

# Algoritmos Probabilísticos

Neste capítulo vamos supor que temos à nossa disposição um gerador de *bits* aleatórios (*random bits generator*), ou seja, um algoritmo ideal **RAND** que recebe um número racional  $\rho$  no intervalo fechado  $[0, 1]$ , devolve 1 com probabilidade  $\rho$  e 0 com probabilidade  $1 - \rho$ . Existem implementações aproximadas do algoritmo **RAND** (veja Knuth [Knu98]).

Um algoritmo que utiliza **RAND** é chamado de **probabilístico** (*randomized*). O comportamento de um algoritmo probabilístico depende não apenas da instância do problema mas também dos números devolvidos por **RAND**. Dizemos que um algoritmo probabilístico é **polinomial** se existe um polinômio  $p$  tal que, para toda instância  $I$  do problema, o número de chamadas ao algoritmo **RAND** e o consumo de tempo das demais operações são limitados por  $p(|I|)$ .

Vamos generalizar a definição de algoritmos de aproximação (seção 1.2) para englobar algoritmos probabilísticos. Considere um algoritmo probabilístico  $A$  para um problema de otimização. Para qualquer instância  $I$  do problema, seja  $X_I$  a **variável aleatória** (apêndice D) cujo valor é o valor da solução produzida por  $A$  para esta instância<sup>1</sup>. Dizemos que  $A$  é uma  **$\alpha$ -aproximação probabilística** para o problema em questão se  $\mathbf{E}[X_I] \geq \alpha \text{opt}(I)$  no caso de problema de maximização e  $\mathbf{E}[X_I] \leq \alpha \text{opt}(I)$  no caso de problema de minimização. No presente capítulo,  $\alpha$  é um número que não depende de  $I$ , embora em geral  $\alpha$  possa

<sup>1</sup> Os algoritmos abordados neste capítulo, para cada instância do problema, provocam um número fixo  $t$  de chamadas de **RAND**, que não depende dos valores devolvidos por **RAND**, sendo que a  $i$ -ésima chamada de **RAND** tem como parâmetro sempre um mesmo número, digamos  $\rho_i$ . Denotando por  $\Omega$  o conjunto  $\{0, 1\}$ , seja  $\mathcal{P}_i$  a medida de probabilidade sobre  $\Omega$  dada por  $\mathcal{P}_i(1) = \rho_i$  e  $\mathcal{P}_i(0) = 1 - \rho_i$ . O espaço de probabilidade no qual  $X_I$  está definida neste caso é o espaço produto  $(\Omega, \mathcal{P}_1) \times \dots \times (\Omega, \mathcal{P}_t)$ .

ser uma função de  $I$ . Dizemos que  $\alpha$  é uma **razão de aproximação esperada** de  $A$ .

Vamos mostrar que, em certas condições, uma  $\alpha$ -aproximação probabilística  $A$  pode ser usada para produzir, com alta probabilidade, soluções aproximadas do problema. Suponha que o problema é de minimização e que a variável aleatória  $X_I$  não assume valores negativos (esse é o caso na grande maioria dos problemas combinatórios). Para cada  $\varepsilon$  positivo, a **desigualdade de Markov** (lema D.1, apêndice D) garante que

$$\Pr[X_I \geq (\alpha + \varepsilon)\text{opt}(I)] \leq \frac{\mathbf{E}[X_I]}{(\alpha + \varepsilon)\text{opt}(I)} \leq \frac{\alpha \text{opt}(I)}{(\alpha + \varepsilon)\text{opt}(I)} = \frac{\alpha}{\alpha + \varepsilon}.$$

Para um dado  $\lambda$  no intervalo aberto  $(0, 1)$ , seja  $k := \lceil \log_{\beta} \lambda \rceil$ , onde  $\beta = \frac{\alpha}{\alpha + \varepsilon}$ . Suponha que  $A$  é **aplicado  $k$  vezes** à instância  $I$  e escolha o resultado de menor valor. Se  $Y_I$  é esse menor valor<sup>2</sup>, então  $\Pr[Y_I \geq (\alpha + \varepsilon)\text{opt}(I)] \leq \lambda$ . Para  $\lambda$  pequeno, este esquema produz, portanto, com probabilidade alta (pelo menos  $1 - \lambda$ ), uma solução viável com valor menor que  $(\alpha + \varepsilon)\text{opt}(I)$ .

O mesmo raciocínio pode ser aplicado a problemas de maximização, desde que se conheça uma delimitação superior para o valor ótimo do problema.

## 6.1 Satisfatibilidade máxima

Vamos usar o problema da satisfatibilidade máxima para exemplificar algoritmos probabilísticos. Para definir o problema, precisamos introduzir alguma notação.

Suponha dado um conjunto finito  $V$  de objetos que chamamos **variáveis**. Uma **cláusula booleana** sobre  $V$ , ou simplesmente **cláusula**, é um par ordenado de subconjuntos de  $V$  disjuntos, um dos quais pelo menos não é vazio. Se  $C$  é uma cláusula, denotamos o primeiro componente de  $C$  por  $C_1$  e o segundo por  $C_0$ . Em terminologia tradicional,  $C_0$  é o conjunto das variáveis “complementadas” e  $C_1$  é o conjunto das variáveis “não-complementadas”. O **número de variáveis** em uma cláusula  $C$  é  $|C_1| + |C_0|$ .

