AULA 17

Compressão de dados

Fonte: Best VPN for Data Compression

Referências: Entrada e saída binárias (PF), Compressão de dados (PF), Data Compression (SW), slides (SW), video (SW)

Introdução

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`.

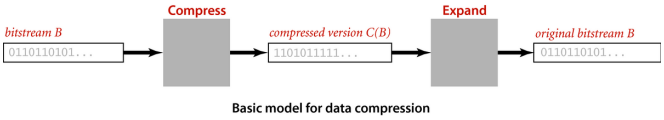

Basic model for data compression

Codificador e decodificador

Fluxo `B` é original e o fluxo `C(B)` é codificado.

Fluxo produzido pelo expansor é decodificado.

Fluxo decodificado é idêntico ao original, a compressão não perde informação (*lossless compression*).

Notação: `|B|` é o número de bits de `B`.

Taxa de compressão: `|C(B)|/|B|`.

Desafio: obter a menor taxa de compressão possível.

Considerações teóricas

Fato. Nenhum algoritmo pode garantir taxa de compressão estritamente menor que 1 para todo e qualquer fluxo de bits.

Fluxos de bits aleatórios são pouco compressíveis.

Mesmo fluxos pseudo-aleatórios podem ser difíceis de comprimir.

Considerações teóricas

Muitos fluxos de bits parecem aleatórios mas não são.

Exemplo: o fluxo de bits parece aleatório...

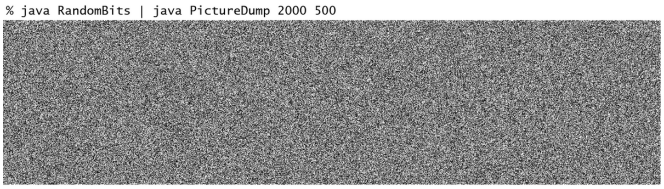

A difficult file to compress: 1 million (pseudo-) random bits

Considerações teóricas

mas foi produzido pelo código

```
public class RandomBits {
  public static void main(String[] args){
  int x = 11111;
  for(int i = 0; i < 1000000; i++) {
      x = x * 314159 + 218281;
      BinaryStdOut.write(x>0);
  }
  BinaryStdOut.close();}
}
```

Taxa de compressão: 0.002

Considerações teóricas

Outro exemplo:

$$4\,(\sum_{i=0}^{\infty}(-1)^i(1/(2i+1))$$

é uma representação muito comprimida da expansão decimal do número π.

Teoria da compressão de dados tem ligações fascinantes com a Teoria da Informação e os conceito de Aleatoriedade e Entropia.

Entrada e saídas binárias

Input / Output Streams

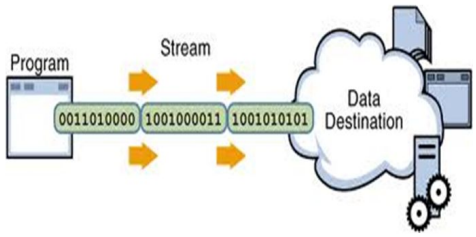

Fonte: Input / Output Streams Byte streams

Referências: BinaryStdIn, BinaryStdOut, BinaryIn, BinaryOut

Cadeia de bits e fluxo de bits

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

```
11000100000111010101001111101100111000101000011
11000000000001111111000001110100011
```

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.

BinaryStdIn

public class	BinaryStdIn	
boolean	readBoolean()	lê 1 bit e devolve o boolena correspond
char	readChar()	lê 8 bits
char	readChar(int r)	lê r (entre 1 e 16) bits
String	readString()	lê fluxo em blocos de 8 bits
int	readInt()	lê 32 bits
int	readInt(int r)	lê r (entre 1 e 32) bits
boolean	isEmpty()	fluxo está vazio?
void	close()	feche o fluxo

BinaryStdOut

public class	BinaryStdOut	
void	write(boolean b)	escreve o bit representado por b
void	write(char c)	escreve 8 bits da representação de c
void	write(char c, int r)	escreve os r (1 a 16) bits de c menos significativos
void	close()	feche o fluxo

Para arquivos o algs4 disponibiliza os irmãos BinaryIn e BinaryOut.

