

# Tópicos em Recuperação de Informação<sup>1</sup>

Nivio Ziviani

---

<sup>1</sup>Conjunto de transparências elaborado por Nivio Ziviani, Patrícia Correia e Fabiano C. Botelho

---

## Como Armazenar e Acessar o Vocabulário

---

O vocabulário de um arquivo invertido armazena os termos que serão usados para buscar na coleção e informações auxiliares para permitir que consultas sejam processadas.

Método	Armazenamento
Fixed Length Strings	28 Mbytes
Terminated Strings	20 Mbytes
Four-entry blocking	18 Mbytes
Front coding	15,5 Mbytes
Hashing perfeito	13 Mbytes

---

Para um vocabulário de 1.000.000 de termos

---

## Estruturas

---

### *Fixed Length Strings*

- Para um vocabulário de 1.000.000 de palavras:
  - 20 bytes: palavra (assumindo que palavras ocupam no máximo 20 bytes).
  - 4 bytes: endereço do arquivo invertido.
  - 4 bytes:  $f_t$  (número de docs que contêm o termo  $t$ ).
  - Vocabulário requer 28 Megabytes.
- Esta alternativa é cara. Uma redução pode ser conseguida se todas as palavras forem concatenadas como uma palavra longa.

## Estruturas

---

### *Fixed Length Strings*

Termo $t$	$f_t$	Endereço em disco
jezebel	20	→
jezer	3	→
jezerit	1	→
jeziah	1	→
jeziel	1	→
jezliah	1	→
jezoar	1	→
jezrahiah	1	→
jezreel	39	→

---

## Estruturas

---


### *Terminated Strings*

- Cada termo ocupa exatamente o seu tamanho.
- Para um vocabulário de 1.000.000 de palavras:
  - O vocabulário requer 20 Megabytes.
- O espaço requerido pode ainda ser reduzido eliminando muitos dos ponteiros de strings.

## Estruturas

---

### *Terminated Strings*



---

## Estruturas

---

### *Four-entry Blocking*

- 1 byte antes de cada palavra para indicar o seu tamanho.



- Para cada grupo de 4 palavras, 12 bytes são ganhos.




- Ganho de 2 Megabytes. O espaço total necessário é de 18 Megabytes.

- Para blocos de 8 palavras, o ganho é de + 0.5 Megabytes.

- Para blocos de 16 palavras, o ganho é de + 0.25 Megabytes.

## Estruturas

### *Four-entry Blocking*



---

## Estruturas

---

### *Front Coding*

- O ganho depende do vocabulário. Na média, 3 a 5 caracteres casam com custo adicional de 1 byte.



- Ganho médio é de 2.5 bytes por palavra.
- Regra do dedão:
  - *Front coding* salva aproximadamente 40% do espaço para vocabulário da língua inglesa.
- Uma estratégia 3-em-4 *front-coding*: salva 4 bytes em cada 3 palavras com custo extra de 2 bytes.



- Total de espaço necessário: 15.5 Megabytes.

---

## Estruturas

---

### *Front Coding*

Palavra	Front coding completo	Front coding “3-in-4” parcial
7, jezebel	3, 4, ebel	, 7, jezebel
5, jezer	4, 1, r	4, 1, r
7, jezerit	5, 2, it	5, 2, it
6, jeziah	3, 3, iah	3, , iah
6, jeziel	4, 2, el	, 6, jeziel
7, jezliah	3, 4, liah	3, 4, liah
6, jezoar	3, 3, oar	3, 3, oar
9, jezrahiah	3, 6, rahiah	3, , rahiah
7, jerezel	4, 3, eel	, 7, jerezel
11, jerezelites	7, 4, ites	7, 4, ites
6, jibsam	1, 5, ibsam	1, 5, ibsam
7, jidlaph	2, 5, dlaph	2, , dlaph

A palavra antes de *jezebel* era *jezaniah*.

---

## Estruturas

---

### *Front Coding*

- Cada entrada do vocabulário pode ser mais reduzida ainda:

$f_t \Rightarrow \lceil \log N \rceil$  bits, no exemplo anterior.



$f_t + d \approx 28$  bits cada.



- Ganho de mais 1 Megabyte.

- É possível fazer melhor?

Resp.: Sim, não armazenando o vocabulário!

---

## Referências

---

[WMB99] Witten I., Moffat A., Bell C. Managing Gigabytes Compressing and Indexing Documents and Images. 2nd Ed., 1999, pag. 161-169.