Compacto dos melhores momentos

AULA 16 e 17

Compressão de dados

Problema: representar um arquivo GRANDE por outro menor.

Exemplo:
arquivo GRANDE: `abababababababababababab`
arquivo menor: `12ab`

Por que comprimir?
Menor espaço de armazenamento.
Menor tempo de transmissão.

Software: `gzip`, `bzip`, `7z`, etc.

Esquema

representar um dado fluxo de bits (*bitstream*) por outro mais curto.

Esquema básico de compressão de dados:

- um compressor transforma um fluxo de bits `B` em um fluxo `C(B)` e
- um expansor transforma `C(B)` de volta em `B`.

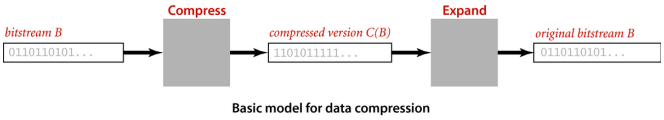

Basic model for data compression

Entradas e saídas binárias

Cadeia de bits (=*bitstring*) é uma sequência de bits:

`1100010000011101010100111110110011100010100001100000000001111110000011101000111`

fluxo de bits (=*bitstream*) é uma cadeia de bits na entrada ou na saída de um programa.

A classe `BinaryStdIn` lê um fluxo de bits a partir da entrada padrão.

A classe `BinaryStdOut` escreve um fluxo de bits na saída padrão.

`BinaryDump`, `HexDump` e `PictureDump`

```
% more abra.txt
ABRACADABRA!

% java BinaryDump 16 < abra.txt
0100000101000010
0101001001000001
0100001101000001
0100010001000001
0100001001010010
0100000100100001
96 bits
```

Genomas

Podemos usar apenas 2 bits por caractere:

```
% more genomeTiny.txt
ATAGATGCATAGCGCATAGCTAGATGTGCTAGC

% java Genome - < genomeTiny.txt | java BinaryDump 32
00000000000000000000000000100001
00110010000111001001100100100100
11001001110010000111011001110010
01000000
104 bits
```

Codificação de comprimento de carreira

Em inglês: *run-length encoding* (=RLE).

Exemplo: cadeia de bits abaixo tem uma carreira de 15 0s, uma carreira de 7 1s, uma de 7 0s, e uma de 11 1s:

000000000000000111111100000011111111111

Pode ser representada pela sequência 15 7 7 11. Usando **8 bits** para cada um desses números, teremos uma cadeia de apenas 32 bits (ignore os espaços):

00001111000001110000011100001011

Algoritmo de Huffman

Ideia do algoritmo de Huffman: usar códigos **curtos** para os caracteres que ocorrem com **frequência** e deixar os códigos mais **longos** para os caracteres mais **raros**.

Algoritmo de Huffman

Uma tabela de códigos leva cada caractere de 8 bits no seu código.
Exemplo de códigos de comprimento fixo:

caractere	código
!	001
A	010
B	011
C	100
D	101
R	110

A tabela de códigos é uma ST em que as chaves são os caracteres e os valores são os códigos.

Algoritmo de Huffman

Usando a tabela de códigos anterior gastaríamos

$$100000 \times 3 = 300000 \quad \text{bits}$$

para codificar o arquivo.

Examinando o arquivo observamos a seguinte frequência de símbolos.

caractere	frequência
!	5000
A	45000
B	13000
C	9000
D	16000
R	12000

Algoritmo de Huffman

Exemplo de códigos de comprimento variável:

caractere	código
!	1010
A	0
B	111
C	1011
D	100
R	110

Com essa nova tabela de códigos gastaríamos

$5\text{M} \times 4 + 45\text{M} \times 1 + 13\text{M} \times 3 + 9\text{M} \times 4 + 16\text{M} \times 3 + 12\text{M} \times 3$

bits $= 224000$ bits para representar o arquivo.