<sup>2</sup>  $Y_I$  é uma variável aleatória. Denotando por  $(\Omega', \mathcal{P}')$  o espaço de probabilidade de  $X_I$ , o espaço no qual  $Y_I$  está definida é o produto  $(\Omega', \mathcal{P}') \times \dots \times (\Omega', \mathcal{P}')$  de  $k$  cópias de  $(\Omega', \mathcal{P}')$ .

A probabilidade das  $k$  aplicações serem  $> (\alpha + \varepsilon) \cdot \text{opt}$  é pequena:  $\leq \beta^k$

Uma **valoração** das variáveis de  $V$  é um vetor  $x$  indexado por  $V$  com valores em  $\{0, 1\}$ . Uma valoração  $x$  **satisfaz** uma cláusula  $C$  se  $x_v = 1$  para algum  $v$  em  $C_1$  ou  $x_v = 0$  para algum  $v$  em  $C_0$ .

Vejamos um exemplo. Suponha que  $V = \{a, b, c, d\}$  e sejam  $C$ ,  $D$  e  $E$  as cláusulas  $(\{a, d\}, \{b\})$ ,  $(\{c\}, \{a, b\})$  e  $(\emptyset, \{b, c, d\})$ . Na notação tradicional, a coleção  $\{C, D, E\}$  seria denotada por  $\{a \vee d \vee \bar{b}, c \vee \bar{a} \vee \bar{b}, \bar{b} \vee \bar{c} \vee \bar{d}\}$ .

O **problema da satisfatibilidade máxima** (*maximum satisfiability problem*), denotado pela sigla MAXSAT, consiste no seguinte:

**Problema MAXSAT**  $(V, \mathcal{C})$ : Dada uma coleção  $\mathcal{C}$  de cláusulas sobre um conjunto  $V$  de variáveis, encontrar uma valoração  $x$  de  $V$  que satisfaça o maior número possível de cláusulas de  $\mathcal{C}$ .

O problema é NP-difícil mesmo quando cada cláusula em  $\mathcal{C}$  tem duas variáveis [GJ79].

O problema 2SAT de decisão é polinomial, mas o problema de maximização Max2SAT é NP-Difícil

### Algoritmo de Johnson

Eis um algoritmo probabilístico para o problema MAXSAT. O algoritmo é atribuído a Johnson [Joh74]. Ele é tão simples que ignora  $\mathcal{C}$ :

#### Algoritmo MAXSAT-JOHNSON $(V)$

- 1 para cada  $v$  em  $V$  faça
- 2      $\hat{x}_v \leftarrow \text{RAND}(\frac{1}{2})$
- 3 devolva  $\hat{x}$

Verdadeiro, com probabilidade 1/2

No algoritmo acima, o número de chamadas a RAND e o consumo de tempo das demais operações é  $O(|V|)$ . Seja  $X_{\mathcal{C}}$  a variável aleatória cujo valor é o número de cláusulas de  $\mathcal{C}$  satisfeitas por uma valoração produzida por MAXSAT-JOHNSON  $(V)$ . O espaço de probabilidade de  $X_{\mathcal{C}}$  é o espaço produto  $(\Omega, \mathcal{P}) \times \cdots \times (\Omega, \mathcal{P})$ , onde  $(\Omega, \mathcal{P})$  aparece  $|V|$  vezes no produto,  $\Omega$  é o conjunto  $\{0, 1\}$  e  $\mathcal{P}$  é a medida de probabilidade sobre  $\Omega$  dada por  $\mathcal{P}(1) = \mathcal{P}(0) = \frac{1}{2}$ .

pelo menos  $k$  variáveis em cada cláusula

**Teorema 6.1:** Se  $(V, \mathcal{C})$  é uma instância do problema MAXSAT na qual cada cláusula tem pelo menos  $k$  variáveis e  $X_{\mathcal{C}}$  é a variável aleatória acima definida, então

$$\mathbf{E}[X_{\mathcal{C}}] \geq \left(1 - \frac{1}{2^k}\right) \text{opt}(V, \mathcal{C}).$$

**Demonstração:** Para cada cláusula  $C$ , defina uma variável aleatória  $Z_C$  da seguinte maneira:  $Z_C := 1$  se a valoração produzida pelo algoritmo satisfaz  $C$  e  $Z_C := 0$  em caso contrário. Como  $C$  tem pelo menos  $k$  variáveis e no algoritmo  $x_v$  é 0 com probabilidade  $1/2$ , a probabilidade do evento  $[Z_C=0]$  é no máximo  $1/2^k$  e a probabilidade do evento  $[Z_C=1]$  é pelo menos  $1 - 1/2^k$ . Portanto, como  $X_{\mathcal{C}}$  é a soma das variáveis aleatórias  $Z_C$ ,

$$E[X_{\mathcal{C}}] = E[\sum_C Z_C] = \sum_C E[Z_C] \geq (1 - \frac{1}{2^k})|\mathcal{C}|$$

e concluímos a prova do teorema, já que  $\text{opt}(V, \mathcal{C}) \leq |\mathcal{C}|$ .  $\square$

Como todas as cláusulas em  $\mathcal{C}$  têm pelo menos uma variável, podemos aplicar o teorema acima a  $(V, \mathcal{C})$  com  $k = 1$  e concluir o seguinte resultado.

**Teorema 6.2:** O algoritmo MAXSAT-JOHNSON é uma 0,5-aproximação probabilística polinomial para o MAXSAT.

Seria melhor sem Cláusulas de tamanho 1. Melhoria: assumir que não há duas cláusulas de tam. 1 com X e seu complem. Se um literal está numa cláusula de tam. 1, atribua V com prob.  $h > 1/2$ . Para demais variáveis atribua V com prob.  $h > 1/2$ .

