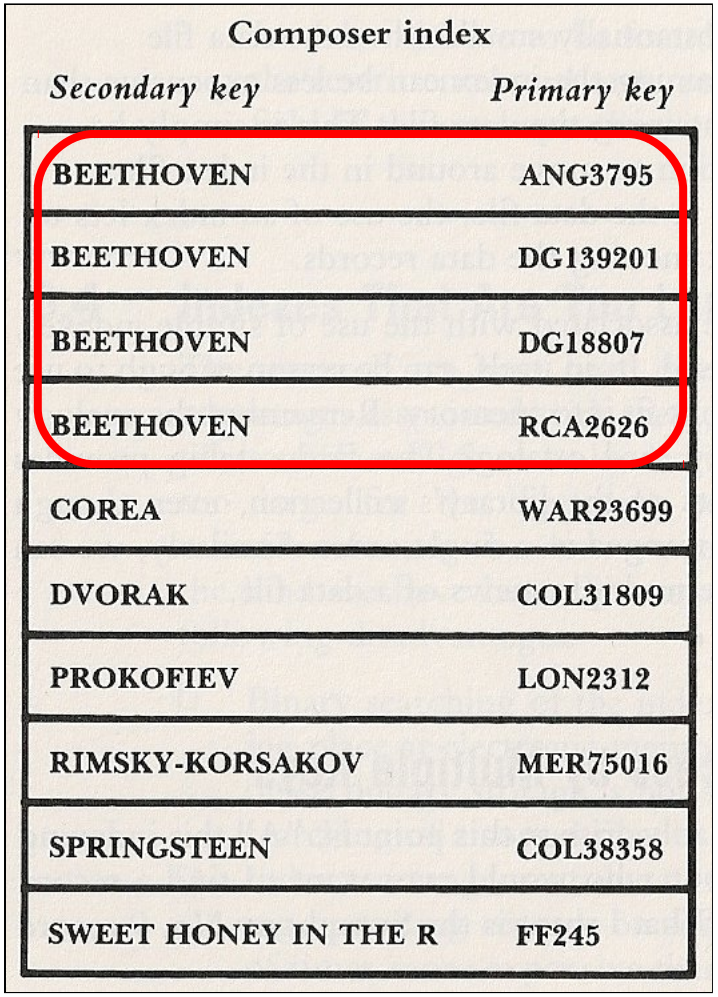

Composer index

Secondary key	*Primary key*
BEETHOVEN	ANG3795
BEETHOVEN	DG139201
BEETHOVEN	DG18807
BEETHOVEN	RCA2626
COREA	WAR23699
DVORAK	COL31809
PROKOFIEV	LON2312
RIMSKY-KORSAKOV	MER75016
SPRINGSTEEN	COL38358
SWEET HONEY IN THE R	FF245