AULA 18

Algoritmo LZW

Limpel Ziv Algorithm Family

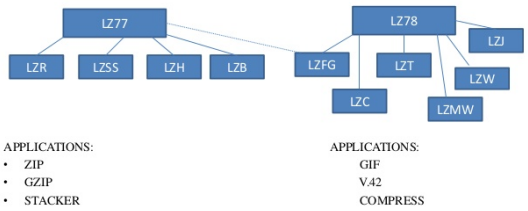

Fig 1: Limpel Ziv Algorithm Family

Referências: Data Compression (SW), slides (SW), LZW compression, video (SW)

Algoritmo LZW

Desenvolvido por Abraham Lempel e Jakob Ziv em 1977 (LZ77).

Refinamento de LZ78 por Terry Welch em 1978.

Huffman é um método estatística de compressão de dados.

LZW é um método baseado em dicionários (*dictionary based compression systems*).

Diferentemente do algoritmo de Huffman, o algoritmo LZW transforma strings de tamanho variado em códigos de tamanho fixo de W bits (usualmente de 8 a 12).

Métodos baseados em dicionários

Não usam conhecimento estatístico dos dados.

`compress()`: a medida que a entrada é processada constrói um dicionário e utiliza os índices dos strings no dicionário como código.

`expand()`: a medida que a entrada é processada reconstrói o dicionário para reverter o trabalho de `compress()`.
Exemplos: LZW, LZ77, Sequitur

Aplicações: Unix compress, `gzip`, GIF

LZW compress()

`input` = string de entrada

```
crie dicionário com símbolos do alfabeto
repita
  encontre o maior prefixo s de input
           que está no diconário
  transmita para saída o índice de s
  ponha s+c no dicionário onde c é
        o símbolo que segue s em input
        (unmatched symbol).
  apague do input o prefixo s
até que input é vazio
```

LZW exemplo

Decisões de projeto:

- Alfabeto = {a, b} ⇒ R = 2
- W = 3 bits ⇒ índices entre 0 e 7
- tamanho L do dicionário é $2^W = 8$
- índice R codificará EOF (end of file)

LZW compress(): exemplo

input	a	b	a	b	a	b	a	b	a	b	
codificação											

dicionário

string	código
a	0
b	1
EOF	2

LZW compress(): exemplo

input	a	b	a	b	a	b	a	b	a	b	
codificação	0										

dicionário

string	código
a	0
b	1
EOF	2
ab	3

LZW compress(): exemplo

input	a	b	a	b	a	b	a	b	a	b	
codificação	0	1									

dicionário

string	código
a	0
b	1
EOF	2
ab	3
ba	4

LZW compress(): exemplo

input	a	b	a	b	a	b	a	b	a	b	
codificação	0	1	3								

dicionário

string	código
a	0
b	1
EOF	2
ab	3
ba	4
aba	5

LZW compress(): exemplo

input	a	b	a	b	a	b	a	b	a	b	
codificação	0	1	3		5						

dicionário

string	código
a	0
b	1
EOF	2
ab	3
ba	4
aba	5
abab	6

LZW compress(): exemplo

input	a	b	a	b	a	b	a	b	a	b	
codificação	0	1	3		5		4				

dicionário

string	código
a	0
b	1
EOF	2
ab	3
ba	4
aba	5
abab	6
bab	7

LZW compress(): exemplo

input	a	b	a	b	a	b	a	b	a	b	
codificação	0	1	3		5		4		1		

dicionário

string	código
a	0
b	1
EOF	2
ab	3
ba	4
aba	5
abab	6
bab	7

LZW compress(): exemplo

input	a	b	a	b	a	b	a	b	a	b	
codificação	0	1	3		5		4		1	2	

dicionário

string	código
a	0
b	1
EOF	2
ab	3
ba	4
aba	5
abab	6
bab	7

LZW compress(): exemplo

Resumo

Fomos de $8 \times 10 = 80$ bits para representar

a b a b a b a b a b

para $W \times 7 = 3 \times 7 = 21$ bits:

000 001 011 101 100 001 010

Taxa de compressão $= 21/80 = 0.2625 \sim 26\%$

LZW compress(): mais um exemplo

Decisões de projeto:

- Alfabeto = ASCII $\Rightarrow$ R = 128
- W = 8 bits $\Rightarrow$ índices entre 0 e 255
- tamanho L do dicionário é $2^W = 256$
- índice R = 128 (= 80 hexa) codificará EOF

LZW compress(): mais um exemplo

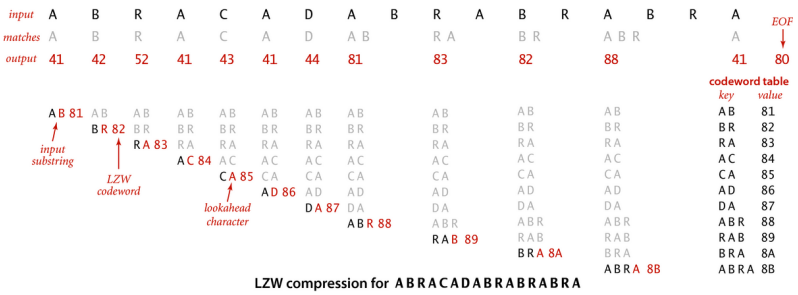

LZW compression for ABRACADABRABRABRA

Fonte: algs4

LZW compress(): mais um exemplo

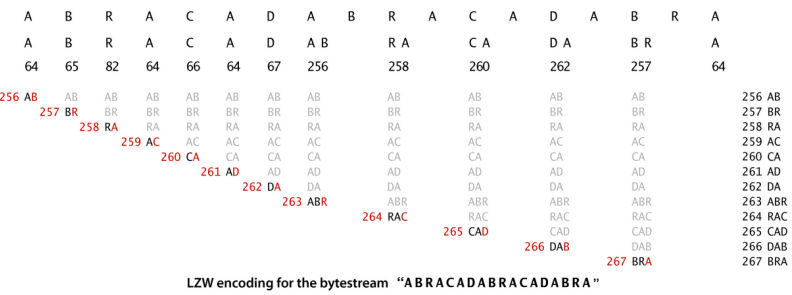

LZW encoding for the bytestream "ABRACADABRACADABRA"

Fonte: algs4

Sobre o dicionário

Dicionário de tamanho fixo:

- W bits de índices permite um dicionário de tamanho 2^W;
- dificilmente todas as entradas no dicionário serão úteis.

Estratégias quando o dicionário atinge seu limite:

- não ponha mais strings, somente use o que já estão no dicionário;
- jogue tudo fora e comece um novo dicionário;
- dobre o dicionário, acrescentando mais um bit ao índices ($W \leftarrow W + 1$);
- jogue fora as entradas mais recentes para fazer espaço para mais entada;
- ideias?

Dicionário (Trie) de LZW

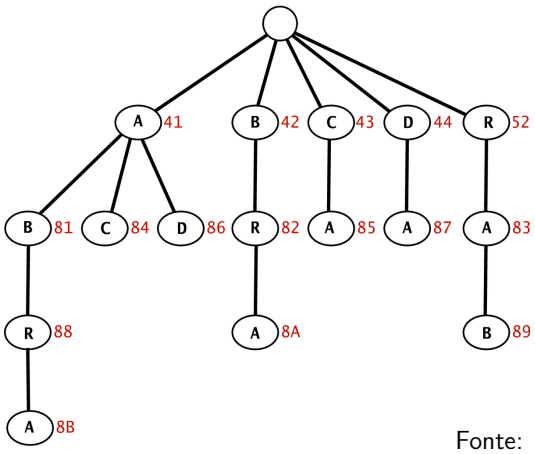

Fonte: algs4

Trie representation of LZW code table

compress()