Cláusula C qualquer. Se tam. 1, prob. ser V é h. Se tam.  $k > 1$ , a prob. de ser V é 1-prob de ser F, que é 1-prob. de todos seus literais F. Como  $h > 1-h$ , essa prob. é  $\geq 1-h^k \geq 1-h^2$ .

Tomando h tal que  $h=1-h^2$ , temos:  $h = 1-h^2 = 0,618$

### Algoritmo do arredondamento probabilístico

Descrevemos a seguir um algoritmo de aproximação para o problema MAXSAT que envolve o “arredondamento probabilístico” (*randomized rounding*) de uma solução ótima de um programa linear. O **arredondamento probabilístico** de um número  $\rho$  do intervalo aberto  $(0, 1)$  consiste em arredondar  $\rho$  “para cima” com probabilidade  $\rho$  e “para baixo” com probabilidade  $1 - \rho$ .

Considere o seguinte problema de **programação linear**: dada uma coleção  $\mathcal{C}$  de cláusulas sobre um conjunto  $V$ , encontrar um par  $(x, z)$  de vetores, com  $x$  indexado por  $V$  e  $z$  indexado por  $\mathcal{C}$ , que

Relaxação de um modelo de Programação Inteira exato para MaxSAT

$z_C = 1$  (cláusula satisfeita)  
 $z_C = 0$  (cláusula não sat.)  
 $x_v = 1$  (variável com valor V)  
 $x_v = 0$  (variável com valor F)

Maximizar o número de cláusulas satisfeitas

maximize  $\sum_{C \in \mathcal{C}} z_C$   
 sob as restrições

Se a cláusula é satisfeita, a soma dos valores de seus literais é  $\geq 1$

$$\sum_{v \in C_0} (1 - x_v) + \sum_{v \in C_1} x_v \geq z_C \quad \text{para cada } C \text{ em } \mathcal{C},$$

$$0 \leq z_C \leq 1 \quad \text{para cada } C \text{ em } \mathcal{C},$$

$$0 \leq x_v \leq 1 \quad \text{para cada } v \text{ em } V.$$

(6.1)

Note a seguinte relação entre este programa linear e o problema MAXSAT. Suponha que temos uma solução ótima  $x^*$  do MAXSAT  $(V, \mathcal{C})$ . Para cada cláusula  $C$  em  $\mathcal{C}$ , faça  $z_C^* := 1$  se  $x^*$  satisfaz  $C$  e  $z_C^* := 0$  em caso

contrário. É claro então que o par  $(x^*, z^*)$  é uma solução viável de (6.1) e o valor dessa solução é igual ao número de cláusulas de  $\mathcal{C}$  satisfeitas por  $x^*$ . Portanto, o programa linear (6.1) é uma relaxação do problema  $\text{MAXSAT}(V, \mathcal{C})$  e

Sendo uma relaxação, sem a restrição de valores inteiros, o valor retornado será maior

$$\sum_C \hat{z}_C \geq \text{opt}(V, \mathcal{C}), \quad (6.2)$$

para qualquer solução ótima  $(\hat{x}, \hat{z})$  de (6.1).

O seguinte algoritmo de arredondamento probabilístico, desenvolvido por Goemans e Williamson [GW94], é um algoritmo de aproximação para o  $\text{MAXSAT}$ .

**Algoritmo  $\text{MAXSAT-GW}(V, \mathcal{C})$**

- 1 seja  $(\hat{x}, \hat{z})$  uma solução ótima racional de (6.1)
- 2 para cada  $v$  em  $V$  faça
- 3      $\hat{x}_v \leftarrow \text{RAND}(\hat{x}_v)$
- 4 devolva  $\hat{x}$

Obtido da Programação Linear, com valores racionais

Verdadeiro, com probabilidade  $\hat{x}_v$

O algoritmo acima pode ser implementado de modo que a execução da linha 1 consuma tempo limitado por um polinômio em  $|V|$  e  $|\mathcal{C}|$ , e produza uma solução ótima racional  $(\hat{x}, \hat{z})$  com o tamanho de  $\hat{x}$  e  $\hat{z}$  limitados por um polinômio em  $|V|$  e  $|\mathcal{C}|$  (fato C.4, apêndice C). Como, além disso, o número de chamadas a  $\text{RAND}$  é  $|V|$ , o algoritmo  $\text{MaxSat-GW}$  é um algoritmo probabilístico polinomial.

**Teorema 6.3:** Se  $(V, \mathcal{C})$  é uma instância do problema  $\text{MAXSAT}$  na qual cada cláusula tem no máximo  $k$  variáveis, com  $k \geq 1$ , e  $X_{\mathcal{C}}$  é a variável aleatória<sup>3</sup> cujo valor é o número de cláusulas de  $\mathcal{C}$  satisfeitas por uma valoração produzida pelo algoritmo  $\text{MAXSAT-GW}(V, \mathcal{C})$ , então

No máximo  $k$  (ao invés de pelo menos  $k$ )

$$\mathbf{E}[X_{\mathcal{C}}] \geq \left(1 - \left(1 - \frac{1}{k}\right)^k\right) \text{opt}(V, \mathcal{C}).$$