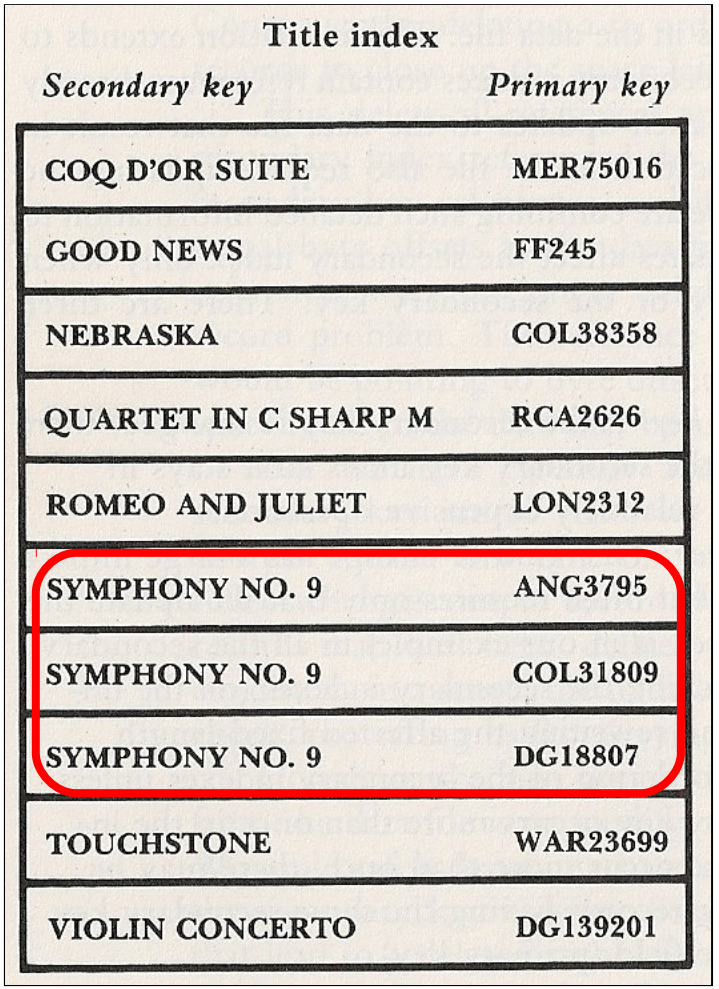

Title index

Secondary key	*Primary key*
COQ D'OR SUITE	MER75016
GOOD NEWS	FF245
NEBRASKA	COL38358
QUARTET IN C SHARP M	RCA2626
ROMEO AND JULIET	LON2312
SYMPHONY NO. 9	ANG3795
SYMPHONY NO. 9	COL31809
SYMPHONY NO. 9	DG18807
TOUCHSTONE	WAR23699
VIOLIN CONCERTO	DG139201

Busca usando múltiplas chaves

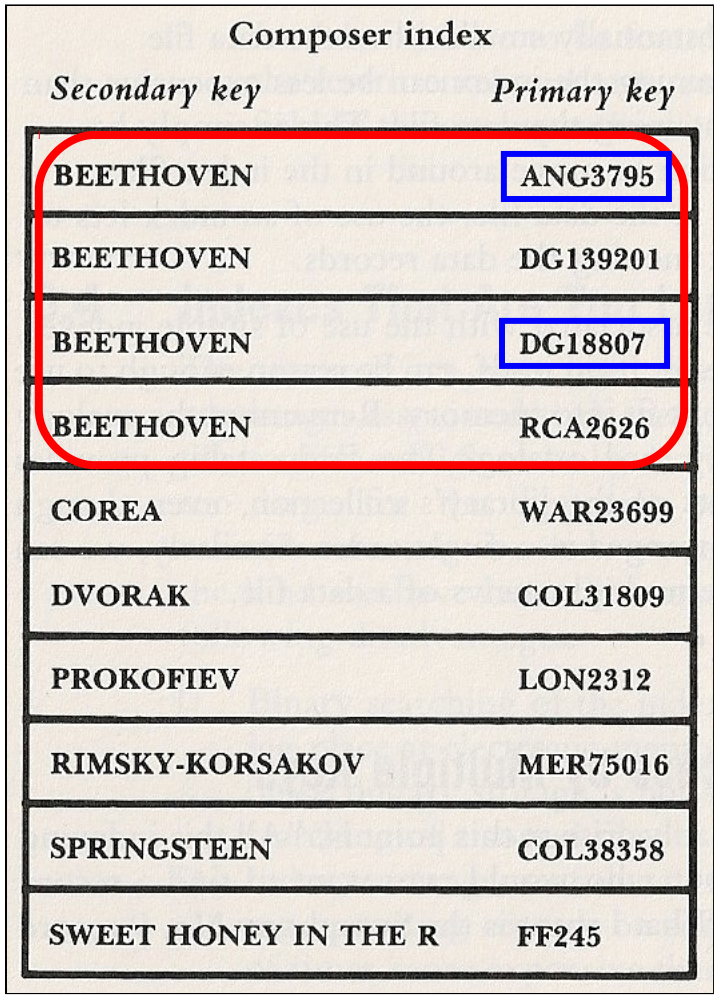

Composer index

Secondary key	*Primary key*
BEETHOVEN	ANG3795
BEETHOVEN	DG139201
BEETHOVEN	DG18807
BEETHOVEN	RCA2626
COREA	WAR23699
DVORAK	COL31809
PROKOFIEV	LON2312
RIMSKY-KORSAKOV	MER75016
SPRINGSTEEN	COL38358
SWEET HONEY IN THE R	FF245