Estatística dos dados não precisa ser passada por compress() para expand().

```
public static void compress() {
   String input=BinaryStdIn.readString();
   TST<Integer> st = new TST<Integer>();
   for (int i = 0; i < R; i++)
       st.put("" + (char) i, i);
   // R é o código para EOF
   int code = R+1;
```

compress()

```
 while (input.length() > 0) {
    String s = st.longestPrefixOf(input);
    BinaryStdOut.write(st.get(s), W);
    int t = s.length();
    if (t < input.length() && code < L)
        st.put(input.substring(0,t+1),code++);
    input = input.substring(t);
 }
 BinaryStdOut.write(R, W); // EOF
 BinaryStdOut.close();
}
```

abra.txt

```
% more abra.txt | java B...Dump 0
96 bits
% java LZW - < abra.txt |java B...Dump 24
000001000001000001000010
000001010010000001000001
000001000011000001000001
000001000100000100000001
000100000011000000100001
000100000000000
136 bits
```

LZW expand(): exemplo

msg codificada	0	1	3	5	4	1	2
output							

dicionário

string	código

LZW expand(): exemplo

msg codificada	0	1	3	5	4	1	2
output							

dicionário

string	código
a	0
b	1
EOF	2

LZW expand(): exemplo

msg codificada	0	1	3	5	4	1	2
output	a						

dicionário

string	código
a	0
b	1
EOF	2
a?	3

LZW expand(): exemplo

msg codificada	0	1	3	5	4	1	2
output	a	b					

dicionário

string	código
a	0
b	1
EOF	2
ab	3

LZW expand(): exemplo

msg codificada	0	1	3	5	4	1	2
output	a	b					

dicionário

string	código
a	0
b	1
EOF	2
ab	3
b?	4

LZW expand(): exemplo

msg codificada	0	1	3		5	4	1	2
output	a	b	a	b				

dicionário

string	código
a	0
b	1
EOF	2
ab	3
ba	4

LZW expand(): exemplo

msg código	0	1	3		5	4	1	2
output	a	b	a	b				

dicionário

string	código
a	0
b	1
EOF	2
ab	3
ba	4
ab?	5

LZW expand(): exemplo

msg código	0	1	3		5	4	1	2
output	a	b	a	b				

dicionário

string	código
a	0
b	1
EOF	2
ab	3
ba	4
ab?	5
	Xiii!

LZW expand(): exemplo

msg código	0	1	3		5			4	1	2
output	a	b	a	b	a	b	?			

dicionário

string	código
a	0
b	1
EOF	2
ab	3
ba	4
ab?	5
	Xiii!

LZW expand(): exemplo

msg código	0	1	3		5			4	1	2
output	a	b	a	b	a	b	a			

dicionário

string	código
a	0
b	1
EOF	2
ab	3
ba	4
aba	5
	:-)