**Demonstração:** Para cada cláusula  $C$ , defina  $Z_C$  da maneira usual:  $Z_C$  vale 1 se a valoração produzida pelo algoritmo satisfaz  $C$  e 0 em caso contrário. A probabilidade de que  $Z_C$  seja 0 é o produto de termos da forma  $\hat{x}_v$ , para  $v$  em  $C_0$ , e  $(1 - \hat{x}_v)$ , para  $v$  em  $C_1$ . Se  $t$  é o número de

<sup>3</sup> O espaço de probabilidade é  $(\Omega, \mathcal{P}_1) \times \dots \times (\Omega, \mathcal{P}_{|V|})$ , onde  $\Omega = \{0, 1\}$  e  $\mathcal{P}_i$  é dado por  $\mathcal{P}_i(1) = \hat{x}_i$  e  $\mathcal{P}_i(0) = 1 - \hat{x}_i$  para cada  $i$  em  $V$ .

$$t = C_0 + C_1$$

68

variáveis de  $C$  então  $t \geq 1$  e

$$\Pr[Z_C=1] = 1 - \prod_{v \in C_0} \hat{x}_v \prod_{v \in C_1} (1 - \hat{x}_v) \geq 1 - ((t - \hat{z}_C)/t)^t \tag{6.3}$$

$$= 1 - (1 - \hat{z}_C/t)^t \geq (1 - (1 - 1/t)^t) \hat{z}_C \tag{6.4}$$

$$\geq (1 - (1 - 1/k)^k) \hat{z}_C. \tag{6.5}$$

Para justificar (6.3), note que a média geométrica de números não-negativos não ultrapassa a sua média aritmética. Disso temos que

$$\begin{aligned} \prod_{v \in C_0} \hat{x}_v \prod_{v \in C_1} (1 - \hat{x}_v) &\leq ((\sum_{v \in C_0} \hat{x}_v + \sum_{v \in C_1} (1 - \hat{x}_v))/t)^t \\ &= ((t - \sum_{v \in C_0} (1 - \hat{x}_v) - \sum_{v \in C_1} \hat{x}_v)/t)^t \\ &\leq ((t - \hat{z}_C)/t)^t. \end{aligned}$$

Vem da restrição do modelo

Para verificar (6.4), considere a função  $f(z) := 1 - (1 - z/t)^t$ . Observe que  $f$  é côncava no intervalo fechado  $[0, 1]$ , pois  $f'(z) \geq 0$  e  $f''(z) \leq 0$  nesse intervalo. Então, como  $f(0) = 0$ , temos que  $f(z) \geq z f(1)$ , que se traduz em (6.4). Finalmente, (6.5) vale pois  $(1 - 1/t)^t$  é crescente para  $t \geq 1$  e, por hipótese,  $t \leq k$ .

Podemos agora calcular o valor esperado de  $X_C$ :

$$\begin{aligned} \mathbf{E}[X_C] &= \mathbf{E}[\sum_C Z_C] \\ &= \sum_C \mathbf{E}[Z_C] \\ &= \sum_C \Pr[Z_C=1] \\ &\geq \sum_C (1 - (1 - 1/k)^k) \hat{z}_C \\ &\geq (1 - (1 - 1/k)^k) \text{opt}(V, \mathcal{C}), \end{aligned}$$

Linearidade da esperança: a esperança da soma é a soma das esperanças

Pois  $Z_C$  é uma v.a. indicadora (0-1)

Pois a solução do modelo relaxado é maior ou igual ao original

onde a última desigualdade segue de (6.2).  $\square$

Como  $(1 - 1/k)^k$  não passa de  $1/e$  para todo  $k \geq 1$ , onde  $e$  é a base dos logaritmos naturais, temos que  $(1 - 1/k)^k < 1/e < 0,37$ . Desse fato, e do teorema anterior, é imediato o seguinte resultado.

**Teorema 6.4:** O algoritmo MAXSAT-GW é uma **0,63-aproximação probabilística** polinomial para o MAXSAT.  $\square$

### Algoritmo combinado

O teorema 6.1 permite deduzir uma razão de **aproximação melhor do algoritmo MAXSAT-JOHNSON** quando todas as cláusulas têm pelo menos

	Razões de aproximação			
Valor de k	1	2	3	4
MaxSat-Johnson	1/2	3/4	7/8 = 0,875	0.94
MaxSat-GW	1	3/4	19/27 = 0,7	0.68

1 menos a probabilidade de ser falsa

literals negativos devem ser V

literals positivos devem ser F

ALGORITMOS PROBABILÍSTICOS

duas variáveis. Já para o algoritmo **MAXSAT-GW** obtêm-se resultados melhores quando as cláusulas têm no máximo duas variáveis, pelo teorema 6.3. Parece razoável, portanto, combinar os dois algoritmos. O algoritmo abaixo deve-se a Goemans e Williamson [GW94] também.

