Estructuras de Datos
Clase 19 – Procesamiento de Texto (Codificación de Huffman)

Dr. Sergio A. Gómez
http://cs.uns.edu.ar/~sag

Departamento de Ciencias e Ingeniería de la Computación
Universidad Nacional del Sur
Bahía Blanca, Argentina

Compresión de datos

- La **compresión de datos** consiste en la reducción del volumen de información tratable (procesar, transmitir o grabar).
- En principio, con la compresión se pretende transportar la misma información, pero empleando menor cantidad de espacio.

Tipos de compresión

- **Compresión sin pérdida de información:**
  - los datos antes y después de comprimirlos son exactos en la compresión sin pérdida.
  - En el caso de la compresión sin pérdida una mayor compresión solo implica más tiempo de proceso.
  - Se utiliza principalmente en la compresión de texto.
- **Compresión con pérdida de información:**
  - Puede eliminar datos para reducir aún más el tamaño, con lo que se suele reducir la calidad.
  - Hay que tener en cuenta que una vez realizada la compresión, no se puede obtener la señal original, aunque sí una aproximación cuya semejanza con la original dependerá del tipo de compresión.
  - Se utiliza principalmente en la compresión de imágenes, videos y sonidos. Ej: Formatos jpg, mpeg, mp3

Compresión de texto (sin pérdida)

- Problema: Dado un string X definido sobre un alfabeto Σ (Ascii o Unicode), deseamos codificar X en forma eficiente en forma binaria (es decir, obtener un string Y formado sólo por 0 y 1).
- Ventajas:
  - Ahorro de ancho de banda en las comunicaciones
  - Ahorro de espacio en disco en archivos almacenados

Codificación binaria

- Si el alfabeto Σ tiene n símbolos se necesitan $\lceil \log_2(n) \rceil$ bits para codificar cada símbolo
- Ejemplo: Como el alfabeto Ascii tiene 256 símbolos, necesito 8 bits.
- Ejemplo: Si $\Sigma = \{$ a, b, c, d, e, f, g, h $\}$, entonces n = 8

  Como $\log_2(8) = 3$, entonces una codificación posible es:

  a = 000 b = 001 c = 010 d = 011

  e = 100 f = 101 g = 110 h = 111

  La cadena “aaabbccdefad” se codifica sin compresión como (los puntos son para leerla más fácil y no se almacenan):

  000.000.000.001.001.010.010.011.100.101.000.011

Codificación de Huffman: Preliminares

- Objetivo: En lugar de usar un número fijo de bits para codificar cada carácter de un string X, los caracteres que más se usan se codifican con menos bits y los que menos se usan se codifican con más bits.
- Por cada carácter es necesario conocer su frecuencia de aparición.
- Es decir, por cada carácter c tendremos f(c) = cantidad de apariciones de c en la cadena X a comprimir
- La concatenación de los bits de la compresión de los caracteres de la cadena forman el string comprimido.
- Código prefijo: Para evitar ambigüedades, no va a haber ningún código que sea prefijo de otro.

Codificación de Huffman: Idea

- Construye un árbol binario T que representa la codificación para una cadena X
- Cada nodo, excepto la raíz, representa un bit del código.
- El hijo izquierdo representa un 0 y el derecho un 1
- Cada hoja representa un carácter c
- La codificación de un carácter c se define como la secuencia de bits determinada por el camino de la raíz a la hoja que contiene a c en el árbol T.
- Cada hoja tiene una frecuencia f(v) correspondiente a la frecuencia del carácter c almacenado en v
- Cada nodo interno tiene una f(v) que corresponde a la suma de las frecuencias de los caracteres en dicho subárbol.
- Ejemplo: Figura 12.11 de GT

Ejemplo

Supongamos queremos comprimir la cadena X = aaaaaabbbaaaaaccd (que tiene longitud 17)

El alfabeto tiene 4 símbolos, luego necesito 2 bits para representar cada uno:

a=00, b=01, c=10, y d=11 .

La cadena sin comprimir se representa como:

00.00.00.00.00.00.01.01.01.00.00.00.00… etc

Necesito 17*2 = 34 bits para representarla.