LZW expand(): exemplo

msg código	0	1	3		5			4	1	2
output	a	b	a	b	a	b	a			

dicionário

string	código
a	0
b	1
EOF	2
ab	3
ba	4
aba	5
aba?	6

LZW expand(): exemplo

msg código	0	1	3		5			4		1	2
output	a	b	a	b	a	b	a	b	a		

dicionário

string	código
a	0
b	1
EOF	2
ab	3
ba	4
aba	5
aba?	6

LZW expand(): exemplo

msg código	0	1	3		5			4		1	2
output	a	b	a	b	a	b	a	b	a		

dicionário

string	código
a	0
b	1
EOF	2
ab	3
ba	4
aba	5
abab	6

LZW expand(): exemplo

msg código	0	1	3		5			4		1	2
output	a	b	a	b	a	b	a	b	a		

dicionário

string	código
a	0
b	1
EOF	2
ab	3
ba	4
aba	5
abab	6
ba?	7

LZW expand(): exemplo

msg código	0	1	3		5			4		1	2
output	a	b	a	b	a	b	a	b	a	b	

dicionário

string	código
a	0
b	1
EOF	2
ab	3
ba	4
aba	5
abab	6
ba?	7

LZW expand(): exemplo

msg código	0	1	3		5			4		1	2
output	a	b	a	b	a	b	a	b	a	b	

dicionário

string	código
a	0
b	1
EOF	2
ab	3
ba	4
aba	5
abab	6
bab	7

LZW expand(): mais um exemplo

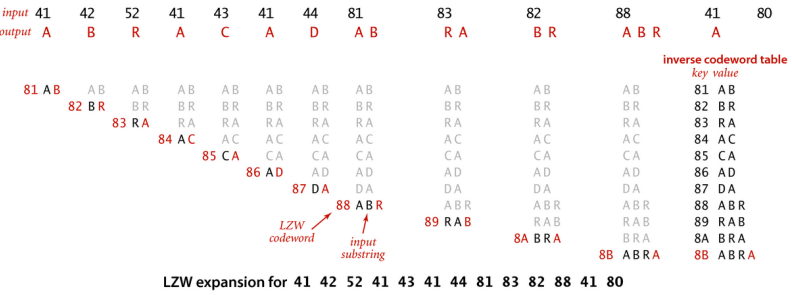

LZW expansion for 41 42 52 41 43 41 44 81 83 82 88 41 80

Fonte: algs4

LZW *lookahead*

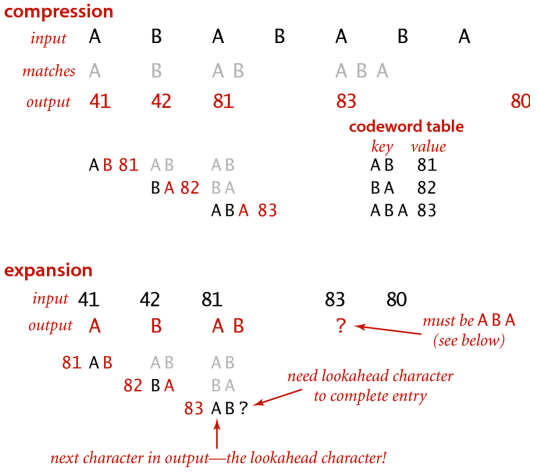

LZW expansion: tricky situation

LZW expand()

expand()

- simula compress() para reconstruir o dicionário.
- anda um *um poucoquino atrás* de compress(), mas olhando para frente (*lookahead*).

LZW expand()

```
crie dicionário com símbolos do alfabeto
decodifique o primero índice code para o
             string val
coloque val+? no dicionário
repita
  decodifique o primeiro símbolo c
             do próximo índice code
  complete com c a última entrada
             da tabela
  termine de decodificar code e obtenha
             o string s
  transmita s para a saída
  ponha s+? no dicionário
até que input é vazio
```

expand()

```
public static void expand() {
   String[] st = new String[L];
   int i; próximo código disponível
   // inicialize a ST
   for (i = 0; i < R; i++)
       st[i] = "" + (char) i;
   st[i++] = " ";
   int codeword = BinaryStdIn.readInt(W);
   // mensagem é vazia?
   if (codeword == R) return;
   String val = st[codeword];
```

expand()

```
   while(true) {
       BinaryStdOut.write(val);
       codeword = BinaryStdIn.readInt(W);
       if (codeword == R) break;
       String s = st[codeword];
       if (i == codeword)
           // caso especial
           s = val + val.charAt(0);
       if (i < L)
           st[i++] = val + s.charAt(0);
       val = s;
   }
   BinaryStdOut.close();
}
```

Esqueleto da classe LZW

```
public class LZW {
   // tamanho do alfabeto
   private static final int R = 256;

   // número de bits dos códigos
   private static final int W = 12;

   // number códigos 2^W
   private static final int L = 4096;

   public static void compress() {...}
   public static void expand() {...}
}
```

LZW exemplos

virus (50000 bits)

```
% java Genome - < genomeVirus.txt | java PictureDump 512 25
```