**Algoritmo MAXSAT-COMBINADO-GW** ( $V, \mathcal{C}$ )

- 1  $\hat{x} \leftarrow \text{MAXSAT-JOHNSON}(V)$
- 2  $\tilde{x} \leftarrow \text{MAXSAT-GW}(V, \mathcal{C})$
- 3 seja  $\hat{s}$  o número de cláusulas de  $\mathcal{C}$  satisfeitas por  $\hat{x}$
- 4 seja  $\tilde{s}$  o número de cláusulas de  $\mathcal{C}$  satisfeitas por  $\tilde{x}$
- 5 se  $\hat{s} \geq \tilde{s}$
- 6     então devolva  $\hat{x}$
- 7     senão devolva  $\tilde{x}$

**Teorema 6.5:** *O algoritmo MAXSAT-COMBINADO-GW é uma 0,75-aproximação probabilística polinomial para o MAXSAT.*

**Demonstração:** Seja  $\mathcal{C}_k$  a coleção das cláusulas de  $\mathcal{C}$  que têm exatamente  $k$  variáveis. Sejam  $X_c$ ,  $\dot{X}_c$  e  $\ddot{X}_c$  variáveis aleatórias cujos valores são o número de cláusulas de  $\mathcal{C}$  satisfeitas por uma valoração produzida por **MAXSAT-COMBINADO-GW** ( $V, \mathcal{C}$ ), **MAXSAT-JOHNSON** ( $V$ ) e **MAXSAT-GW** ( $V, \mathcal{C}$ ), respectivamente. Note que  $X_c \geq \frac{1}{2}(\dot{X}_c + \ddot{X}_c)$ . Se refizermos as partes apropriadas das demonstrações dos teoremas 6.1 e 6.3 temos

pois o máximo é maior ou igual a média

Analisar a tabela anterior

$$\begin{aligned}
 \mathbf{E}[X_c] &\geq \mathbf{E}\left[\frac{1}{2}(\dot{X}_c + \ddot{X}_c)\right] \\
 &= \frac{1}{2}(\mathbf{E}[\dot{X}_c] + \mathbf{E}[\ddot{X}_c]) \\
 &\geq \frac{1}{2} \sum_k \sum_{C \in \mathcal{C}_k} ((1 - 2^{-k}) + (1 - (1 - k^{-1})^k)) \hat{z}_C \\
 &\geq \frac{1}{2} \sum_k \sum_{C \in \mathcal{C}_k} (1 - 2^{-k} + 1 - (1 - k^{-1})^k) \hat{z}_C \\
 &\geq \frac{1}{2} \sum_k \sum_{C \in \mathcal{C}_k} \frac{3}{2} \hat{z}_C & (6.6) \\
 &\geq \frac{3}{4} \text{opt}(V, \mathcal{C}). & (6.7)
 \end{aligned}$$

onde a desigualdade (6.6) pode ser concluída analisando-se os casos  $k = 1$ ,  $k = 2$  e  $k \geq 3$  e (6.7) vale em virtude de (6.2).  $\square$

## 6.2 Desaleatorização

Em muitos casos, é possível converter um algoritmo de aproximação probabilístico em um determinístico com uma razão de aproximação

igual à razão esperada do algoritmo probabilístico. Isso pode ser feito através do **método das esperanças condicionais** [AS92, ES74, Spe87]. Para aplicá-lo, precisamos saber calcular eficientemente certas esperanças condicionais, que dependem do problema em foco. É esse o cerne do processo de desaleatorização de um algoritmo probabilístico por esse método. Ilustramos o método aplicando-o ao algoritmo MAXSAT-JOHNSON. Obtemos como resultado a seguinte 0,5-aproximação polinomial determinística, que utiliza um procedimento ESPCOND, detalhado posteriormente.

**Algoritmo** MAXSAT-JOHNSON-DESALEATORIZADO ( $V, \mathcal{C}$ )

```

1   $\mathcal{D} \leftarrow \mathcal{C}$ 
2  para cada  $v$  em  $V$  faça
3    se  $\text{ESPCOND}(v, 1, \mathcal{D}) \geq \text{ESPCOND}(v, 0, \mathcal{D})$ 
4      então  $\hat{x}_v \leftarrow 1$ 
5        para cada  $C$  em  $\mathcal{D}$  faça
6          se  $v \in C_1$ 
7            então  $\mathcal{D} \leftarrow \mathcal{D} \setminus \{C\}$ 
8            senão  $C_0 \leftarrow C_0 \setminus \{v\}$ 
9        senão  $\hat{x}_v \leftarrow 0$ 
10       para cada  $C$  em  $\mathcal{C}$  faça
11         se  $v \in C_0$ 
12           então  $\mathcal{D} \leftarrow \mathcal{D} \setminus \{C\}$ 
13           senão  $C_1 \leftarrow C_1 \setminus \{v\}$ 
14  devolva  $\hat{x}$ 

```

Cláusula  $C$  satisfeita por  $v$  é removida

$v$  é removido de  $C$ , pois não pode satisfazê-la

No algoritmo acima,  $\mathcal{D}$  é um multiconjunto (um conjunto em que cada elemento aparece com uma certa multiplicidade). No início de cada iteração,  $\mathcal{D}$  contém, além de pares  $\{\emptyset, \emptyset\}$ , que chamaremos de **pseudo-cláusulas**, apenas as cláusulas de  $\mathcal{C}$  que a “valoração parcial”  $\hat{x}$  do algoritmo ainda não satisfaz. Ademais, de cada cláusula de  $\mathcal{C}$  em  $\mathcal{D}$ , foram eliminadas as variáveis cujos valores  $\hat{x}$  já fixou.

O procedimento auxiliar ESPCOND recebe uma variável  $v$ , um elemento  $i$  de  $\{0, 1\}$  e um multiconjunto  $\mathcal{D}$  de cláusulas e pseudo-cláusulas. Seja  $X_{\mathcal{D}}$  a variável aleatória cujo valor é o número de cláusulas em  $\mathcal{D}$ , levando em conta a multiplicidade, satisfeitas por uma valoração produzida pelo algoritmo MAXSAT-JOHNSON( $V$ ). Se  $i = 1$  então o procedimento devolve o valor esperado de  $X_{\mathcal{D}}$  sob a condição que  $\hat{x}_v=1$  no algoritmo



MAXSAT-JOHNSON. Este valor esperado é denotado por  $\mathbf{E}[X_{\mathcal{D}}|\dot{x}_v=1]$ . Se  $i = 0$  então o procedimento devolve  $\mathbf{E}[X_{\mathcal{D}}|\dot{x}_v=0]$ , que é definido de maneira análoga.