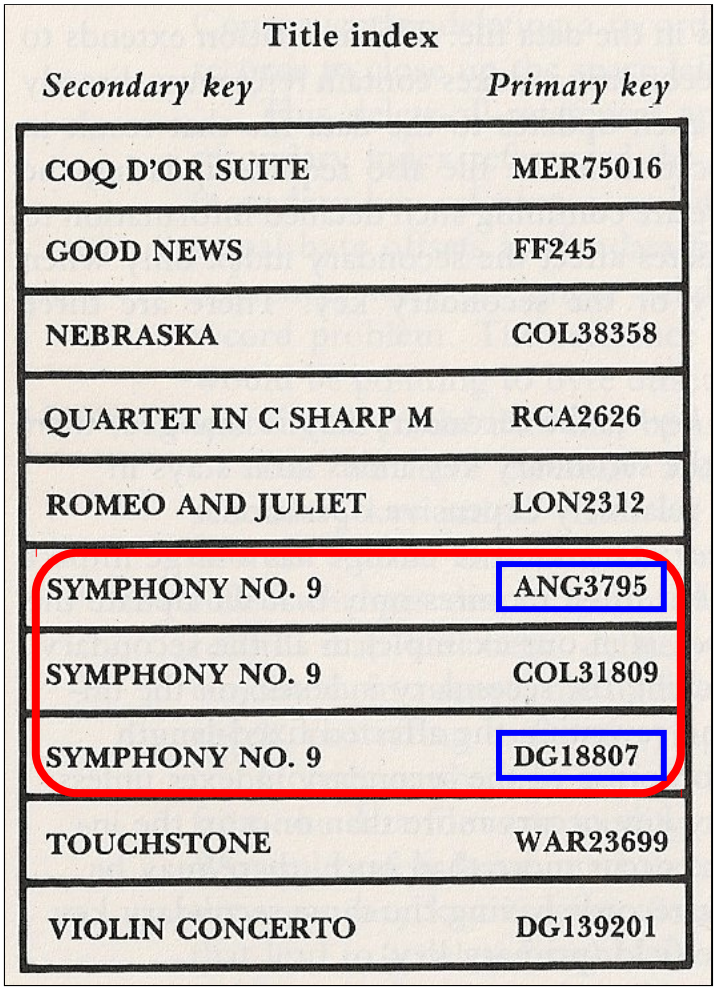

Title index

Secondary key	*Primary key*
COQ D'OR SUITE	MER75016
GOOD NEWS	FF245
NEBRASKA	COL38358
QUARTET IN C SHARP M	RCA2626
ROMEO AND JULIET	LON2312
SYMPHONY NO. 9	ANG3795
SYMPHONY NO. 9	COL31809
SYMPHONY NO. 9	DG18807
TOUCHSTONE	WAR23699
VIOLIN CONCERTO	DG139201

