

# Estruturas de Dados

## Aula 19 — Compressão de Dados

---

Prof Ana Carolina Sokolonski

Bacharelado em Sistemas de Informação

Instituto Federal da Bahia — Campus Feira de Santana

2026



O que é Compressão de Dados?

Algoritmo de Huffman

Aplicações

Exercícios

# O que é Compressão de Dados?

Representar a mesma informação com menos bits

## ▪ Cenário

Um texto usa um alfabeto de símbolos com **frequências desiguais**. A codificação padrão (ex.: ASCII, 8 bits/caractere) gasta o mesmo número de bits para símbolos raros e frequentes.

## ▪ Ideia central

Atribuir códigos **mais curtos** a símbolos **mais frequentes** e códigos **mais longos** a símbolos raros – reduzindo o tamanho médio em bits.

## ▪ Codificação de tamanho fixo

Com 5 símbolos distintos, um código de tamanho fixo precisa de  $\lceil \log_2 5 \rceil = 3$  bits por símbolo – mesmo que um deles apareça 50% das vezes.

## ▪ Origem

Proposta por David A. Huffman em 1952, ainda estudante de doutorado no MIT, como resposta a um trabalho da disciplina de teoria da informação.

## ▪ Definição

Um código de prefixo é um esquema de codificação em que **nenhum** código é prefixo de outro código. Isso garante que a sequência de bits pode ser decodificada **sem ambiguidade**, sem precisar de separadores.

## ▪ Sem essa propriedade...

Se  $A = 0$  e  $B = 01$ , a sequência 01 pode significar AB ou apenas B – ambíguo!

## ▪ Árvore binária → código

Qualquer **árvore binária** cujas folhas são os símbolos define naturalmente um código de prefixo: o código de um símbolo é o caminho raiz→folha (0 = esquerda, 1 = direita).

## ▪ Vantagem

Decodificação simples: percorrer a árvore bit a bit até atingir uma folha, emitir o símbolo, voltar à raiz.

# Algoritmo de Huffman

Construção via fila de prioridade

## ▪ Algoritmo guloso

- 1 Criar um nó-folha para cada símbolo, com peso = sua frequência.
- 2 Inserir todos os nós em uma **fila de prioridade (min-heap)**, ordenada por peso.
- 3 Repetir até restar um único nó:
  - 1 Remover os **dois** nós de menor peso.
  - 2 Criar um novo nó interno, com esses dois como filhos e peso = soma dos pesos.
  - 3 Inserir o novo nó na fila.
- 4 O nó restante é a **raiz** da árvore de Huffman.

## ▪ Por que sempre os dois menores?

Combinar os dois símbolos menos frequentes garante que eles fiquem nas posições **mais profundas** da árvore (códigos mais longos), enquanto os mais frequentes ficam perto da raiz (códigos mais curtos).

## ▪ Complexidade

Com  $n$  símbolos: cada remoção/inserção no heap custa  $\mathcal{O}(\log n)$ , repetida  $n - 1$  vezes  $\Rightarrow \mathcal{O}(n \log n)$  no total.


# Construção da Árvore: Exemplo

## ■ Frequências

| Símbolo | Freq. |
|---------|-------|
| A       | 5     |
| B       | 9     |
| C       | 12    |
| D       | 13    |
| E       | 16    |
| F       | 45    |

Exemplo clássico (Cormen et al.) com 6 símbolos e total de 100 ocorrências.

## Árvore de Huffman resultante



## ■ Campos do nó

Cada nó guarda o símbolo (apenas em folhas), o peso (frequência acumulada) e ponteiros para os dois filhos.

## ■ Folha vs. nó interno

Uma **folha** representa um símbolo original; um **nó interno** (criado durante a fusão) tem peso = soma dos pesos dos filhos e símbolo indefinido ('\\0').

```
1 typedef struct HNo {
2     char simbolo; //válido se é folha
3     int peso;
4     struct HNo *esq, *dir;
5 } HNo;
6
7 HNo* criarFolha(char simbolo, int peso){
8     HNo *no = (HNo*)malloc(sizeof(HNo));
9     no->simbolo = simbolo;
10    no->peso = peso;
11    no->esq = no->dir = NULL;
12    return no;
13 }
```

## ■ Fila de prioridade

Implementada como **min-heap**: o nó de menor peso fica sempre acessível em  $\mathcal{O}(1)$ , e inserir/remover custa  $\mathcal{O}(\log n)$ .

## ■ Criando um nó interno

Ao combinar dois nós (os de menor peso da fila), cria-se um novo nó interno cujo peso é a soma dos pesos dos dois filhos.

```
1 HNo* criarInterno(HNo *esq, HNo *dir){
2     HNo *no = (HNo*) malloc(sizeof(HNo));
3     no->simbolo = '\0';
4     no->peso = esq->peso + dir->peso;
5     no->esq = esq;
6     no->dir = dir;
7     return no;
8 }
```

## ■ Passo a passo

Usando um min-heap (MinHeap) já populado com uma folha por símbolo: enquanto houver mais de um nó na fila, remover os dois de menor peso e inserir o nó interno combinado.