**Procedimento** ESPCOND( $v, i, \mathcal{D}$ )

```

1  esp ← 0
2  para cada C em D faça
3    k ← |C1| + |C0|
4    se v ∈ Ci
5      então esp ← esp + 1
6      senão se v ∈ C1-i
7        então esp ← esp + (1 - 2-k+1)
8        senão esp ← esp + (1 - 2-k)
9  devolva esp

```

Calcula a Esperança do número de cláusulas satisfeitas, condicionado a variável v ter valor i=0 ou i=1

**Teorema 6.6:** O algoritmo MAXSAT-JOHNSON-DESALEATORIZADO é uma 0,5-aproximação polinomial para o MAXSAT.

Demonstração: Seja  $X_{\mathcal{C}}$  a variável aleatória cujo valor é o número de cláusulas em  $\mathcal{C}$  satisfeitas por uma valoração produzida pelo algoritmo MAXSAT-JOHNSON( $V$ ). Como, no algoritmo MAXSAT-JOHNSON,  $\dot{x}_v = 1$  com probabilidade  $1/2$  e  $\dot{x}_v = 0$  com probabilidade  $1/2$ , temos que  $\mathbf{E}[X_{\mathcal{C}}] = \frac{1}{2}\mathbf{E}[X_{\mathcal{C}}|\dot{x}_v=1] + \frac{1}{2}\mathbf{E}[X_{\mathcal{C}}|\dot{x}_v=0]$ , e disso concluímos que  $\mathbf{E}[X_{\mathcal{C}}]$  não ultrapassa o maior entre as duas esperanças condicionais,  $\mathbf{E}[X_{\mathcal{C}}|\dot{x}_v=1]$  e  $\mathbf{E}[X_{\mathcal{C}}|\dot{x}_v=0]$ . Logo,  $\mathbf{E}[X_{\mathcal{C}}] \leq \mathbf{E}[X_{\mathcal{C}}|\dot{x}_{v_1}]$ , onde o último termo denota o valor esperado de  $X_{\mathcal{C}}$  sob a condição que, no algoritmo MAXSAT-JOHNSON, atribua-se a  $\dot{x}_{v_1}$  o mesmo valor atribuído no algoritmo MAXSAT-JOHNSON-DESALEATORIZADO. Uma vez fixado o valor de  $\dot{x}_{v_1}$ , o mesmo raciocínio vale para as demais variáveis e, disso, concluímos que

Em MaxSat-GW, é um pouco diferente

Pois fomos escolhendo as maiores esperanças condicionais

$$X = (x_v) * \mathbf{E}[X | v=1] + (1-x_v)*\mathbf{E}[X | v=0]$$

$$\mathbf{E}[X_{\mathcal{C}}] \leq \mathbf{E}[X_{\mathcal{C}}|\dot{x}_{v_1}] \leq \mathbf{E}[X_{\mathcal{C}}|\dot{x}_{v_1}, \dot{x}_{v_2}] \leq \dots \leq \mathbf{E}[X_{\mathcal{C}}|\dot{x}_{v_1}, \dots, \dot{x}_{v_n}].$$

O último termo é o número de cláusulas de  $\mathcal{C}$  satisfeitas pela valoração  $\dot{x}$  produzida pelo algoritmo MAXSAT-JOHNSON-DESALEATORIZADO. Esse número é pelo menos  $0,5 \text{opt}(V, \mathcal{C})$ , pois  $\mathbf{E}[X_{\mathcal{C}}] \geq 0,5 \text{opt}(V, \mathcal{C})$ .

Quanto ao tempo de execução do algoritmo, basta observar que o procedimento ESPCOND( $v, i, \mathcal{D}$ ) consome tempo  $O(|V|)$ . Disso, é fácil concluir que o algoritmo MAXSAT-JOHNSON-DESALEATORIZADO é polinomial.  $\square$

É um pouco surpreendente que desaleatorizações produzam, mesmo sem levar em conta como as variáveis aleatórias se distribuem em torno do valor esperado, um algoritmo com razão de aproximação igual à razão esperada do algoritmo probabilístico. No caso do algoritmo acima, o procedimento para o cálculo das esperanças condicionadas é bem simples. Em outros problemas, esses cálculos podem ser bastante complicados, inviabilizando o processo de desaleatorização.

### 6.3 Geradores de números aleatórios

Uma maneira mais geral de definir algoritmos probabilísticos parte de um gerador de números aleatórios no intervalo  $[0, 1)$ . Nessa definição alternativa, substitui-se o algoritmo **RAND** por um algoritmo ideal **RANDUNI** que devolve um número real aleatório com distribuição uniforme no intervalo  $[0, 1)$  (apêndice D). Existem implementações aproximadas desse algoritmo **RAND** [Knu98].

Os conceitos introduzidos no início deste capítulo (algoritmo de aproximação probabilístico, algoritmo probabilístico polinomial, etc.) podem ser naturalmente adaptados a esta outra definição. Em particular, os algoritmos vistos neste capítulo são probabilísticos polinomiais também de acordo com esta nova definição, pois é fácil implementar **RAND( $\rho$ )** com uma chamada a **RANDUNI**: o algoritmo **RAND** devolve 1 se o número devolvido por **RANDUNI** for menor que  $\rho$  e devolve 0 em caso contrário.

