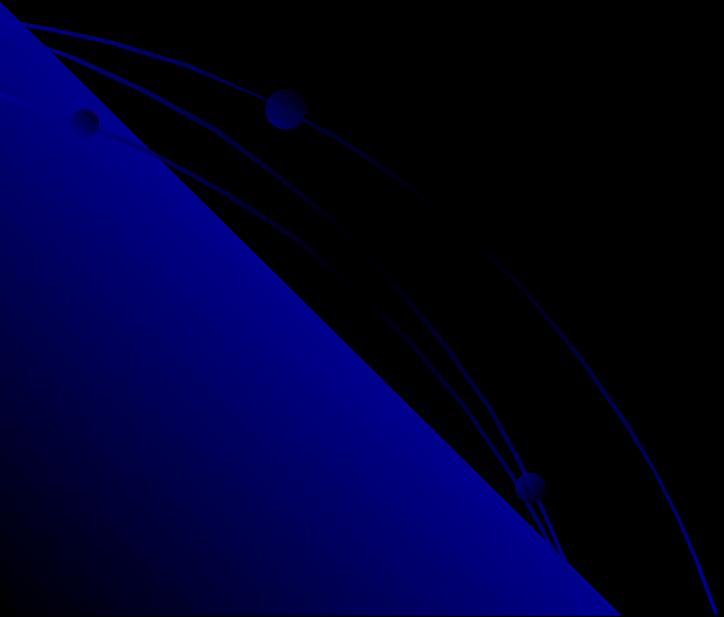


webir

Clase 6



Temas

- Compresión de índices - vocabulario
- Compresión de índices – lista de postings

Compresión de Vocabulario

... ArbolArteriaArterioesclerosisArtrosis...

- Diccionario en un sólo String
 - Lista continua de todos los términos
 - Reducción de hasta 60%

- Por Bloques

... 5Arbol7Arteria17Arterioesclerosis8Artrosis...

... 9Elemental8Elemento8Eliminar...

...

... 5Zorro6Zorzal8Zozobrar...

- Codificación Frontal – Front Coding

- 11.2 → 5.9

... 8Automata8Automate9automatic10Automation...

... 8Automat*a1æe2æic3æion...

Compresión de la Lista de Postings REUTERS-RCV1

- 800 000 documentos
 - $\log_2 800\,000 = 20$ bits para docID
- 200 tokens por documento
- Tokens de 6 caracteres = 6 bytes
- 100 000 000 postings

- Tamaño de la colección
 - $800\,000 * 200 * 6 = 960$ MB
- Tamaño del conjunto de postings (sin comprimir)
 - $100\,000\,000 * 20/8 = 250$ MB

Compresión de la Lista de Postings

- Ejemplo Reuters-RCV1
 - 800 000 documentos (~ 20 bits)
- ¿Menos de 20 bits para docID (por documento)?
- Dependiendo de la frecuencia de aparición de los términos en los documentos es la magnitud del gap

the	docIDs	...	283042	283043	283044
	gaps			1	1
computer	docIDs	...	283047	283154	283159
	gaps			107	5
zenith	docIDs		252000		500100
	gaps		252000	2481000	

Compresión de la Lista de Postings

- Ejemplo Reuters-RCV1
 - 800 000 documentos (~ 20 bits)
- ¿Menos de 20 bits para docID (por documento)?
- Dependiendo de la frecuencia de aparición de los términos en los documentos es la magnitud del gap

the	docIDs	...	283042	283043	283044
	gaps			1	1
computer	docIDs	...	283047	283154	283159
	gaps			107	5
zenith	docIDs		252000		500100
	gaps		252000	2481000	

Compresión de la Lista de Postings

- ¿Menos de 20 bits para docID (por documento)?
- Los términos frecuentes aparecen en muchos documentos
 - Es más “económico” representar el espacio entre documentos < 20 bits

the	docIDs	...	283042	283043	283044
	gaps			1	1
computer	docIDs	...	283047	283154	283159
	gaps			107	5
zenith	docIDs		252000		500100
	gaps		252000	2481000	

Compresión de la Lista de Postings

- ¿Menos de 20 bits para docID (por documento)?
- Los términos poco frecuentes aparecen en pocos documentos
 - No es tan “económico” representar el espacio entre documentos ~ 20 bits

the	docIDs	...	283042	283043	283044
	gaps			1	1
computer	docIDs	...	283047	283154	283159
	gaps			107	5
zenith	docIDs		252000		500100
	gaps		252000	2481000	

Compresión de la Lista de Postings

- Representación de largo variable!
- Compresión
 - Por bytes
 - Por bits

Código Variable en Bytes-

Código VB

- Número variable de bytes (8 bits)
- El primer bit de cada byte indica “continuación”
 - 1 si es el último byte
 - 0 en caso contrario
- Se concatenan 7 bits de cada byte
- Se obtiene número binario


docID	... 824	829	2125406...
gap	5	214577	
Código VB	<u>1</u> 0000101	<u>0</u> 0001101	<u>0</u> 0001100 <u>1</u> 0110001