Exemplo

Representação de datas, como 15/05/2018.

```
StdOut.print(dia + "/"+ mes + "/"+ ano);
```

```
00110001 00110101 16 bits
00101111          8 bits
00110000 00110101 16 bits
00101111          8 bits
00110010 00110000 00110001 00111000 32 bits
80 bits
```

representação: 10 chars $= 10 \times 8$ bits

Exemplo. . . continuação

Representação de datas, como 15/05/2018.

```
BinaryStdOut.write(dia);
BinaryStdOut.write(mes);
BinaryStdOut.write(ano);
```

```
00000000000000000000000000001111 32 bits
00000000000000000000000000000101 32 bits
00000000000000000000011111100010 32 bits
96 bits
```

representação: 3 ints $= 3 \times 32$ bits

Exemplo . . . continuação

Representação de datas, como 15/05/2018.

```
BinaryStdOut.write((char) dia);
BinaryStdOut.write((char) mes);
BinaryStdOut.write((short) ano);
```

```
00001111 8 bits
00000101 8 bits
0000011111100010 16 bits
32 bits
```

representação: 2 chars + 1 short $= 2 \times 8 + 16$ bits

Exemplo . . . continuação

Representação de datas, como 15/05/2018.

```
BinaryStdOut.write(dia, 5);
BinaryStdOut.write(mes, 4);
BinaryStdOut.write(ano, 12);
```

```
01111 5 bits
0101 4 bits
011111100010 12 bits
000 3 bits
24 bits
```

representação: 5 + 4 + 12 bits + 3 bits de padding

BinaryDump: exemplo

```
% more abra.txt
ABRACADARRA!

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

BinaryDump

Examina e converta uma cadeia de bits no caracteres 0 e 1.

```
public class BinaryDump{
  public static void main(String[] args){
    int width= Integer.parseInt(args[0]);
    int cnt;
```

BinaryDump

```
for(cnt= 0;!BinaryStdIn.isEmpty();cnt++){
  if (width == 0) {
      BinaryStdIn.readBoolean();
      continue;
  }
  if (cnt != 0 && cnt % width == 0)
      StdOut.println();
  if (BinaryStdIn.readBoolean())
      StdOut.print("1");
  else StdOut.print("0");
}
if (width != 0) StdOut.println();
StdOut.println(cnt + "bits");
}
```

HexDump: exemplo

Divide a cadeia de bits em blocos de 4 bits e imprime cada bloco como um par de dígitos hexadecimais.

```
% more abra.txt
ABRACADARRA!

% java HexDump 4 < abra.txt
41 42 52 41
43 41 44 41
42 52 41 21
96 bits
```

PictureDump: exemplo

Exibe uma cadeia de bits como uma sequência de pequenos quadrados pretos e brancos dividida em linhas de comprimento especificado.

```
% java PictureDump 16 6 < abra.txt
```

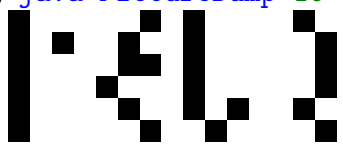

Compressão de genomas

Fonte: A New DNA Sequence Search – Compressive Genomics

Genomas

Genomas são representados por cadeias sobre o alfabeto A, C, G e T.

```
GAATTGCTAGCAATTGTGTCCCCCTCACACTCCCAAATTCGCGGGC
CCACACTCACCGGAGTGGCAAGCTAGCTTAAGTAACGCCACTTTGC
GAAAGTTCAGATCAAGGTCAGGAACAAAGAAACAGCTGAATACCAA
```

Podemos representar cada caractere por 1 byte = 8 bits.

Genomas

O genoma ATAGATGCATAGCGCATAGCTAGATGTGCTAGC usaria $33 \times 8 = 264$ bits