## ■ Caso especial

Se houver apenas **um símbolo** distinto, é preciso tratar separadamente (a árvore teria só uma folha, sem código bem definido).

```
1 HNo* construirHuffman(MinHeap *fila){
2     while (heapTamanho(fila) > 1) {
3         HNo *esq = heapRemoverMin(fila);
4         HNo *dir = heapRemoverMin(fila);
5         HNo *interno=criarInterno(esq,dir);
6         heapInserir(fila, interno);
7     }
8     return heapRemoverMin(fila); //raiz
9 }
```

## ■ Percurso da árvore

Após construída a árvore, percorrer recursivamente acumulando os bits do caminho: 0 ao ir para a esquerda, 1 ao ir para a direita. Ao atingir uma **folha**, o código acumulado é o do símbolo correspondente.

## ■ Complexidade

$\mathcal{O}(n)$  nós visitados, gerando  $n$  códigos – cada código tem, no máximo,  $\mathcal{O}(n)$  bits no pior caso (árvore degenerada).

```
1 void gerarCodigos(HNo *no, char *codigo, int
   profundidade) {
2     if(no->esq==NULL && no->dir==NULL){
3         codigo[profundidade] = '\0';
4         printf("%c: %s\n", no->simbolo, codigo);
5         return;
6     }
7     codigo[profundidade] = '0';
8     gerarCodigos(no->esq, codigo, profundidade+1);
9     codigo[profundidade] = '1';
10    gerarCodigos(no->dir, codigo, profundidade+1);
11 }
```

# Aplicações

Compactação de arquivos e texto

## ■ Formatos que usam Huffman

- **DEFLATE** (usado em ZIP, gzip, PNG): combina LZ77 com Huffman para comprimir os resultados.
- **JPEG**: usa Huffman na etapa final, depois da transformada DCT e quantização.
- **MP3 e outros codecs**: aplicam codificação de entropia semelhante à dos coeficientes já processados.

## ■ Taxa de compressão

O ganho depende de quão **desigual** é a distribuição de frequências: textos com poucos caracteres muito frequentes comprimem melhor do que dados aleatórios ou uniformes já existentes.

## ■ Limite teórico

Pelo **teorema da fonte de Shannon**, a entropia  $H$  da fonte é o limite inferior do número médio de bits por símbolo; Huffman se aproxima desse limite (é ótimo entre códigos de prefixo, mas não atinge  $H$  exatamente quando as probabilidades não são potências de  $1/2$ ).

## ▪ Huffman estático

Lê todo o arquivo, conta as frequências, constrói **uma** árvore e a usa para todo o arquivo. A árvore (ou tabela de códigos) precisa ser **armazenada** junto com os dados comprimidos, para a decodificação.

## ▪ Huffman adaptativo

Atualiza a árvore **durante** a codificação, conforme novos símbolos são lidos – não precisa transmitir a árvore, mas é mais complexo de implementar (ex.: algoritmo de Vitter).

## ▪ Comparação com outras técnicas de compressão

Huffman comprime por **frequência de símbolos individuais** (codificação de entropia). Técnicas como **LZ77/LZ78** exploram **repetições de trechos** (substrings) – por isso os formatos modernos (DEFLATE, LZMA) combinam ambas as ideias.

# Exercícios

Pratique Huffman

- 1 **Construção manual:** Dadas as frequências A:2, B:3, C:4, D:5, E:9, construa a árvore de Huffman passo a passo (mostrando o estado da fila de prioridade a cada iteração) e escreva o código binário de cada símbolo.
- 2 **Tamanho comprimido:** Usando os códigos do exercício anterior, calcule o número total de bits necessários para codificar a string "ABCDE" repetida conforme as frequências acima, e compare com a codificação de tamanho fixo (3 bits/símbolo).
- 3 **Implementação – decodificar Huffman:** Implemente uma função que recebe a raiz da árvore de Huffman e uma sequência de bits (string de '0's e '1's) e retorna a string decodificada.
- 4 **Análise:** Explique por que a árvore de Huffman, embora ótima entre códigos de prefixo, não é necessariamente única: dê um exemplo de frequências em que existam duas árvores de Huffman válidas e igualmente ótimas.

# Fim da Aula 19

Dúvidas e próximos passos

## ■ Resumo da aula

- **Compressão:** símbolos frequentes ganham códigos mais curtos
- **Código de prefixo:** decodificação sem ambiguidade
- **Huffman:** algoritmo guloso, construção via min-heap,  $\mathcal{O}(n \log n)$
- **Ótimo** entre códigos de prefixo (não necessariamente único)
- **Aplicações:** ZIP/gzip/PNG (DEFLATE), JPEG, MP3
- **Estático vs. adaptativo;** combinação com LZ77/LZ78 nos formatos modernos

[carolsoko@ifba.edu.br](mailto:carolsoko@ifba.edu.br)

Dúvidas? Mande uma mensagem!