Por outro lado, não se sabe, em geral, converter um algoritmo que chama **RANDUNI** um número polinomial de vezes em um que chama **RAND** um número polinomial de vezes. Por isso é razoável dizer que esta nova definição é uma generalização da original. A desvantagem da nova definição é que ela requer manipulação números reais.

## Exercícios

6.1 Considere o seguinte algoritmo para o **MAXSAT** ( $V, C$ ).

**Algoritmo MAXSAT-CARACOROA** ( $V$ )

- 1  $b \leftarrow \text{RAND}(\frac{1}{2})$
- 2 para cada  $v$  em  $V$  faça  $\hat{x}_v \leftarrow b$
- 3 devolva  $\hat{x}$

Mostre que o algoritmo acima é uma 0,5-aproximação probabilística polinomial para o **MAXSAT**.

- Seja  $C$  uma cláusula qualquer. Qual a probabilidade de  $C$  ser verdadeira?
- Se  $C$  possui literais todos positivos (não complementados), então a probabilidade de todos serem verdadeiros é  $1/2$ .
- Se  $C$  possui literais todos negativos (complementados), então a probabilidade de todos serem falsos é  $1/2$ .
- Se  $C$  possui literais positivos e negativos, então a probabilidade de  $C$  ser verdadeira é  $1$ .
- Portanto, qualquer cláusula tem pelo menos  $1/2$  de probabilidade de ser verdadeira, e o número de cláusulas satisfeitas é em média metade do total de cláusulas. Essa número esperado é maior ou igual a metade do ótimo (número máximo de cláusulas satisfeitas).

Vamos criar um conjunto  $A$  aleatoriamente. Para cada vértice  $v$  de  $G$ , coloque  $v$  em  $A$  com probabilidade  $1/2$ . Seja  $B = V(G) - A$ . Vamos analisar o peso do corte  $(A, B)$  de  $G$ .

Cada aresta  $(u, v)$  tem  $1/2$  de probabilidade de estar entre  $A$  e  $B$ :  
 $u$  em  $A$  e  $v$  em  $B$  ---> prob.  $1/4$   
 $u$  em  $B$  e  $v$  em  $A$  ---> prob.  $1/4$

O peso esperado do corte  $(A, B)$  é metade do peso total das arestas. Esse peso esperado é maior ou igual à metade do peso do corte máximo.

6.2 Inspire-se no algoritmo MAXSAT-JOHNSON e projete uma 0,5-aproximação probabilística polinomial para o problema do corte máximo:

**Problema MAXCUT  $(G, w)$ :** Dado um grafo  $G$  e um peso  $w_e$  em  $\mathbb{Q}_{\geq}$  para cada aresta  $e$  de  $G$ , encontrar um corte  $R$  que maximize  $w(R)$ .

Apresente uma versão desaleatorizada do seu algoritmo.

6.3 Projete uma 0,5-aproximação probabilística polinomial para a seguinte variante do MAXCUT (exercício 6.2), que denotamos por MAX $k$ CUT: dados um grafo  $G$ , um peso  $w_e$  em  $\mathbb{Q}_{\geq}$  para cada aresta  $e$  e um inteiro  $k \geq 2$ , determinar uma partição de  $V_G$  em  $k$  partes que maximize a soma do peso das arestas com extremos em partes distintas da partição.

6.4 Projete uma 0,5-aproximação probabilística polinomial para o problema da cobertura máxima (exercício 2.4). Mostre que a versão desaleatorizada deste algoritmo é exatamente o algoritmo guloso sugerido no exercício 2.4.

6.5 Escreva uma versão desaleatorizada do algoritmo MAXSAT-GW. Apresente-a da forma mais simples que puder omitindo, se possível, todos os vestígios “probabilísticos” do algoritmo original. Prove, sem usar argumentos probabilísticos, que o algoritmo obtido é uma 0,63-aproximação para MAXSAT.

É possível também obter um algoritmo MaxSat-Combinado-GW-Desaleatorizado com fator de aprox 3/4 determinístico

6.6 Considere o seguinte algoritmo probabilístico para o MAXSAT:

**Algoritmo MAXSAT-COMBINADO-PROBABILÍSTICO  $(V, \mathcal{C})$**

- 1  $b \leftarrow \text{RAND}(\frac{1}{2})$
- 2 se  $b = 0$
- 3 então  $\hat{x} \leftarrow \text{MAXSAT-JOHNSON}(V)$
- 4 senão  $\hat{x} \leftarrow \text{MAXSAT-GW}(V, \mathcal{C})$
- 5 devolva  $\hat{x}$

Prove que esse algoritmo é uma 0,5-aproximação probabilística polinomial para o MAXSAT. Escreva e comente a versão desaleatorizada deste algoritmo. O que muda se alterarmos o  $\frac{1}{2}$  da linha 1 do algoritmo para um outro valor no intervalo  $(0, 1)$ ?

6.7 Considere a seguinte versão ponderada do MAXSAT. Além do conjunto  $V$  e da coleção  $\mathcal{C}$  de cláusulas sobre  $V$ , é dado também um peso  $w_C$  em  $\mathbb{Q}_{\geq}$  para cada cláusula  $C$  em  $\mathcal{C}$ ; o problema consiste em encontrar uma valoração que maximize a soma dos pesos das cláu-

O algoritmo Graham-aleatório é 2-aproximativo, pois Escalonamento-Graham é 2-aproximativo.

