

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**: ababababababababababababab

arquivo **menor**: 12ab

Por que comprimir?

Menor espaço de armazenamento.

Menor tempo de transmissão.

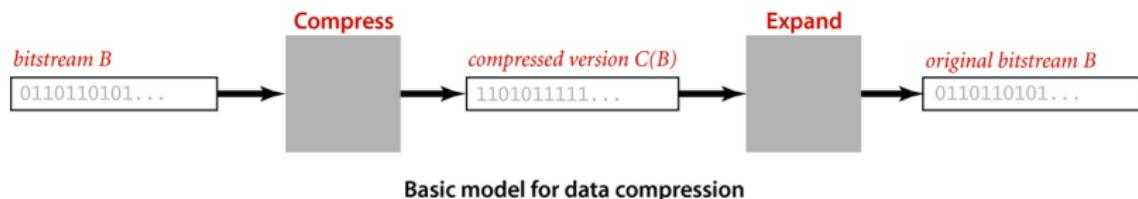
Software: gzip, bzip, 7z, etc.

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 .



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.

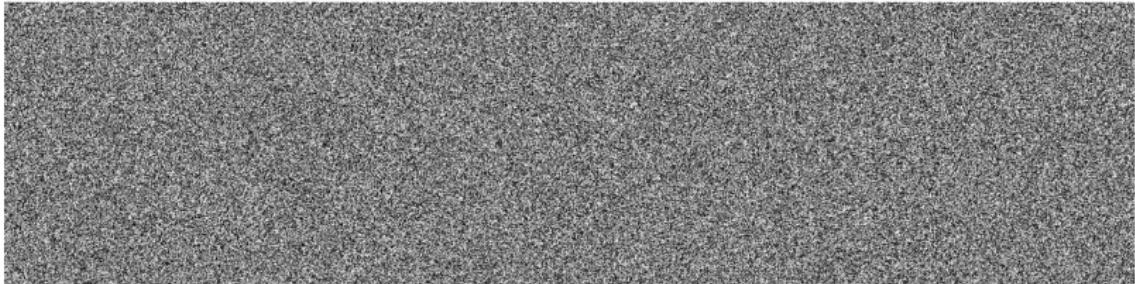
Mesmo fluxos pseudo-aleatórios podem ser difíceis de comprimir.

Considerações teóricas

Muitos fluxos de bits **parecem aleatórios** mas não são.

Exemplo: o fluxo de bits parece aleatório...

```
% java RandomBits | java PictureDump 2000 500
```



1000000 bits

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:

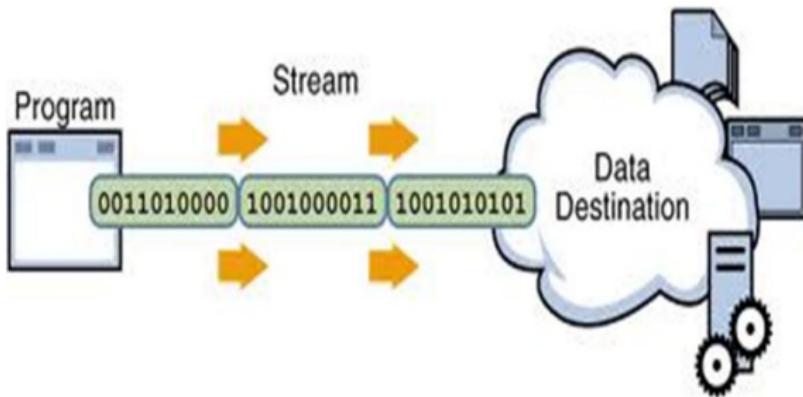
$$4 \left(\sum_{i=0}^{\infty} (-1)^i \left(\frac{1}{2i+1} \right) \right)$$

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 ($=\textit{bitstring}$) é uma sequência de bits:

11000100000111010101001111011001110001010000

1100000000001111110000011101000111

fluxo de bits ($=\textit{bitstream}$) 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 booleana correspondente
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()	fecha 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 = 10×8 bits

Exemplo... continuação

Representação de datas, como 15/05/2018.