Busca usando múltiplas chaves

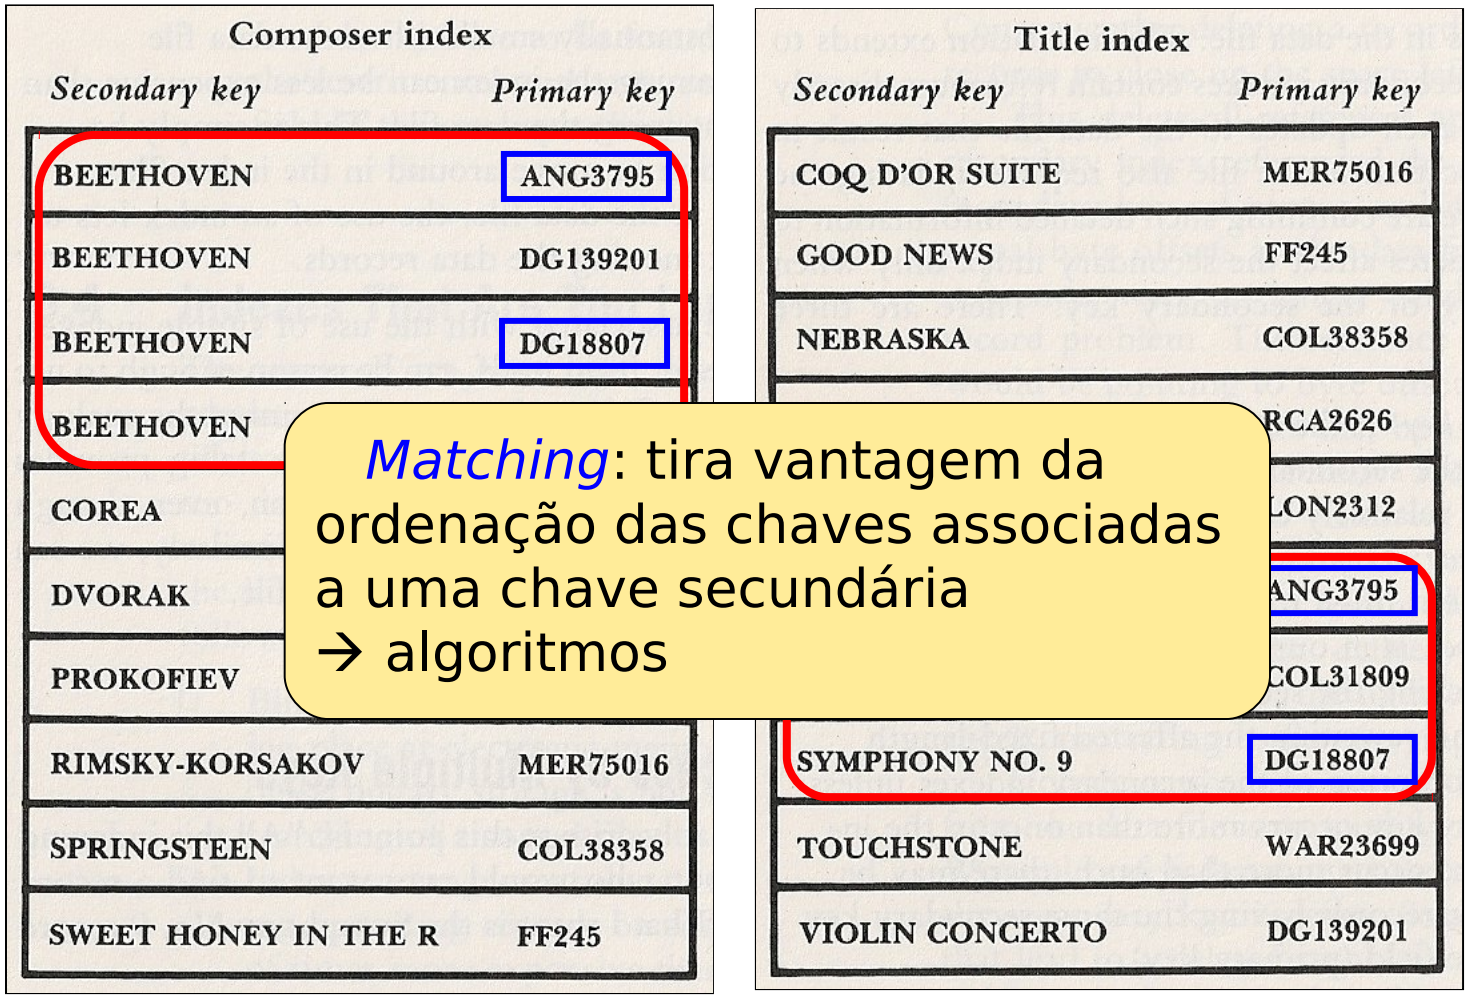

Composer index

Secondary key	*Primary key*
BEETHOVEN	ANG3795
BEETHOVEN	DG139201
BEETHOVEN	DG18807
BEETHOVEN	
COREA	
DVORAK	
PROKOFIEV	
RIMSKY-KORSAKOV	MER75016
SPRINGSTEEN	COL38358
SWEET HONEY IN THE R	FF245

Title index

Secondary key	*Primary key*
COQ D'OR SUITE	MER75016
GOOD NEWS	FF245
NEBRASKA	COL38358
	RCA2626
	LON2312
	ANG3795
	COL31809
SYMPHONY NO. 9	DG18807
TOUCHSTONE	WAR23699
VIOLIN CONCERTO	DG139201

Matching: tira vantagem da ordenação das chaves associadas a uma chave secundária
→ algoritmos