```
% more genomeTiny.txt
ATAGATGCATAGCGCATAGCTAGATGTGCTAGC
```

```
% java BinaryDump 56 < genomeTiny.txt
01000001010101000100000101000111010000010101010001000111
01000011010000010101010001000001010001110100001101000111
01000011010000010101010001000001010001110100001101010100
01000001010001110100000101010100010001110101010001000111
01000011010101000100000101000111010000011
264 bits
```

Genomas

Não precisamos usar 8 bits para representar os caracteres de um alfabeto pequeno.

Podemos usar só 2 bits por caractere:

```
% more genomeTiny.txt
ATAGATGCATAGCGCATAGCTAGATGTGCTAGC
```

```
% java Genome - < genomeTiny.txt | java
BinaryDump 32
00000000000000000000000000100001
00110010000111001001100100100100
11001001110010001110111001110010
01000000
104 bits
```

Genomas

Podemos usar só 2 bits por caractere:

```
% more genomeTiny.txt
ATAGATGCATAGCGCATAGCTAGATGTGCTAGC
```

```
% java Genome - < genomeTiny.txt | java
HexDump 8
00 00 00 21 23 2d 23 74
8d 8c bb 63 40
104 bits
```

Genomas

```
public static void compress() {
   Alphabet DNA = new Alphabet("ACTG");
   int w = DNA.lgR(); // w == 2
   String s = BinaryStdIn.readString();
   int n = s.length();
   BinaryStdOut.write(n);
   for(int i = 0; i < n; i++) {
      int d = DNA.toIndex(s.charAt(i));
      // escreve em 2 bits
      BinaryStdOut.write(d, w);
   }
   BinaryStdOut.close();
}
```

Genomas

```
public static void expand() {
   Alphabet DNA = new Alphabet("ACTG");
   int w = DNA.lgR(); // w == 2
   int n = BinaryStdIn.readInt();
   for (int i = 0; i < n; i++) {
      // leia 2 bits
      char c = BinaryStdIn.readChar(w);
      // escreva um char
      BinaryStdOut.write(DNA.toChar(c));
   }
   BinaryStdOut.close();
}
```

Genomas

Não dá para ver o fluxo de bits diretamente na saída padrão:

```
% java Genome - < genomeTiny.txt
??
```

Compressão seguida de expansão reproduz o fluxo original:

```
% java Genome- < genomeTiny.txt > genomeTiny.2bit
ATAGATGCATAGCGCATAGCTAGATGTGCTAGC
```

```
% java Genome - < genomeTiny.txt | java Genome +
ATAGATGCATAGCGCATAGCTAGATGTGCTAGC
```

Genomas

Virus de verdade, taxa de compressão de 12536/50000 = 0.25:

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

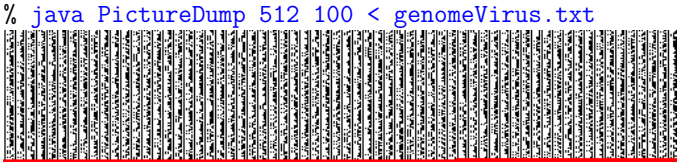

50000 bits

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

12536 bits

Codificação de comprimento de carreira

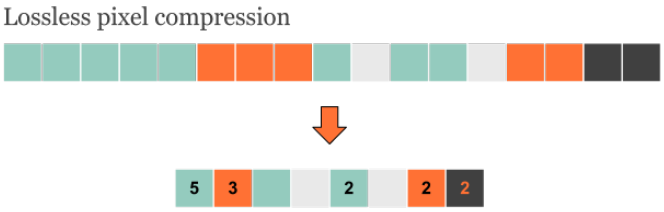

Fonte: Lossy Image Compression with Run-Length Encoding

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):

00001111000000111000001110000 1011

Codificação de comprimento de carreira

Decisões de projeto:

- Use 8 bits (valores de 0 a 255) para cada comprimento de carreira.
- Use carreiras de comprimento 0 para dividir carreiras muito longas em blocos de comprimento menor que 256.
- A primeira carreira é sempre de 0s (e pode ser vazia).

Codificação de comprimento de carreira

Para texto ASCII, a compressão é ruim

Exemplo: "ABRACADABRA!" tem carreiras curtas