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

000000000000000000000000000000001111 32 bits
00000000000000000000000000000000101 32 bits
0000000000000000000000000000000011111100010 32 bits
96 bits

representação: 3 ints = 3×32 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 converte 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.

GAATTGCTAGCAATTGTGTCCCCCTCACACTCCCAAATTCGCGGG
CCACACTCACCGGAGTGGCAAGCTAGCTTAAGTAACGCCACTTG
GAAAGTTCAGATCAAGGTCAGGAACAAAGAACAGCTGAATACCA

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
0100000101000111010000010101010001000111010101010001000111
0100001101010001000001010001110100001101000111

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
```

```
0000000000000000000000000000000100001
```

```
00110010001110010011001001100100100
```

```
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  
??
```

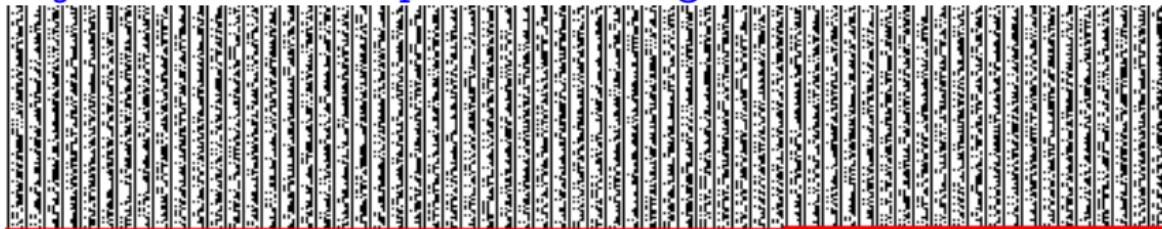
Compressão seguida de expansão reproduz o fluxo original:

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

Genomas

Vírus de verdade, taxa de compressão de
 $12536/50000 = 0.25$:

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



50000 bits

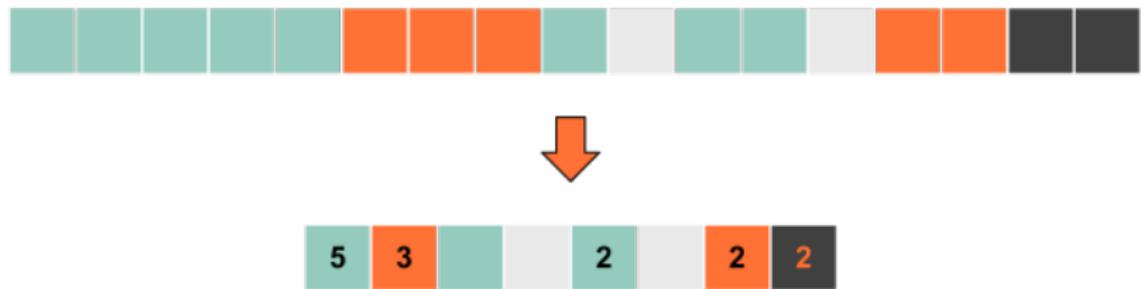
```
% java Genome - < genomeVirus.txt | java  
PictureDump 512 25
```



12536 bits

Codificação de comprimento de carreira

Lossless pixel compression



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:

00000000000000001111111000000011111111111

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

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
```

```
00000000000000001111111000000000
```

```
000000000000000011111111111111100000
```

```
000000000000111100001111111111100000
```

```
000000000111100000000000111111000000
```

```
0000000001110000000000000011111000000
```

```
000000000111100000000000000011111000000
```

```
000000000111100000000000000011111000000
```

```
000000000111100000000000000011111000000
```

```
000000000111100000000000000011111000000
```

```
000000000111100000000000000011111000000
```

```
000000000111100000000000000011111000000
```

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	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
```