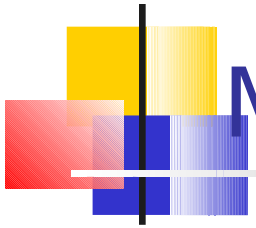

Melhoria de índices secundários

- Dois problemas nas estruturas de índices vistas até agora
  - Repetição das chaves secundárias
  - Necessidade de reordenar os índices sempre que um novo registro é inserido no arquivo, mesmo que esse registro tenha um valor de chave secundária já existente no arquivo

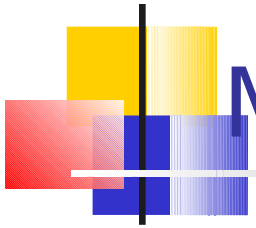

Melhoria de índices secundários

- **Solução 1:** associar um vetor de tamanho fixo a cada chave secundária
  - Não é necessário reordenar o índice a cada inserção de registro
  - Limitado a um número fixo de repetições
  - Ocorre fragmentação interna enorme no índice - que talvez não compense a eliminação da duplicação de chaves

Solução 1

Revised composer index

Secondary key	*Set of primary key references*			
BEETHOVEN	ANG3795	DG139201	DG18807	RCA2626
COREA	WAR23699			
DVORAK	COL31809			
PROKOFIEV	LON2312			
RIMSKY-KORSAKOV	MER75016			
SPRINGSTEEN	COL38358			
SWEET HONEY IN THE R	FF245			

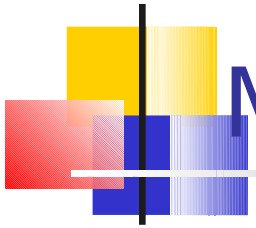

Melhoria de índices secundários

- **Solução 2:** manter uma lista de referências - listas invertidas
  - Pode-se associar cada chave secundária a uma lista encadeada das chaves primárias referenciadas
    - Índice secundário passa a ser composto por registros com 2 campos: campo chave e campo com o RRN/byte offset do primeiro registro com essa chave na lista invertida
  - Referências às chaves primárias associadas a cada chave secundária são mantidas em um arquivo seqüencial separado, organizado segundo a entrada dos registros

