

Projeto e Análise de Algoritmos (PAA)

Código de Huffman

Roteiro para projetar um algoritmo guloso:

- Compreender o problema
- Propor estratégias/critérios gulosos
- Resolver exemplos usando essas estratégias
- Selecionar a estratégia mais promissora
- Escrever o pseudocódigo do algoritmo
- Analisar a eficiência do algoritmo
- Provar a corretude do critério guloso

Códigos Binários de Comprimento Fixo

- mapeiam cada símbolo de um alfabeto Σ p/ uma seq. de K bits

Exemplo: $a = 00, b = 01, c = 10, d = 11$ e $K = 2$

Decodificar: $011000011110 \Rightarrow b c a b d e$

⊗ Quiz: qual o valor mínimo de K em função de Σ ? $|\Sigma| \leq 2^K$, por exemplo

Se K já é mínimo, é possível economizar mais? $K = 5$ p/ o alfabeto latino

Comprimento Variável e Ambiguidade

- a ideia é usar menos bits p/ caracteres muito frequentes
- mas alguns cuidados são necessários

Exemplo: considere a seguinte codificação $a = 0, b = 01, c = 10, d = 1$

Tente decodificar: $001 \rightarrow ab$

$\left. \begin{array}{l} \text{ou} \\ \rightarrow aad \end{array} \right\} ?$

⊗ Quiz: como evitar ambiguidade?

Códigos Livres de Prefixo

- com comprimento variável não dá p/ contar K bits
p/ saber o fim de um caracté
- a solução p/ ambiguidade é que o código de um caracté não pode ser prefixo do código de outro

Não exemplo: $a = \underline{0}$ e $b = \underline{0}1$ é proibido

Exemplo $a = 0$, $b = 10$, $c = 110$, $d = 111$

Caracté	Freq
a	60%
b	25%
c	10%
d	5%

⊗ Quiz: qual o comprimento por caracté no código fixo? R.: 2 bits


⊗ Quiz: e o comp. médio do código variável?

$$R.: 0,6 \cdot 1 + 0,25 \cdot 2 + 0,1 \cdot 3 + 0,05 \cdot 3 = 1,55 \text{ bits}$$
$$0,6 + 0,5 + 0,3 + 0,15$$


Relação entre Códigos e Árvores

- Para cada código binário tem uma árvore binária correspondente, e vice-versa


Exemplo 1: $a = 00$, $b = 01$, $c = 10$, $d = 11$



Exemplo 2: $a = 0$, $b = 01$, $c = 10$, $d = 1$



Exemplo 3: $a = 0$, $b = 10$, $c = 110$, $d = 111$



- O caminho da raiz até o caracté corresponde ao código (esq. = 0 e dir. = 1)

⊗ Q: qual característica deve ter uma árvore que corresponde a um código livre de prefixo? R: caracteres são folhas

Problema de Compressão

Entrada: Alfabeto Σ e frequências/probabilidades $p_i \geq 0$ p/ cada $i \in \Sigma$

Seja T uma árvore binária que codifica Σ

O custo médio de T é $L(T) = \sum_{i \in \Sigma} p_i \cdot h_i$

→ prof. de i em T
= # de bits do código de i

Solução: T c/ menor custo médio

Estratégias Gulosas

- ideia 1: pegam maior freq. e colocam no menor código disponível ✗

Exemplo 1: $p_a = 0,6$; $p_b = 0,25$; $p_c = 0,10$; $p_d = 0,5$
 $a = 0$ $b = 10$ $c = 110$ $d = 111$ → $L(1) = 1,55$

Exemplo 2: $p_a = 0,3$; $p_b = 0,25$; $p_c = 0,24$; $p_d = 0,21$

$$L(2) = 0,3 \cdot 1 + 0,25 \cdot 2 + 0,24 \cdot 3 + 0,21 \cdot 3 = 2,15 > 2 \text{ (cap. fixo)}$$

$0,3$ $0,75$ $0,45 \cdot 3 = 1,35$

Estratégias Gulosas (Cont.)

Voltando a pensar na árvore, unir (mesclar) dois nós e adicionar 1 bit ao código de cada um.





- Assim, a questão é: quem é seguro para unir?

importante




Importante p/ recurso !!!

ideia 2: ir de baixo p/ cima "mesclando" nós com menor freq.