```
% java BinaryDump 32 < abra.txt
01000001010000100101001001000001
01000011010000010100010001000001
01000010010100100100000100100001
96 bits
```

Codificação de comprimento de carreira

Para texto ASCII, a compressão é ruim

Exemplo: "ABRACADABRA!" tem carreiras curtas

```
% java RunLength - < abra.txt | java
HexDump 13
01 01 05 01 01 01 04 01 02 01 01 01 02
01 02 01 05 01 01 01 04 02 01 01 05 01
01 01 03 01 03 01 05 01 01 01 04 01 02
01 01 01 02 01 02 01 05 01 02 01 04 01
416 bits
```

Taxa de compressão: 416/96 = 4.33

Codificação de comprimento de carreira

Para mapas de bits (*bitmaps*) é boa

Exemplo: q32x48.bin representa uma letra "q" em 32 por 48 pixels:

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

Codificação de comprimento de carreira

```
% java BinaryDump 32 < q32x48.bin
00000000000000000000000000000000
00000000000000000000000000000000
00000000000000011111110000000000
00000000000011111111111111100000
00000000001111000011111111100000
00000000111100000000011111100000
00000001110000000000001111100000
00000011110000000000001111100000
00000111100000000000001111100000
00001111000000000000001111100000
00001111000000000000001111100000
00011110000000000000001111100000
00011110000000000000001111100000
```

Codificação de comprimento de carreira

```
% java RunLength - < q32x48.bin >
q32x48.bin.rle
% java HexDump 13 < q32x48.bin.rle
4f 07 16 0f 0f 04 04 09 0d 04 09 06 0c
03 0c 05 0b 04 0c 05 0a 04 0d 05 09 04
0e 05 09 04 0e 05 08 04 0f 05 08 04 0f
05 07 05 0f 05 07 05 0f 05 07 05 0f 05
07 05 0f 05 07 05 0f 05 07 05 0f 05 07
05 0f 05 07 05 0f 05 07 06 0e 05 07 06
0e 05 08 06 0d 05 08 06 0d 05 09 06 0c
05 09 07 0b 05 0a 07 0a 05 0b 08 07 06
0c 14 0e 0b 02 05 11 05 05 05 1b 05 1b
05 1b 05 1b 05 1b 05 1b 05 1b 05 1b 05
1b 05 1b 05 1b 05 1a 07 16 0c 13 0e 41
```

Codificação de comprimento de carreira

```
% java RunLength - < q32x48.bin >
q32x48.bin.rle
% java HexDump 0 < q32x48.bin
1536 bits
% java HexDump 0 < q32x48.bin.rle
1144 bits
```

Taxa de compressão: $1144/1536 = 0.74$

Codificação de comprimento de carreira

```
public static void compress() {
   char cnt = 0;
   boolean b, old = false;
   while (!BinaryStdIn.isEmpty()) {
      b = BinaryStdIn.readBoolean();
      if (b != old) {
         BinaryStdOut.write(cnt);
         cnt = 0;
         old = !old;
      }
```

Codificação de comprimento de carreira

```
      else {
         if (cnt == 255) {
            BinaryStdOut.write(cnt);
            cnt = 0;
            BinaryStdOut.write(cnt);
         }
      }
      cnt++;
   }
   BinaryStdOut.write(cnt);
   BinaryStdOut.close();
}
```

Codificação de comprimento de carreira

```
public static void expand() {
   boolean b = false;
   while(!BinaryStdIn.isEmpty()) {
      // comprimento de uma carreira
      char cnt=BinaryStdIn.readChar();
      for (int i = 0; i < cnt; i++)
         // sai um único bit
         BinaryStdOut.write(b);
      b = !b;
   }
   BinaryStdOut.close();
}
```

Codificação de comprimento de carreira

Para mapas de bits a taxa de compressão diminui linearmente com o aumento da resolução!

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

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

Codificação de comprimento de carreira

Para mapas de bits a taxa de compressão diminui linearmente com o aumento da resolução!

```
% java PictureDump 64 96 < q64x96.bin
6144 bits
```

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