Listas invertidas: visão conceitual

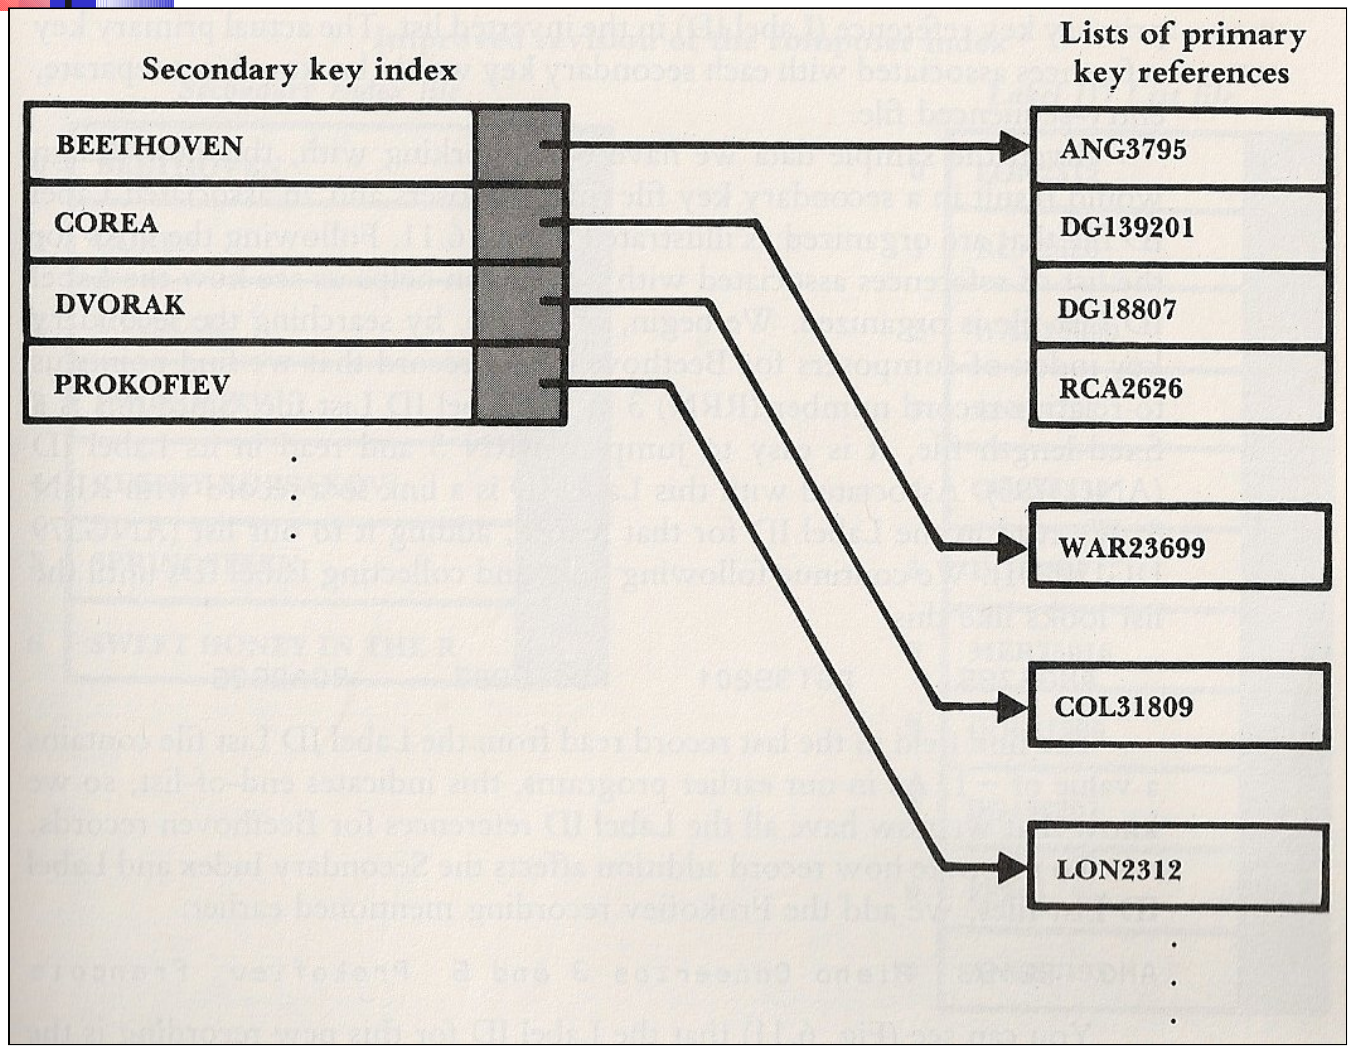

Por que se chama lista invertida?