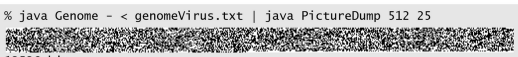

```
12536 bits

% java LZW - < genomeVirus.txt | java PictureDump 512 36
```

```
18232 bits  <-- not as good as 2-bit code because repetitive data is rare
```

bitmap (6144 bits)

```
% java RunLength - < q64x96.bin | java BinaryDump 0
2296 bits

% java LZW - < q64x96.bin | java BinaryDump 0
2824 bits  <-- not as good as run-length code because file size is too small
```

entire text of *Tale of Two Cities* (5812552 bits)

```
% java BinaryDump 0 < tale.txt
5812552 bits

% java Huffman - < tale.txt | java BinaryDump 0
3043928 bits

% java LZW - < tale.txt | java BinaryDump 0
2667952 bits  <-- compression ratio 2667952/5812552 = 46% (best yet)
```

Compressing and expanding various files with LZW 12-bit encoding

Fonte: algs4

Genome versus LZW

```
% java PictureDump 512 100 < genomeVirus.txt
```

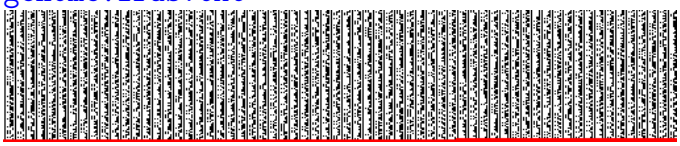

50008 bits

Genome versus LZW

```
% java Genome - < genomeVirus.txt | java PictureDump 512 25
```

12536 bits

```
% java LZW - < genomeVirus.txt | java PictureDump 512 25
```

18232 bits

strings repetidas parecem ser raras.

RunLength versus LZW

```
% java PictureDump 32 48 < q32x48.bin
```
1536 bits

```
% java RunLength - < q32x48.bin | java
BinaryDump 0
```
1144 bits

```
% java LZW - < q32x48.bin | java
BinaryDump 0
```
1176 bits

Tamanho do arquivo é muito pequeno?

RunLength versus LZW

```
% java PictureDump 64 96 < q32x48.bin
```
6144 bits

```
% java RunLength - < q32x48.bin | java
BinaryDump 0
```
2296 bits

```
% java LZW - < q32x48.bin| java
BinaryDump 0
```
2824 bits

Tamanho do arquivo é muito pequeno?

Huffman versus LZW

```
% java BinaryDump 0 < les-miserables.txt
```
26581192 bits

```
% java Huffman - < les-miserables.txt |
java BinaryDump 0
```
15211904 bits

```
% java LZW - < les-miserables.txt | java
BinaryDump 0
```
15316048 bits **demorou muito para responder!**

Observações sobre LZW

- positivo: extremamente efetivo quando padrões repetidos ocorrem de maneira dispersa nos dados
- negativo: cria entrados no dicionário que podem não são usadas

LZ77

Ziv e Lempel, 1977

Dicionário é implícito.

Usa o string codificado até agora como dicionário

Se `input.substring(0,n)` foi codificado, queremos codificar `input.substring(0,n+k)` para o maior `k` possível

LZ77

Ideia: `input.substring(0,n+k)` é substring de `input.substring(0,n)`, então podemos codificar `input.substring(0,n+k)` por um par de inteiros $\langle j, k \rangle$ onde `j` é índice do início da ocorrência.

Exemplo:

ababababa	babababa	bababaababa...
codificado	$\langle 1, 8 \rangle$	a codificar

Observações sobre LZ77

Muito polular no mundo Unix.

Muitas variantes implementadas: `zip`, `gzip`, `png`, `pkzip`, `lharc`, `arj`

Em geral melhor que `LZW`:

- `LZW` tem dicionário com entradas que não são usadas
- `LZW` tem substrings examinados que não estão no dicionário
- `LZ77` tem um dicionário implicito e pares frequentes são codificados com menos bits.