É possível obter instâncias que se aproximam do fator 2 de aproximação esperado.

Instância limite:  $n$  tarefas de tempo  $n$  e  $(n+1)n^2$  tarefas de tempo 1 em  $n(n+2)$  máquinas.  
Ótimo: tempo  $n$  em cada máquina.

Ordem aleatória: Sorteia uniformemente número em  $[0,1]$  para cada tarefa.  
A ordem desses números determina a ordem das tarefas.

Ideia: Order Statistics: Número esperado da última tarefa grande  $n/(n+1)$   
Aproximadamente  $(n/(n+1)) * (n+1)n^2 = n^3$  tarefas pequenas antes da última tarefa grande.

Algoritmo Escalonamento-Graham: tempo  $n + n^3/(n(n+2)) \rightarrow 2n = 2 * \text{opt}$  (ver slides da disciplina)

74

sulas satisfeitas. Modifique os três algoritmos apresentados neste capítulo, bem como suas análises, para o MAXSAT ponderado. Que razão de aproximação tem cada um dos algoritmos modificados?

**6.8 Considere o seguinte algoritmo para o ESCALONAMENTO (seção 2.1): escolha aleatoriamente a próxima tarefa a ser escalonada e aplique o critério de Graham. Estime o valor esperado da solução assim obtida.**

## Notas bibliográficas

A discussão do algoritmo MAXSAT-GW é um resumo de um artigo de Goemans e Williamson [GW94]; resumos semelhantes aparecem no livro de Motwani e Raghavan [MR95b] e no livro editado por Hochbaum [Hoc97]. Os exercícios 6.1, 6.3 e 6.4 foram extraídos do livro de Vazirani [Vaz01].

O livro de Motwani e Raghavan [MR95b] é um texto abrangente sobre algoritmos probabilísticos, com muitos exercícios e problemas de pesquisa.

O algoritmo MAXSAT-JOHNSON é atribuído a Johnson [Joh74], embora este tenha escrito a versão não-probabilística do algoritmo. A primeira 0,75-aproximação polinomial para o MAXSAT deve-se a Yannakakis [Yan94]. Zwick [Zwi99] projetou um algoritmo de aproximação para um caso particular do MAXSAT e conjecturou, baseando-se em experimentos numéricos, que seu algoritmo é uma 0,797-aproximação para o problema. **Recentemente, Asano e Williamson [AW00] projetaram uma 0,784-aproximação, combinando vários algoritmos conhecidos para o problema** [GW94, FG95, KZ97]. No momento, esse é o melhor algoritmo de aproximação conhecido para o MAXSAT. Utilizando o algoritmo de Zwick [Zwi99], Asano e Williamson obtêm uma 0,833-aproximação para o MAXSAT, desde que a conjectura de Zwick seja confirmada.

A técnica de arredondamento probabilístico foi introduzida por Raghavan e Thompson [RT87, Rag88] e vem sendo aplicada com bastante sucesso a vários problemas [BTV99, CKR00, Fei99, JV00].

O método das esperanças condicionais aparece implicitamente em um artigo de Erdős e Selfridge [ES73]. A conexão com algoritmos polinomiais determinísticos foi feita por Spencer [Spe87].

Uma outra técnica bem sucedida de desaleatorização de algoritmos probabilísticos foi desenvolvida por Luby [Lub86] e por Alon *et al.* [ABI86]. Uma sucessão de chamadas ao algoritmo RAND produz

uma seqüência de *bits* aleatórios. Podemos imaginar então que, além dos dados do problema, um algoritmo probabilístico recebe uma seqüência de *bits* aleatórios, de comprimento conveniente. Freqüentemente, basta que os *bits* nessa seqüência sejam  $k$ -mutuamente independentes. Para explicar este conceito, denote por  $b_1, \dots, b_n$  os *bits* produzidos por  $n$  chamadas de RAND. Dizemos que  $b_1, \dots, b_n$  são  **$k$ -mutuamente independentes** se, para qualquer subseqüência  $b_{i_1}, \dots, b_{i_k}$  de  $b_1, \dots, b_n$ , a probabilidade de que  $b_{i_1}, \dots, b_{i_k}$  coincida com qualquer das  $2^k$  seqüências de  $k$  *bits* é  $2^{-k}$ . Enquanto independência plena requer um espaço de probabilidade composto de  $2^n$  vetores binários, pode-se construir espaços de probabilidade com  $n^{k/2}$  vetores binários cujos *bits* são  $k$ -mutuamente independentes. Se  $k$  é constante, um algoritmo probabilístico pode ser desaleatorizado da seguinte forma: executa-se o algoritmo para cada um dos vetores neste espaço de probabilidade e devolve-se a melhor das soluções produzidas. Isso resulta em um algoritmo polinomial, determinístico, e com razão de aproximação igual à razão esperada do algoritmo probabilístico original. Para saber mais sobre isso, veja o artigo de Chor e Goldreich [CG89], bem como o relatório técnico de Luby e Wigderson [LW95].

A respeito de geradores de números pseudo-aleatórios, veja os livros de Johnson [Joh87], Devroye [Dev86] e Knuth [Knu98]. Knuth descreve implementações aproximadas do algoritmo RANDUNI que fornecem números pseudo-aleatórios satisfatórios em tempo probabilístico constante: o tempo *esperado* de execução de tais implementações é limitado por uma constante.