Listas invertidas

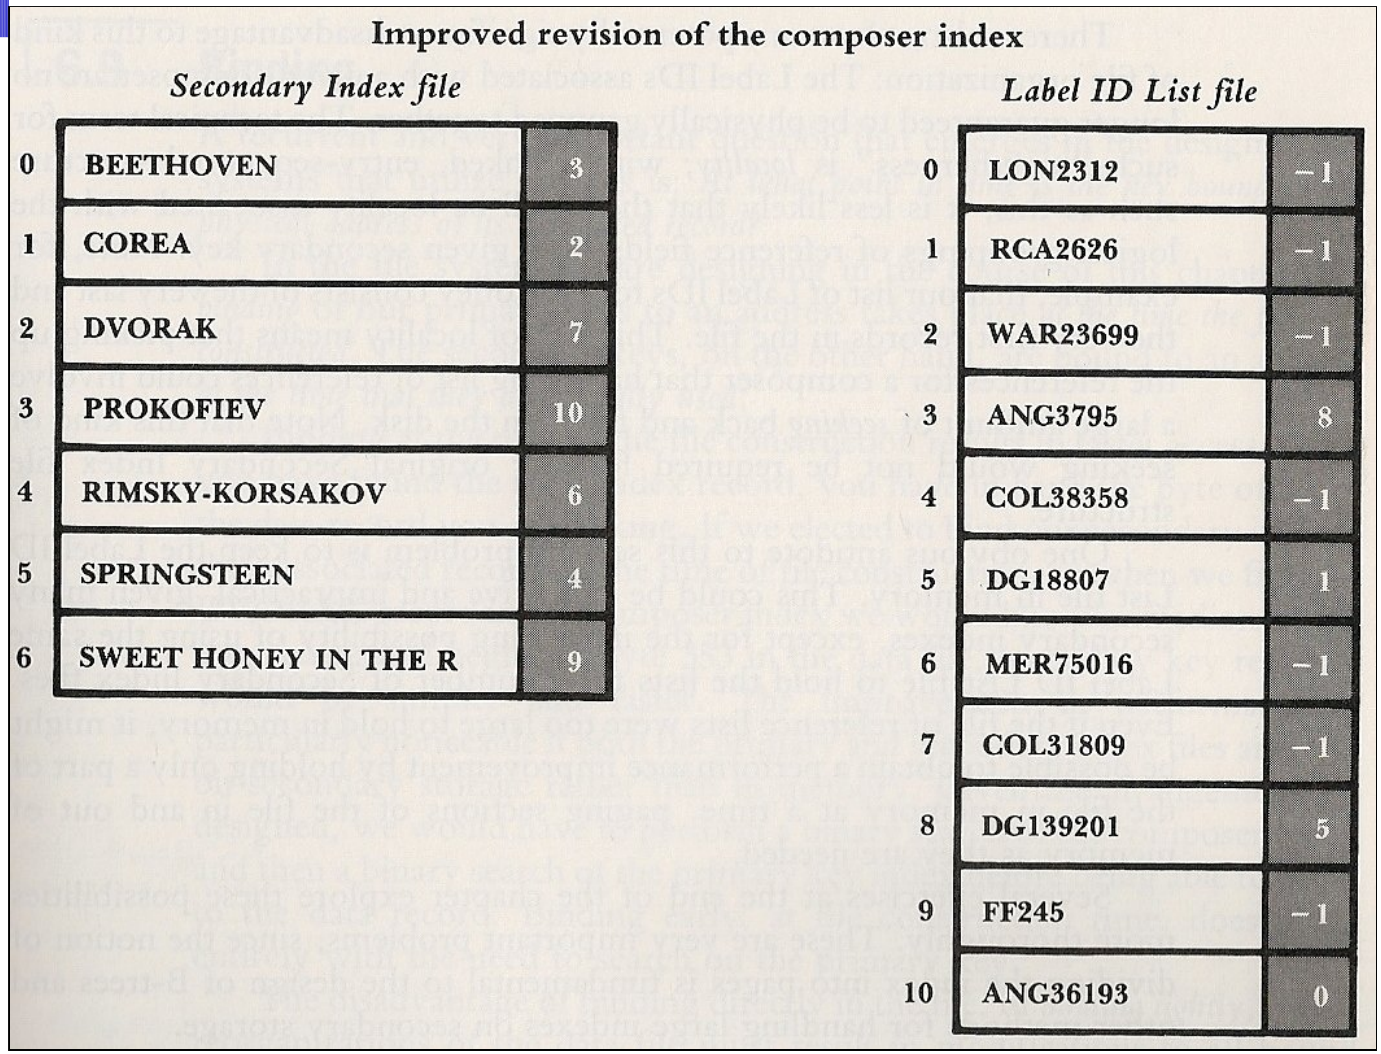

Improved revision of the composer index

Secondary Index file

0	BEETHOVEN	3
1	COREA	2
2	DVORAK	7
3	PROKOFIEV	10
4	RIMSKY-KORSAKOV	6
5	SPRINGSTEEN	4
6	SWEET HONEY IN THE R	9

Label ID List file

0	LON2312	−1
1	RCA2626	−1
2	WAR23699	−1
3	ANG3795	8
4	COL38358	−1
5	DG18807	1
6	MER75016	−1
7	COL31809	−1
8	DG139201	5
9	FF245	−1
10	ANG36193	0

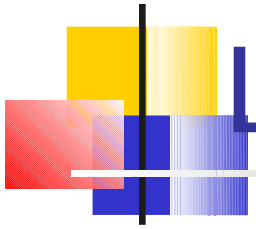

Listas invertidas

- Vantagens desta estratégia?