Exemplo 1: $p_a = 0,6$; $p_b = 0,25$; $p_c = 0,10$; $p_d = 0,5$



Exemplo 2: $p_a = 0,3$; $p_b = 0,25$; $p_c = 0,24$; $p_d = 0,21$



Essa estratégia parece promissora :) !!!

Subproblema Recursivo


- Estrutura recursiva do alg.:

- "mescl" os dois símbolos u e v c/ suas frequências
- novo símbolo u/v tem freq. $p_u + p_v$
- resolve recursivamente o subprob. c/ 1 símbolo a menos

Exemplo  *Quiz*: qual o caso base da recursão?

Algoritmo de Huffman

Huffman Rec(Σ , p):

se $|\Sigma| = 2$: devolva , e/ $a, b \in \Sigma$


Seja a e b o par de símbolos e/ menor freqs p_a, p_b

Mesde a e b em $a|b$ e/ freq. $p_a + p_b$

Seja $\Sigma' = \Sigma - \{a, b\} + \{a|b\}$

$T' = \text{Huffman Rec}(\Sigma', p')$

Transforme T' em T expandindo $a|b$ em



Devolva T



* Note que $a|b$ é folha em T' ;

mas $\bar{n}$ necessariamente do último nível

Exemplo

a b c d e f
3 2 6 8 2 6

a	b	c	d	e	f
3	2	6	8	2	6


a	b e	c	d	f
3	2+2=4	6	8	6

a b e	c	d	f
3+4=7	6	8	6

a b e	c f	d
7	6+6=12	8

a b e d	c f
7+8=15	12

Na volta
da recursão




Prova de Corretude do Algoritmo

Teorema: O alg. de Huffman produz uma árvore T de custo $L(T)$ mínimo p/ Σ max folhas

Prova por indução em $n = |\Sigma|$

$$L(T) = \sum_{i \in \Sigma} p_i \cdot h_i$$

Base: $n=2$ a única árvore possível é 

H.I.: T' produzida p/ Σ' que tem $n-1$ símbolos é ótima

Passo Indutivo

Seja $\Sigma' = \Sigma - \{a, b\} + \{a|b\}$ c/ a, b tendo freq. mínima em Σ

Observe que $L(T) - L(T') = p_a \cdot h_a^T + p_b \cdot h_b^T - (p_a + p_b) \cdot h_{a|b}^{T'}$



Prof. de a em T = Prof. de b em T = $1 + \text{Prof. de } a|b \text{ em } T'$

$$= p_a + p_b \quad \text{e esse resultado vale p/ qualquer } T'$$



Prova do Lema Central

Note que, pela H.I. a chamada recursiva devolve T' ótima p/ Σ' . Por isso, T obtida de T' é de custo mínimo dentre as árvores em que a e b são irmãos. ⊗ decorre do resultado

} $L(T) - L(T') = p_a + p_b$ p/ qualquer T'

[Resta analisar o caso em que a e b não são irmãos numa árvore ótima T^*]

Vamos usar um argumento de troca, i.e., sendo x e y irmãos do nível mais baixo de T^* , troque x e a e y e b .



$$L(\hat{T}) - L(T^*) = p_a(h_x - h_a) + p_x(h_a - h_x) + p_b(h_y - h_b) + p_y(h_b - h_y)$$

$$= (p_a - p_x)(h_x - h_a) + (p_b - p_y)(h_y - h_b)$$

≥ 0 ≤ 0 ≥ 0 ≤ 0

[Logo, sempre temos árvore ótima c/ a e b irmãos]

Prova do Teorema

Como sempre existe uma árvore ótima em que os dois símbolos menos frequentes ^{a e b} são irmãos, e T gerada a partir de T' é uma árvore de custo mínimo p/ Σ dentre as que tem a e b sendo irmãos, temos que T é uma árvore ótima.

Eficiência de Diferentes Implementações

- Implementação básica tem n chamadas recursivas (ou iterações) e trab. local $\Theta(n)$ p/ encontrar os dois símbolos menos frequentes em cada passo. Logo é $\Theta(n^2)$
- Usando heap de mínimo p/ manter os símbolos da p/ fazer em tempo $\Theta(n \log n)$

⊛ Quiz: Também dá p/ fazer ordenando no início e usando 2 filas ou 2 listas. Como???