El cálculo de las frecuencias de apariciones da: f(a) = 11, f(b)=3, f(c)=2 y f(d)=1.

Ejemplo (cont)

El algoritmo genera el siguiente código:

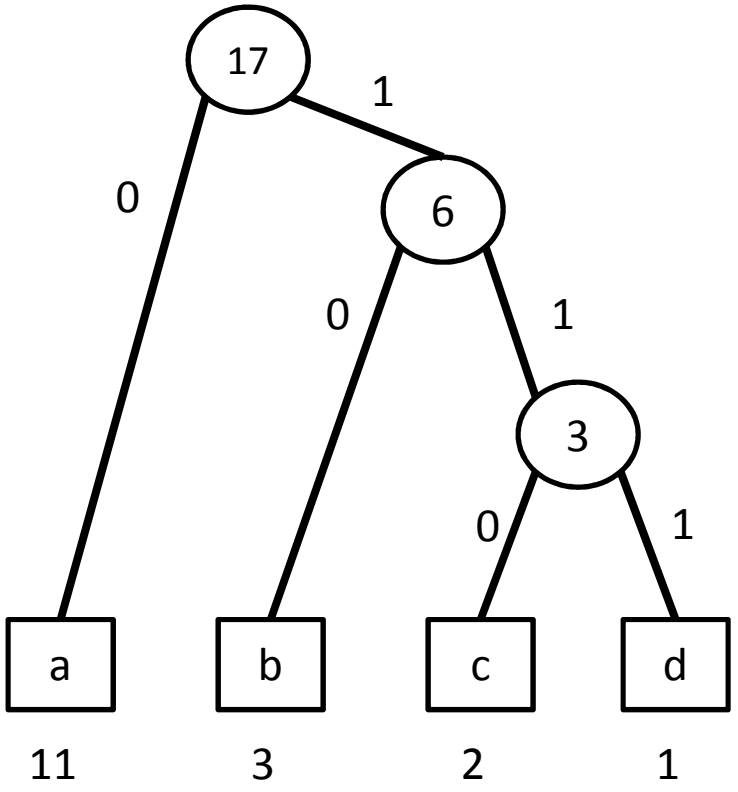

a = 0

b = 10

c = 110

d = 111

Por lo tanto, la cadena X = aaaaaabbbaaaaaccd se comprime como: 00000010101000000110110111, la cual mide 26 bits.

Así tengo una tasa de compresión del:

34 bits _____ 100%

26 bits _____ x =

100%*26bits/34bits = 76%

Algoritmo de Huffman

Algoritmo Huffman(X)
Entrada: Un string X de longitud n sobre alfabeto de tamaño d
Salida: árbol para codificar X
Computar la frecuencia f(c) para cada carácter c de X
Crear una cola con prioridad C
Para cada carácter c en X **hacer**
    Crear un árbol binario hoja T con rótulo c
    Insertar T en Q con prioridad f(c)
Mientras Q.size() > 1 **hacer**
    $f_1 \leftarrow$ Q.min().key(); $T_1 \leftarrow$ Q.removeMin()
    $f_2 \leftarrow$ Q.min().key(); $T_2 \leftarrow$ Q.removeMin()
    Crear un nuevo árbol binario T con hijo izquierdo T_1 e hijo derecho T_2
    Insertar T en Q con prioridad f_1+f_2
Retornar el árbol Q.removeMin()

Aplicando Huffman al idioma castellano

- En GT, Huffman se estudia orientado a comprimir una cadena de texto en particular y generar una compresión óptima para dicha cadena.
- Para aplicarlo a documentos arbitrarios sin necesidad de armar cada vez el árbol de compresión se puede:
  - Determinar la frecuencia de aparición de cada letra/símbolo en el idioma castellano
  - Construir el árbol de compresión de Huffman
  - Utilizar siempre el mismo árbol para comprimir/descomprimir
  - Algunas veces el resultado será malo y otras bueno pero considerando todos los archivos comprimidos en conjunto el resultado será bueno.

Bibliografía

- Capítulo 12, Sección 3 de M. Goodrich & R. Tamassia, Data Structures and Algorithms in Java. Fourth Edition, John Wiley & Sons, 2006.