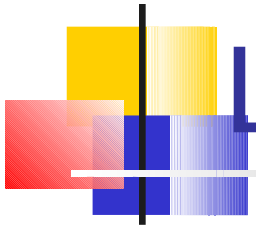

Listas invertidas

- **Vantagens**
  - Índice secundário só é alterado quando é inserido um registro com chave inexistente, ou quando é alterada uma chave já existente
    - Eliminação, inserção ou alteração de registros já existentes implicam apenas em alterar lista invertida
    - Ordenação do arquivo de índice secundário é mais rápida: menos registros - e registros menores
  - Arquivo com listas de chaves nunca precisa ser ordenado, pois a ordem de entrada é mantida
  - É fácil reutilizar o espaço liberado pelos registros eliminados do arquivo de listas

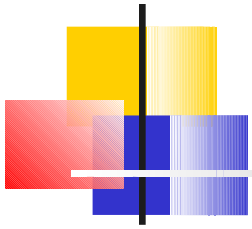

Listas invertidas

- Problemas desta estratégia?

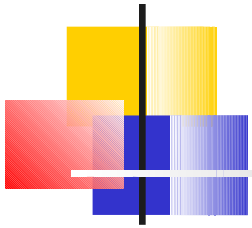

Listas invertidas

- **Problemas**
  - Registros associados não estão adjacentes no disco: podem ser necessários vários *seeks* para recuperar a lista
    - O ideal seria manter o índice e a lista na memória

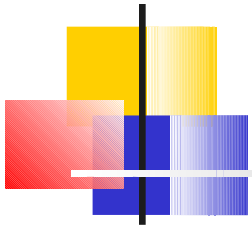

Índices seletivos

- O índice não precisa cobrir todo o arquivo de dados
  - Índice de músicas clássicas
  - Índice de músicas lançadas depois de 1980

- Dependente da aplicação e uso dos dados

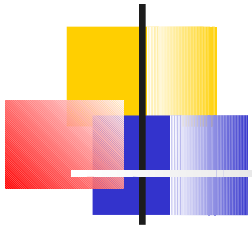

Binding

- Nos índices primários vistos, a associação (*binding*) entre a chave primária e o endereço físico do registro a que ela se refere ocorre no momento em que o registro é criado

- Índice simples fornece acesso direto e, portanto, mais rápido, a um registro, dada a sua chave

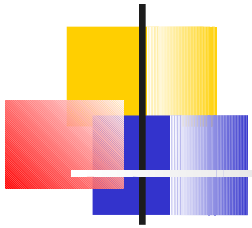

Binding

- As chaves secundárias são associadas a um endereço apenas no momento em que são de fato usadas (*late binding*)
  - Isso implica em um acesso mais lento
- O *late binding* traz vantagens: manutenção mais flexível, mais eficiente e confiável
- Ressalta-se: é sempre desejável manter as modificações localizadas, o que é possível com o *late binding*
  - O *early binding* só é aconselhável se o arquivo de dados é (quase) estático, e o acesso rápido a registros é a maior prioridade
    - Caso contrário, o que acontece?

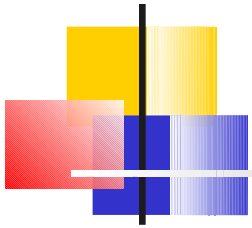

Binding

- As chaves secundárias são associadas a um endereço apenas no momento em que são de fato usadas (*late binding*)
  - Isso implica em um acesso mais lento
- O *late binding* traz vantagens: manutenção mais flexível, mais eficiente e confiável
- Ressalta-se: é sempre desejável manter as modificações localizadas, o que é possível com o *late binding*
  - O *early binding* só é aconselhável se o arquivo de dados é (quase) estático, e o acesso rápido a registros é a maior prioridade
    - Caso contrário, o que acontece?
      - Muita atualização de índice secundário

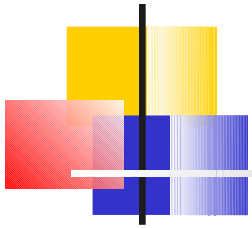

Estudo de caso

- *Como ferramentas de busca na Internet funcionam?*
  - *Criação e atualização de índices de palavras-chave e onde encontrá-las*
  - *Definição de uma ordenação de páginas baseada na "importância" ou "relevância"*
- *"Como o Google funciona"*
  - *http://www.google.com/howgoogleworks/*