Código Variable en bytes - Código VB

- REUTERS-RCV1
 - Se reduce de 250 MB a 116 MB
 - Más del 50%
- Se puede aplicar otras unidades
 - 32 bits
 - 16 bits
 - 4 bits
- Espacio ahorrado/tiempo de decodificación

Código Variable en bits – Código Vb

- Número variable de bits
- Códigos γ y δ



Código Variable en bits – Código Vb

- Código unario
- Código variable en bits más sencillo
- Ineficiente

0	0
1	10
2	110
3	1110
4	11110
9	1111111110

Código Variable en bits – Código Vb

- Cantidad de gaps G
 - $1 \leq G \leq 2^n$
 - Asumiendo que son equiprobables
- Código óptimo usa \underline{n} bits
 - En particular $g=2^n$, no se puede codificar con menos de $\log_2 2^n \text{ bits} = n \text{ bits}$
- Acercarse al óptimo de \underline{n} bits
 - Se debe distinguir un gap de otro = desperdicio

Código Variable en bits – Código Vb

- Representación del código y
 - *largo y offset*
- *offset*
 - Es el número en representación binaria sin el 1 más significativo
 - 13 → 1101, *offset* = 101
- *largo*
 - Largo del *offset* en código unario + 0
 - 13 → 1101, *offset* = 101 y *largo* = 1110
- Código y para 13 es 1110101

Código Variable en bits – Código Vb

- Código γ
- Leer el *largo* hasta el 1er 0
- Leer el *offset*
- Agregar el 1 que se eliminó
- Código γ para 13 es 1110101
 - *largo* = 1110 \rightarrow
 - *offset* = 101 \rightarrow
 - número es 1101 = 13

Número	Código γ
0	¿Porqué?
1	0
2	10,0
3	10,1
4	110,00
9	1110,001
13	1110,101
24	11110,1000
511	111111110,11111111

Código Variable en bits – Código Vb

- Cantidad de gaps G
 - $1 \leq G \leq 2^n$
- Código γ
 - *offset* es $\lfloor \log_2 G \rfloor$
 - *largo* es $\lfloor \log_2 G \rfloor + 1$
 - Total $2 * \lfloor \log_2 G \rfloor + 1$
 - Diferencia del óptimo por constante multiplicativa = 2
- ¿Equiprobables?

Código Variable - Entropía

- Propiedades de la codificación en base a una distribución de probabilidad P de los datos a codificar (en este caso gaps) se determina mediante


- Entropía
$$H(P) = -\sum_{x \in X} P(x) \log_2 P(x)$$

- X es el conjunto de números a codificar
$$\sum_{x \in X} P(x) = 1$$

- $H(P)$ es una cota inferior para el largo esperado de la codificación óptima (optimalidad del código)
- Código y constante multiplicativa = 3, sin importar P
→ codificación Universal

Código Variable - Entropía

- Dos eventos x_1 y x_2
- $X = \{x_1, x_2\}$
- $H(P) = 1$, máxima
 - $P(x_1) = P(x_2) = 0.5$
 - Máxima incertidumbre
- $H(P) = 0$, mínima
 - $P(x_1) = 1$ y $P(x_2) = 0$ o viceversa
 - Mínima incertidumbre



Código Variable en bits – Código Vb

- Código γ – Ventajas
 - Universalidad
 - Sin prefijos comunes – no se necesitan delimitadores
 - Sin parámetros que ajustar
- REUTERS-RCV1
 - Se reduce de 250 MB a 101 MB

Código Variable en bits – Código Vb

- Código γ – Desventajas
 - Decodificación costosa
 - No siempre coinciden las unidades con palabras/unidades en memoria
 - Las operaciones de bajo nivel se aplican a las unidades de memoria
- Tiempo vs espacio

Código Variable en bits – Código Vb

- Código δ (para mejorar rep. del largo en γ)
 - *largo y offset*
- Optimizar la representación del *largo*
- Codificar el largo con código γ
- Código γ para 7 es 10,0,11
 - Código γ para *largo* 2 \rightarrow 10,0
 - *offset* = 11 permanece igual

Código Variable en bits – Código Vb

Method	Bits per gap			
	Bible	GNUBib	Comact	TREC
Unary	262	909	487	1918
Gamma γ	6.51	5.68	4.48	6.63
Delta δ	6.23	5.08	4.35	6.38

- ¿Para qué rango de valores es más corto el código δ que el código γ ?

Códigos de Compresión

- Tabla anterior:
 - I.H. Witten, A. Moffat and T.C. Bell, “Managing Gigabytes”, Morgan Kaufmann, 1999
- Compresión de documentos de texto con posibilidades de búsqueda de palabras o frases:
 - de Moura, Edleno Silva, Gonzalo Navarro, Nivio Ziviani, and Ricardo Baeza-Yates, “Fast and flexible word searching on compressed text”, 2000
 - Brisaboa, Nieves R., Antonio Fariña, Gonzalo Navarro, and José R. Paramá, “Lightweight natural language text compression”, 2007